

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇ HIZLI ŞARJ İSTASYONLARINDA ÖNCELİKLİ SERVİS
İÇİN DERİN PEKİŞTİRMELİ ÖĞRENME TABANLI KAYNAK YÖNETİM
MODELİ VE UZUN-KISA SÜRELİ BELLEK İLE ORTALAMA BEKLEME
SÜRESİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Aslınur ÇOLAK

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Nilgün FESCİOĞLU ÜNVER

NİSAN 2023



TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Aslınur ÇOLAK



ÖZET

Yüksek Lisans

ELEKTRİKLİ ARAÇ HIZLI ŞARJ İSTASYONLARINDA ÖNCELİKLİ SERVİS İÇİN DERİN PEKİŞTİRMELİ ÖĞRENME TABANLI KAYNAK YÖNETİM MODELİ VE UZUN-KISA SÜRELİ BELLEK İLE ORTALAMA BEKLEME SÜRESİ TAHMİNİ

Aslınur Çolak

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Nilgün Fescioğlu Ünver

Tarih: Nisan 2023

Günümüzde elektrikli araçlar içten yanmalı motorlu araçların yerini hızla almaktadır. Kıyaslandığında da elektrikli araçların küresel ısınmaya çok daha az etki etme potansiyeli vardır. Ancak bu olumlu etkisine karşın, elektrikli araçların hızlı şarj istasyonlarında 30 dakika olmak üzere uzun şarj dolma süresine ihtiyacı vardır. Hızlı şarj istasyonlarının sayısı ve kapasitelerinin sınırlı olmasıyla birlikte uzun şarj süreleri, istasyonlarda araçların kuyruk uzunluğunu ve bekleme süresini artırmaktadır. Araçların belli bir bölümünün bekleme süresini azaltmak için öncelikli servis veren şarj istasyonları oluşturulabilir. Bunun yanında araç kullanıcıları istasyona varış yaptıklarında şarj olmak için bekleyecekleri ortalama süre hakkında öngörü sahibi olmak isteyebilir. Bu çalışmada iki amaç bulunmaktadır. İlk amaç Derin Q-Öğrenme tabanlı öncelikli servis veren bir şarj istasyonu yönetim modeli geliştirilmesi, ikincisi ise araç kullanıcılarına ortalama bekleme süresi bilgisinin Uzun-Kısa Süreli Bellek yöntemi kullanılarak tahmin edilmesi.

Literatür incelendiğinde hızlı şarj hizmetini ele alan çeşitli çalışmalar vardır. Fiyatlandırma, talep dengeleme, istasyon konumlandırma ve kapasite belirleme,

bekleme sürelerini azaltmak için şarja kabul edilen araç sayısının kısıtlanması gibi konularda çalışmalar bulunmaktadır.

Bu çalışmada elektrikli şarj istasyonuna gelen araçlar düşük ve yüksek öncelikli iki araç sınıfına ayrılmaktadır. Ekspres (öncelikli) şarj istasyonu yönetim modelinin amacı, bu araç sınıflarının ortalama bekleme sürelerinin oranının belirli bir seviyede tutmaktır. İstasyon, hedeflediği görece bekleme süresi oranını belirler ve ilan eder ve hedefini tutturmak için boşalan kaynaktan hizmet alacak öncelik sınıfını gerçek zamanda dinamik olarak değiştirir. Bu değişiklik için Derin Q-Öğrenme tabanlı kaynak kontrol mekanizması geliştirilmiştir ve performansı çeşitli şartlar altında test edilmiştir. Ayrıca geliştirilen yöntemin performansı literatürde bu alandaki Fescioglu-Unver ve diğ. (2021) ve Kakillioglu ve diğ. (2022) çalışmalarıyla kıyaslanmıştır. Sonuçlar incelendiğinde geliştirilen yöntemin hedeflenen bekleme oranını gerçekleştirdiği ve istasyona gelecek ani araç yüklenmeleri karşısında hızlı bir şekilde toparlanabildiği gözlenmiştir.

Literatürde elektrikli araçlar ve şarj istasyonları alanında ise bekleme süresi tahmini yapan bir çalışmaya rastlanmamıştır. Bu çalışmada, istasyondan gerçek zamanda veri toplanarak takip eden 5 dakika içinde gelecek araçlar için tahmini bekleme süresi ilan edilmektedir. Tahmin için Uzun-Kısa Süreli Bellek (LSTM) yöntemi kullanılmaktadır. Buna ek olarak, LSTM yönteminin tahmin kalitesi yapay sinir ağı yöntemi de çalışmada uygulanarak karşılaştırılmış ve daha iyi performans gösterdiği görülmüştür.

Anahtar Kelimeler: Elektrikli araç, Ekspres şarj, Derin Q-öğrenme, Bekleme süresi tahmini.

ABSTRACT

Master of Science

DEEP REINFORCEMENT LEARNING BASED RESOURCE MANAGEMENT
MODEL FOR PRIORITY SERVICE IN ELECTRIC VEHICLE EXPRESS
CHARGING STATIONS AND AVERAGE DELAY TIME PREDICTION WITH
LONG-SHORT-TERM MEMORY

Aslınur Çolak

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Industrial Engineering Science Programme

Supervisor: Assoc. Prof. Nilgün Fescioğlu-Ünver

Date: April 2023

Today, electric vehicles are rapidly replacing internal combustion engine vehicles. Moreover, electric vehicles have much less potential to contribute to global warming. However, despite this positive impact of electric vehicles, they require much longer charging times, up to 30 minutes at fast charging stations. With the limited number and capacity of fast charging stations, the long charging times increase the queue length and waiting time of vehicles at the stations. Charging stations with priority service can be a solution to reduce the waiting time of a certain portion of the vehicles. In addition, drivers may want to know the average time they will have to wait for charging when they arrive at the station. There are two aims in this thesis. The first objective is to develop a charging station management model with priority service based on Deep Q-Learning, the second objective is to predict the average delay time of electric vehicles using the Long-Short Term Memory method. There are various studies on fast charging service in the literature. There are studies on dynamic pricing of charging, demand balancing, charge station location selection

and capacity determination, restricting the number of vehicles accepted for charging to reduce waiting times.

In this study, vehicles arriving at the electric charging station are categorized into two vehicle classes as low and high priority. The aim of the express (priority service) charging station management model is to try to keep the ratio of the average delay times of the vehicle classes at a target level. The station determines and announces this target relative delay time ratio. In order to achieve its target rate, the priority class charging from the idle resource is dynamically changed in real time. For this dynamic and real time control, a resource management mechanism based on Deep Q-Learning, a deep reinforcement learning method, is developed. The performance of the method at a single station is tested by simulation under various conditions. In addition, the performance of the developed method is compared with Fescioglu-Unver et al. (2021) and Kakillioglu et al. (2022) the studies about the same subject in the literature. When the results are analyzed, the developed method tracks the target delay rate successfully also the station settles quickly against the impact of instantaneous vehicle impulses.

In the literature, there is no study on waiting time prediction in the field of electric vehicles and charging stations. Waiting time estimation studies have mostly been conducted on waiting times in emergency services. In this thesis, Long-Short Term Memory (LSTM) method is used to provide the predicted average waiting time information for both high and low priority vehicles using the data collected from the station real-time. Additionally, the prediction accuracy of the LSTM method was compared by Artificial Neural Network method in the study. As a result, it is found that LSTM has superior performance.

Keywords: Electric vehicle, Express charging, Deep Q-learning, Waiting time prediction.

TEŞEKKÜR

Eđitim süresi boyunca burs imkânı sağladığı için TOBB Ekonomi ve Teknoloji Üniversitesi'ne, çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren danışman hocam Doç. Dr. Nilgün FESCİOĐLU ÜNVER'e, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Endüstri Mühendisliđi Bölümü öğretim üyelerine ve tezimi okuyup değerlendiren jüri üyeleri hocalarım Doç. Dr. Ayşegül ALTIN KAYHAN ve Dr. Öğretim Üyesi Elif Tuğçe CERAN ARSLAN'a ve destekleriyle her zaman yanımda olan aileme ve arkadaşlarıma çok teşekkür ederim. Son olarak beni 2210/A Yurt İçi Genel Yüksek Lisans Burs Programı kapsamında destekleyen TÜBİTAK'a teşekkür ederim.

İÇİNDEKİLER

ÖZET	v
ABSTRACT	vii
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
ŞEKİL LİSTESİ	xiii
ÇİZELGE LİSTESİ	xv
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	5
2.1 Elektrikli Araçları Şarj İstasyonlarına Yönlendirerek İstasyonlar Arası Talep Dağılımını Düzenleyen Çalışmalar	6
2.2 Şarj İstasyonlarının Konumlandırılması ve Boyutlandırılması Konusundaki Çalışmalar.....	12
2.3 Şarj istasyonlarındaki Elektriğin Akıllı Şebeke Aracılığı ile Yönetilmesi ve Maliyet Minimizasyon Çalışmaları	14
2.4 Pekiştirmeli Öğrenme Yaklaşımını Elektrikli Araç Şarj İstasyonu Alanında Kullanan Çalışmalar	17
2.5 Şarj İstasyonlarında Öncelikli Şarj Alanında Yapılan Çalışmalar	20
2.6 Diğer Alanlarda Yapılan Sunucu Sayısını Dinamik Olarak Değiştiren Çalışmalar.....	22
2.7 Bekleme Süresi Tahmini Yapan Çalışmalar	23
3. EKSPRES ŞARJ İSTASYONU YÖNETİMİ	25
3.1 Ekspres Şarj İstasyonu Yerleşim ve İşleyişi	25
3.2 Görece Bekleme Modeli	28
3.3 Karşılaştırmada Kullanılan Modeller	29
3.3.1 SC-EXP (Açık çevrim) kontrol yöntemi.....	29
3.3.2 FC-EXP (Kapalı çevrim) kontrol yöntemi.....	30
3.3.3 Sabit sunucu yöntemi	30
4. SİMÜLASYON MODELİ	33
5. PEKİŞTİRMELİ ÖĞRENME İLE KONTROL METODU (RL-EXP)....	35
5.1 Monitör.....	37
5.2 Sistem Yöneticisi	38
5.2.1 Kaynak yöneticisi.....	38
5.2.2 LSTM bekleme süresi tahmincisi.....	39
5.3 Kontrolcü	40
5.4 RL-EXP modeli.....	41
5.4.1 Pekiştirmeli öğrenme (RL).....	41
5.4.2 Q-öğrenme.....	44
5.4.3 Derin Q-öğrenmesi.....	44
5.5 Kontrolör Parametrelerinin Belirlenmesi.....	46
6. RL-EXP KAYNAK YÖNETİM MODELİ PERFORMANS ANALİZİ	51
6.1 Kararlı Hâlde Görelî Gecikme Performansı.....	52
6.2 Gerçek Zamanlı Görelî Gecikme Performansı.....	57

6.3	Tepki Süresi Performansı	60
7.	BEKLEME SÜRESİ TAHMİNİ.....	63
7.1	Yapay Sinir Ağları	64
7.2	Uzun Kısa Süreli Bellek Sinir Ağları (LSTM).....	67
7.3	Ortalama Bekleme Süresi Tahmin Modeli Eğitim Veri Setinin Hazırlanması ve Performans Ölçütleri	70
7.4	Uzun Kısa Süreli Bellek (LSTM) Tahmin Modeli Geliştirilmesi.....	72
7.5	Yapay Sinir Ağı Tahmin Modelinin Geliştirilmesi.....	74
7.6	LSTM ve YSA Yöntemine Ait Sonuçlar ve Performans Karşılaştırması..	76
8.	TARTIŞMA VE GELECEK ÇALIŞMALAR.....	87
	KAYNAKÇA	91
	EKLER.....	101



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: Ekspres şarj istasyonu yerleşimi.....	26
Şekil 3.2: Sistem aktivite diyagramı.....	26
Şekil 5.1: RL-EXP modeli bileşenleri.....	35
Şekil 5.2: Pekiştirmeli öğrenme algoritma sınıflandırması.....	41
Şekil 5.3: Ajan ve çevre etkileşimi.....	42
Şekil 5.4: Derin Q-Öğrenmesi algoritmasının sözde kodu.....	46
Şekil 5.5: Derin pekiştirmeli öğrenme yönteminde ajanın eğitimi aşamasında bölüm sayısına karşılık topladığı ortalama ödül miktarı.....	50
Şekil 6.1: (a) RL-EXP, (b) SC-EXP (c) FC-EXP Kararlı durum performansı – $\rho = 0.95$ iken farklı EX-Araç oranları (pe) ve farklı hedef görece bekleme oranları (φ) için $diff$	54
Şekil 6.2: Gerçek zamanlı performans – $\varphi = 1.5$, $pe = 0.5$ ve $\rho = 0.95$ koşulları altında 9 dakikalık zaman penceresinde $EX_{bekleme}(t)$ ve $NR_{bekleme}(t)$...	58
Şekil 6.3: Tepki süresi performansı – 20 EX-Araç varışının ortalama $diffQ(t)$ üzerinde etkisi ($\rho = 0.95$, $pe = 0.5$, $\varphi = 1.5$).....	61
Şekil 6.4: Tepki süresi performansı – Farklı hedef görece bekleme oranları için %95 güven aralığı ile tepki süresi karşılaştırması ($\rho = 0.95$, $pe = 0.5$).....	62
Şekil 7.1: Yapay Sinir Ağlarında kullanılan aktivasyon fonksiyonları.....	65
Şekil 7.2: Regresyon problemi için basit LSTM mimarisi.....	67
Şekil 7.3: LSTM hücre durumu.....	68
Şekil 7.4: LSTM ağ modelinde kapı gösterimi.....	68
Şekil 7.5: LSTM unutmaya kapısı katmanı.....	69
Şekil 7.6: Yeni bilginin hücre durumunda saklanması.....	69
Şekil 7.7: LSTM tahmin modeli ağ yapısı.....	72
Şekil 7.8: EX-Araçlara ait tahmin için LSTM ağı eğitim aşaması.....	74
Şekil 7.9: YSA tahmin modeli için çok katmanlı ağın gösterimi.....	74
Şekil 7.10: EX-Araçlara ait tahmin için yapay sinir ağı eğitim aşaması.....	76
Şekil 7.11: LSTM için $TS=5$ dakika, $\varphi = 1.7$ ve $\rho=0.95$ koşullarında EX ve NR dizi ortalamasına karşılık RMSE değeri dağılımı.....	78
Şekil 7.12: LSTM için $TS=15$ dakika, $\varphi = 1.7$ olduğu EX ve NR test verisinde dizi ortalamasına karşılık RMSE değeri dağılımı.....	80
Şekil 7.13: Yapay sinir ağı için $TS=5$ dakika, $\varphi = 1.7$ olduğu EX ve NR dizi ortalamasına karşılık RMSE değeri dağılımı.....	82
Şekil 7.14: Yapay sinir ağı için $TS=15$ dakika, $\varphi = 1.7$ olduğu EX ve NR test verisinde dizi ortalamasına karşılık RMSE değeri dağılımı.....	84
Şekil 7.15: $\varphi=1.5$, doluluk oranı 0.95 ve $TS=5$ dakika koşullarını taşıyan bir EX ve NR test dizisi için gerçek ve tahmini değerlerin karşılaştırılması.....	86



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1: Yönetim metotlarının karşılaştırılması.	29
Çizelge 4.1: Simülasyon modeli değişkenleri.	33
Çizelge 5.1: RL-EXP derin pekiştirmeli öğrenme metodunun parametre ve değerleri.	49
Çizelge 6.1: Simülasyon parametrelerinin farklı performans karşılaştırma yönleri için aldığı farklı değerler.	51
Çizelge 6.2: RL-EXP Kararlı durum performansı – $pe = 0.50$ iken farklı istasyon doluluk oranı ve farklı hedef görece bekleme oranı koşulları altında RL-EXP için gerçekleşen görece bekleme oranı (φr) değerleri.	52
Çizelge 6.3: Kararlı durum performansı – $\rho = 0.95$ ve $pe = 0.50$ durumunda RL-EXP ile diğer metotların kıyaslaması – farklı hedef görece bekleme oranlarına ait gerçekleşmiş görece bekleme oranları (φr).....	55
Çizelge 6.4: RL-EXP Kararlı durum performansı- $\rho = 0.95$ iken uç noktalardaki <i>diff</i> değerlerinin FC-EXP ve SC-EXP ile kıyaslanması 56	56
Çizelge 6.5: Gerçek Zamanlı Performans – $\varphi = 1.5$, $pEX = 0.5$ ve farklı istasyon doluluk oranları koşulu altında RL-EXP ve SC-EXP, Klasik, FC-EXP yöntemi için <i>diff</i> , <i>Min</i> , <i>Max</i> değerleri 59	59
Çizelge 7.1: LSTM ağ hiper parametreleri.	73
Çizelge 7.2: Yapay sinir ağı hiper parametreleri 75	75
Çizelge 7.3: Önümüzdeki 5 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfına ait LSTM ile yapılan tahminlerin RMSE hata değerleri 77	77
Çizelge 7.4: Önümüzdeki 15 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfına ait LSTM ile yapılan tahminlerin RMSE hata değerleri 79	79
Çizelge 7.5: Önümüzdeki 5 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfı için Yapay Sinir Ağı ile yapılan tahminlerin RMSE hata değerleri 81	81
Çizelge 7.6: Önümüzdeki 15 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfı için Yapay Sinir Ağı ile yapılan tahminlerin RMSE hata değerleri. 83	83
Çizelge 7.7: LSTM ve yapay sinir ağı tahmin hataları için özet tablo..... 85	85



1. GİRİŞ

Elektrikli araçlar hem çevreye olumlu etkileri hem de insan yaşamına olumlu etkileri sebebiyle elektrikli araçlar günümüzde giderek önemli hale gelmektedir. Geleneksel araçların çevreye olan hava kirliliği gibi olumsuz etkilerini azaltmak, iklim sağlığının iyileştirilmesi ve zararlı gazların sebep olduğu küresel ısınmanın engellenmesi için elektrikli araçların üretimi ve kullanımı önemli bir tercihtir. Halk sağlığı açısından incelendiğinde de elektrikli araçlarla birlikte egzoz emisyonlarının azalması solunan havanın kalitesinin ve dolayısıyla insan yaşamındaki kalitesinin artması sağlanır (Weeberb ve diğ. (2018)). Üretim ve kullanımın giderek yaygınlaşmasıyla birlikte literatürde de elektrikli araçlar ile ilgili yapılan çalışmalarda artış gözlemlenmektedir. Türkiye'nin üyesi olduğu Elektrikli Araçlar Girişimi (Electric Vehicles Initiative – EVI) üyesi 30 ülke, 2030 yılı hedeflerinin, satılacak araçlardan en az %30'unun elektrikli araçlar olduğunu belirtmiştir. Organizasyon, Çin'de, Avrupa'da ve Birleşik Devletlerde oldukça artış gösterdiğini 2021'de yollarda olan elektrikli araç sayısının 2018'deki miktara göre 3'e katlandığını ve 16,5 milyon olduğunu belirtmiştir (Global Electric Vehicle Outlook, 2021).

Elektrikli araçların geleneksel araçların depo dolum sürelerine göre oldukça uzun şarj olma süreleri vardır. Zorlu Enerji Çözümlerinden aktarılan bilgiye göre elektrikli araçlar evde şarj edildiğinde 1 gece veya daha uzun, normal şarj istasyonlarında 2 ila 4 saat arası sürmekteyken hızlı şarj istasyonlarında 30 dakikaya kadar düşmektedir (Zorlu Energy Solutions, 2022).

Elektrikli araçların pek çok olumlu yönünün yanı sıra araç kullanıcılarının yaşayabileceği bazı problemler ortaya çıkabilmektedir. Bunlardan en önemlisi, uzun şarj sürelerinin kapasitesi ve sayısı sınırlı olan şarj istasyonlarında araç kuyruklarının uzamasına dolayısıyla bekleme sürelerinde artışa ve tıkanıklığa sebebiyet vermesidir. Bu çalışmada daha hızlı şarj olmak için daha yüksek ücret ödeyerek yüksek öncelikli olmayı seçen müşterilere karşın, daha az ücret ödeyen diğer müşteriler düşük öncelikli araç sınıfı olarak belirlenmiştir. Bu çalışmanın ilk bölümünde yukarıda belirtilen öncelik tanımına dayanan öncelikli servis veren hızlı şarj istasyonlarında kuyruğu yönetmek için bir kaynak yönetim modeli geliştirilmiştir.

Geliştirilen model ile araç öncelik sınıflarına ait ortalama bekleme sürelerinin oranı ekspres şarj istasyonunun belirlediği hedef oranda tutulması amaçlanmaktadır. Bu doğrultuda önerilen model şarj cihazlarının (sunucuların/şarj pompalarının) araç öncelik sınıflarına dinamik olarak atamasını Derin Q-Öğrenme Modeli tekniği kullanarak yapmaktadır.

Tez kapsamında yapılan ikinci çalışmada ise istasyondan hizmet almak isteyen farklı öncelik sınıflarından araçlara tahmini ortalama bekleme süresi bilgisi veren bir tahmin modeli geliştirilmiştir. Yöntem olarak Uzun Kısa Süreli Bellek (LSTM) yöntemi kullanılmıştır.

Literatürde araçların konum, şarj bilgisi gibi bilgilerinin kullanarak istasyonlara yönlendiren, istasyona yapacakları toplam yolculuk süresini azaltan, istasyonda çeşitli fiyatlandırma politikalarıyla yoğunluğu düzenleyen, istasyon içinde araç ve kuyrukları düzenleyen çeşitli çalışmalar bulunsa da elektrikli araç şarj istasyonlarında öncelikli servis için kaynak kontrol metodu kullanarak dinamik sunucu ataması yapan 2 çalışma bulunmaktadır. Fescioglu-Unver ve diğ. (2021) ve Kakillioglu ve diğ. (2022) tarafından yapılan çalışmalarda öncelikli servis veren şarj istasyonunda kaynakları dinamik olarak atayan sırasıyla PI tabanlı geri beslemeli kontrol yöntemi ve simülasyon tabanlı kaynak kontrol yöntemi geliştirilmiştir. Kakillioglu ve diğ. (2022), tarafından yapılan çalışmada araçların talep ettikleri servis sürelerinin (şarj olma süresi) önceden kesin olarak bilindiği varsayılmıştır. Bu çalışmada ise servis sürelerinin bilinmediği durumda hedeflenen bekleme oranının elde edilmesi için Derin-Q Öğrenme tabanlı kontrol yöntemi kullanan gerçek zamanlı bir dinamik kaynak atama metodu geliştirilmiştir. Buna ek olarak çalışmanın ikinci adımında yer alan farklı öncelik sınıfından araçlar için bir ortalama bekleme süresi tahmini alanında daha önce hızlı şarj istasyonları için bu çalışma dışında başka bir çalışmada yapıldığına rastlanmamıştır. Ancak literatüre bakıldığında bekleme süresi tahminine dair, hastane acil servis departmanında hastaların bekleme süresi ve bankada müşteriler için bekleme süresi tahmini için, yapılan çalışmalar karşımıza çıkmıştır.

Tez, Bölüm 2’de literatür araştırması ile devam edecektir. Sonrasında Bölüm 3 ile ekspres şarj istasyonu yönetim sistemi ve bu tez kapsamında geliştirilen kontrol yöntemi ile karşılaştırmalarda kullanılan Fescioglu-Unver ve diğ. (2021) ve Kakillioglu ve diğ. (2022) çalışmalarında yer alınan kaynak yönetim metodları

anlatılmış birbirleriyle ve sabit sunuculu yöntemle olan farkları incelenmiştir. 5. Bölümde tez kapsamında geliştirilen RL-EXP modeli detaylı olarak anlatılmakta ve yönteme dair gerekli teorik açıklamalar verilmektedir. 6. Bölümde ise geliştirilen kaynak yönetim modeline ait sonuçlar ve bahsedilen çalışmalar ile performans karşılaştırmalarına yer verilmiştir. Tez çalışmasının ikinci kısmı olan farklı öncelik sınıfından araçların ortalama bekleme süresinin tahmini için geliştirilen modellere ait teorik bilgiler ve model geliştirilmesine ait detaylarla birlikte elde edilen tahmin sonuçları ise Bölüm 7’de verilmiştir. Son olarak 8. Bölümde tartışma ve gelecek çalışmalar anlatılmaktadır.





2. LİTERATÜR ARAŞTIRMASI

Araştırmacılar elektrikli araçlar benzinli ve dizel araçların yerini aldıkça hızlı şarj istasyonlarının sayısının da önemli ölçüde artacağına işaret etmektedir (Bryden ve diğ. 2018). Fakat kıyaslandığında benzinli ve dizel araçların depolarının dolma süresine kıyasla elektrikli araçların çok daha uzun şarj süresine ihtiyacı vardır. Bu şarj süreleri evde veya otoparklarda 6 ila 8 saat arasında iken hızlı şarj istasyonları sayesinde aracın şarj durumuna bağlı olarak 30 dakika civarındadır.

Elektrikli araçların sayısının artması ve buna paralel olarak şarj istasyonları sayısında gözlemlenecek artışla birlikte elektrikli araçların istasyonlardan aldığı şarj hizmetiyle alakalı çeşitli konularda yapılan çalışmalar hız kazanmıştır. Literatürde istasyonların lokasyonlarının ve kapasitelerinin belirlenmesi, araçların istasyonlara yönlendirilerek talep dağılımının dengelenmesi, istasyonda bekleme süresinin en aza indirgenmesi, istasyonda kuyrukta bekleme süresinin ve/veya kuyruk uzunluğunun düzenlenmesi ve istasyona giren araç sayısının bir eşik değerinde tutulması gibi hedefler göz önünde bulunduran çeşitli çalışmalar bulunmaktadır.

Literatürde elektrikli araçların şarj edilmek için kullanacağı elektriği en uygun yerden en şekilde almasıyla ilgilenen elektrikli araçların akıllı şebeke ağı içinde yönetimine dair çalışmalar, enerjinin verimli kullanılması, istasyon veya dağıtım ağının kârının gözetilmesi, fiyatlandırma ile talebin dengede tutulması, gibi konularda çeşitli çalışmalar karşımıza çıkmaktadır.

Bunlara ek olarak istasyonlarda sıklığına azaltılmasına dair yapılan çalışmalar da mevcuttur. Bu tür çalışmaların genel amacı müşteri memnuniyetini artırmak ve müşterinin sistemde geçirdiği toplam sürenin azaltılmasıdır. Bu kapsamdaki çalışmalarda, araçların şarj istasyonlarına yönlendirilmesi yöntemi kullanılır. Araçlar istasyonlara dağıtık veya merkezi bir sistem kullanılarak yönlendirilirler ve talebin dağılımını dengelerler. İstasyonlarda öncelikli şarj alanında yapılan çalışmalar ve diğer alanlarda sistemde bulunma veya bekleme süresini azaltmayı amaçlayan çalışmalar da sıklığına azaltılmasına yönelik incelenen çalışmalar arasındadır. Bu çalışmalar alt başlıklara ayrılarak incelenmiştir.

Çalışmanın ikinci kısmında, farklı öncelik sınıfına sahip araçların istasyonda ortalama bekleme sürelerinin tahminine ait literatürde elektrikli araçlar ve elektrikli araç şarj istasyonları alanında yapılmış bir çalışmaya rastlanmamıştır. Ancak hastane acilinde bekleme süresi, bankada bekleme süresi tahmini için, yapılan çalışmalar incelenmiştir.

Bu bölümde tezle ilgili literatür çalışmaları farklı alt bölümler altında incelenmektedir. İlk beş alt bölümde Elektrikli araç şarj istasyonu tasarım ve yönetim çalışmaları, son bölümde ise bekleme süresi tahmin çalışmaları ele alınmıştır. Öncelikli şarj alanında yapılan çalışmalar, Bölüm 2.5'te incelenmektedir.

2.1 Elektrikli Araçları Şarj İstasyonlarına Yönlendirerek İstasyonlar Arası Talep Dağılımını Düzenleyen Çalışmalar

Literatürde elektrikli araçların şarj olmayı bekleme süresini ve şarj olacakları istasyona ulaşmaları için geçen toplam yolculuk süresini azaltmaya yönelik pek çok çalışma mevcuttur. Bunlardan istasyonlar arasında talep dağılımını düzenleyen çalışmalar önemli yer tutar.

Anil ve diğ. (2020) yaptıkları çalışmada, Nesnelerin İnterneti (Internet of Things) konsepti tabanlı bir sistem geliştirmişlerdir. Bu sistemde birbiriyle iletişimde olan elektrikli araçlarda bulunan bir cihaz, bir sunucu ve istasyonlar için öncelik tahmincisi bulunmaktadır. İstasyon ve araç arasında bilgi alışverişine imkân vererek aracın istasyona yönlendirilmesini sağlayan sistemde, araçlardan alınan girdi sunucu sayesinde yakındaki istasyonlara iletilir ve istasyonlar öncelik listesi belirler. Yeni bir araç verisi alındığında öncelik listesi tekrar sıralanır. Belirlenen öncelik listesi istasyonun konumu ve kimliği ile birlikte araca geri iletilir. Bu entegre sistem, elektrikli araç kullanıcısına aracını şarj etmek için en uygun şarj istasyonuna karar verirken yardımcı olur ve istasyonların verimli şekilde kullanılmasını sağlar.

Moradipari ve Alizadeh (2019) merkezi rotalama ve fiyatlandırma mekanizmalarını birleştirerek farklılaştırılmış hizmet seviyelerine sahip araçlar sağlamayı amaçlamıştır. Kullanıcılar şarj olacakları istasyonu direkt seçmez, bunun yerine öncelik seviyesini seçer. Merkezi sistem olan şarj ağı operatörü ise bu kullanıcıları istasyonlara atar. Şarj ağı operatörü talepleri doğrudan yöneterek yüksek öncelikli kullanıcıları istasyonda daha az bekletmeyi amaçlar.

Tan ve Wang, (2017), güç sistemi ve ulaşım sisteminin istasyona etkilerini göz önünde bulunduracak şekilde şarj navigasyon çerçevesi sunmaktadır. Elektrikli araçların yoğun olmayan saatlerde şarj edilmesini sağlayarak ve gerçek zamanlı yönlendirme ile araç sahiplerinin zamandan tasarruf etmesini sağlayarak hem güç hem ulaşım sistemine fayda sağlanır. Araçların istasyonlara etkin şekilde yönlendirilmesi için hiyerarşik oyun yöntemi kullanılmıştır. Simülasyon sonuçları geliştirilen entegre istasyona yönlendirme yaklaşımının hem güç dağıtım ağının güvenilirliğini artırdığını hem de istasyona ekonomik kar sağladığını göstermektedir.

Bireysel elektrikli araçların şarj yönetimini ele alan çalışmalardan farklı olarak kamusal şehir içi elektrikli taksi sistemine ait bir çalışma Zhang ve diğ. (2020) tarafından yapılmıştır. Önerilen metot sayesinde, elektrikli taksilerin talebinin ne kadar acil olduğuna bağlı olarak zamanla değişen gereksinimler göz önünde bulundurularak uygun şarj istasyonlarına yönlendirilmektedir. Batarya şarj etme veya batarya değişimi kararlarında amaç taksilerin müşteriye yapacakları yolculuk süresindeki gecikmeyi minimize etmektir.

Kim ve Kim (2021) yaptıkları çalışmada elektrikli araç şarj talebi tahmini için geçmiş verinin kullanıldığı zaman serisi modellerine başvurmuşlardır. Çalışmada karma otoregresif hareketli ortalama, otoregresif hareketli ortalama, yapay sinir ağları ve LSTM yöntemleri birbiriyle kıyaslanmıştır. Çalışmada ayrıca LSTM yönteminde tarihsel veriye ek olarak çevresel değişkenler de modele katılmış ve diğer modellerle kıyaslamada bu değişkenlerin etkisi gözlemlenmiştir.

Rahmani-Andebili ve diğ. (2018) yaptığı çalışmada elektrikli araçların park yeri atama planlama ve operasyonu üzerine çalışmıştır. Çalışmada sürücülerin davranışsal modelleri, park yerlerine uzaklıkları gibi faktörler dikkate alınmıştır.

Abd Eldjalil ve Lyes (2017) bu makalede akıllı şebekenin, şarj bekleme süresini en aza indirmeyi ve şebeke istikrarını koruma amacıyla istasyonlar arasında şarj ve deşarj gücünü dengelemeyi hedeflemiştir. Bunu başarmak için araç kullanıcılarının bulut sağlayıcıları ile şarj-deşarj takvimlerini iletmek üzere iletişim kurdukları bir bulut bilişim çerçevesine dayalı bir şarj-deşarj modeli geliştirilmiştir. Geliştirilen modelde araçların taleplerini idare etmek için 2 araç öncelik sınıfının ele alındığı kuyruk teorisi tabanlı bir matematiksel model geliştirilmiştir. Geliştirilen yaklaşımın performansı simülasyon ile ölçülmüştür.

Eddine ve Shen (2022) yaptıkları çalışmada elektrikli araç şarj enerjisi talebinin tahmini için Temporal Kodlayıcı-Kodçözücü Uzun Kısa Süreli Bellek yöntemini kullanmışlardır. Gerçek hayat verisi kullanmışlardır ve istasyonun konumu ve şarj servisi ile ilgili şarj tüketimi, servis günü, saati, tatil olup olmadığı vb. bilgileri kullanmışlardır.

Zhu ve diğ. (2019) derin öğrenme tabanlı Yapay Sinir Ağları ve Uzun Kısa Süreli Bellek modellerini elektrikli araç şarj yük tahmini için uzun ve kısa vadeli tahminde kullanmış ve kıyaslamışlardır. Girdi olarak tarihsel şarj yük verisi kullanılmıştır. Sonuç olarak LSTM'nin daha iyi performans gösterdiği görülmüştür.

Vardakas (2014), akıllı şebeke ortamında hızlı şarj istasyonu ağı için bir elektrikli araç şarj yönetim modeli sunmaktadır. Önerilen model, birden fazla elektrikli araç şarj sınıfına hizmet veren bir istasyon ağını dikkate almaktadır. Modelde elektrikli araçların tercih ettiği istasyondan hizmet alamaması durumunda bir iletişim sistemi aracılığıyla sabit veya esnek şarj hizmetleri sağlayan bir sonraki istasyonu seçmeleri istenir. Çalışmada yapılan analizler kullanılarak bir alana kurulacak olan istasyon sayısının belirlenmesinde kullanılabilir.

Mukherjee ve Gupta, (2015), derleme çalışmasında akıllı şebekede elektrikli araçların şarj çizelgeleme algoritmalarına ait yapılan çalışmaları ele almaktadır. Derlenen çalışmalar önce tek yönlü ve çift yönlü şarj olarak sınıflandırılmış, sonra her iki sınıf çizelgelemenin merkezi mi dağıtık mı olduğuna ve herhangi bir hareketlilik yönünün dikkate alınıp alınmadığına göre sınıflandırılmıştır.

Said ve diğ. (2015) çalışmasında istasyonlarda bekleme süresi minimize edilirken şebeke gücünün dengelenmesine yönelik iki model geliştirilmiştir. Çalışmada araçlar istasyonlara varışlarından önce şarj talebi ve konumlarının önceden bildirir. İlk modelde kuyruk teorisini temel alan bir matematiksel model geliştirilmiş. İkinci modelde ise ilk model yüksek ve düşük öncelikli araç sınıfı ve hizmet kesme politikası dahil edilerek genişletilmiştir. Araçların istasyona yönlendirilmesine yönelik geliştirilen iki algoritma şarj tamamlanma süresi veya bekleme süresini en aza indirecek şekilde tasarlanmıştır.

Gusrialdi ve diğ. (2017), çift yönlü bir otoyol boyunca trafik akışları ve otoyoldaki istasyonların durumu hakkında yalnızca yerel bilgilerle şarj istasyonları arasındaki kuyrukları koordine etmek için bir strateji geliştirmeyi amaçlamaktadır, böylece uzun

bekleme sürelerinden kaçınılabılır. Özellikle, elektrikli araç akışlarını komşu şarj istasyonlarına planlamak için dağıtılmış bir algoritma sunulmuştur, Böylece elektrikli araçların hepsine otoyol boyunca uygun şekilde hizmet verilir ve tüm şarj kaynakları eşit şekilde kullanılır. Buna ek olarak, herhangi bir şarj istasyonuna giren toplam elektrikli araç sayısını dengeli bir seviyede tutması amaçlanarak aracın o istasyona girip girmeyeceğine yönelik bir karar verme politikası geliştirilmiştir.

Zhang ve diğ. (2018) tarafından ilk olarak çift modlu bir istasyonun çalışması birden fazla sunucuya ve heterojen servis hızına sahip bir kuyruk ağı olarak formüle edilmiştir. Ve istasyonun servis bırakma oranı ve elektrikli araçların seçimleri arasındaki ilişki analiz edilmiştir. Sonrasında istasyonu şarj olmadan terk eden elektrikli araçların sayısını minimize etmeye yönelik müşteri kaybı minimizasyonu problemi formüle edilmiş ve istasyondaki araçları yönlendirmek ve şarj süreçlerini koordine etmek için optimal fiyatlandırma sunulmuştur.

Qin ve Zhang, (2011) tarafından yapılan şarj olma aktivitelerinin ne zaman ve hangi istasyonda gerçekleşmesi gerektiğini çizelgeleyen çalışmada elektrikli araçların bekleme süresinin minimize edilmesi hedeflenmiştir. Araçlar konumu, hızı, şarj durumu, hedefi hakkında bilgiyi istasyonlarla paylaşmaktadır. İstasyon, bir araç kendisine varış yaparsa beklemesi gereken süreyi hesaplarken şu bilgilere dikkat eder: şu anda şarj olmakta olan araç sayısı ve şarjın süresi, şarj için şu anda beklemekte olan araçlar ve şarj süreleri ve istasyona gelmek için yapılan rezervasyonlar. Çalışmada, bekleme süresi minimize edilmiş şarj çizelgeleme problemini formüle etmek ve şarj olmayı bekleme süresinin teorik alt sınır değerinin elde edilmesi için teorik bir çalışma yapılmıştır. Simülasyon sonuçlarına göre, önerilen yöntem ile bekleme süresinin teorik alt sınır değerinin elde edilebileceği doğrulanabilmiştir.

Yang ve diğ. (2013) çalışmalarında iki tip şarj istasyonu seçim algoritması geliştirmiştir. İlkinde, elektrikli aracın sadece yerel bilgisi kullanılmaktadır. İkinci algoritmada ise elektrikli araç ve mobil telekomünikasyon ağı sunucusu arasındaki etkileşim doğrultusunda elde edilen küresel bilgisi kullanılmaktadır. Geliştirilen yöntemde, istasyona gelen araç talep ettiği şarj miktarını bildirir. Sistem tarafından araç şarj istasyonuna yaklaştığı anda veya bir sonraki şarj olacağı istasyon seçimi için bir bekleme süresi hesap etmekte ve en az bekleyeceği istasyonu seçebilme imkânı vermektedir.

Cao ve diğ. (2015) tarafından geliştirilen yöntemde her istasyon kendisiyle ilgili konumu, şarj hızı, kuyrukta bekleme süresi gibi bilgileri her 100 saniyede bir dinleyenlere ilan eder. Dinleme üniteleri, bu istasyonlardan dinledikleri bilgileri araçlara iletir. Araç şarj olmak istediği istasyonu seçer, istasyona varış yapması beklenen zamanı ve şarj süresi talebini iletir. İstasyonlar, bekleme süresini anlık kuyruk durumuna bakarak hesaplar. Araçlar ise istasyon seçerken bildirilen bu bekleme süresini ve istasyona kendinden önce varış yapacak araçların rezervasyonlarının en az bekleyeceği şekilde yapar.

De Weerd ve diğ. (2013), çalışmasında özellikle en yoğun saatlerde meydana gelen uzun bekleme sürelerinin çözümünü ele almıştır. Çalışmada, yönlendirme politikalarını diğer sürücülere ileten bir navigasyon sistemi önerilmiştir. Bu yönlendirmeler kullanılarak sistem şarj istasyonlarındaki sıklığı belirleyerek kullanıcıya en verimli rotayı önerir. Ayrıca şarj istasyonlarındaki kuyruk durumunu belirlemek için tarihsel verileri ajan politikalarıyla birleştiren yeni bir teknik tanımlanmıştır.

Malandrino ve diğ. (2015), Akıllı Ulaşım Sistemi (Intelligent Transportation System) aracılığı ile elektrikli araç sürücülerine şarj istasyonu önerilmesi hedeflemiştir. Çalışmada, problem oyun teorisi ile modellenmiştir. Sürücülerden mevcut konum, hedef bilgisi ve şarj talepleri toplanarak Nash-dengesine uygun istasyon önerisi sürücülere gönderilmektedir. İstasyon önerisinde mevcut konumdan hedef konuma ulaşırken geçen süre ve şarj talebi için ödenecek ücret göz önünde bulundurulmaktadır.

Gharbaoui ve diğ. (2012) bu makale, elektrik altyapısının verimliliğini optimize ederken elektrikli araç şarj sürelerini en aza indirmek amacıyla dağıtılmış enerji kaynaklarının akıllıca kullanılmasını sağlayacak bir öneri sunmaktadır. Benimsenen yöntemde, araçlar sisteme konumları ve şarj taleplerini bildirmekte, istasyonlar ise tahmini bekleme süresi hesaplamaktadır. Bu hesap yapılırken, aracın bilgiyi talep ettiği andaki bekleme süresi ve aracın şarj süresi kullanılmakta, aracın istasyona varacağı ana kadar geçecek süre içerisinde istasyona gelecek diğer araçların sebep olacağı bekleme süresindeki değişiklikler göz önünde bulundurulmamaktadır.

Zhang ve diğ. (2017) makalesinde gerçek zamanlı bir akıllı şarj algoritması önermiştir. Önerilen yaklaşımda en yüksek talebi azaltabilen ve takılı elektrikli

araçların verilerine dayalı araçlara öncelik verebilen gerçek zamanlı bir su doldurma algoritması (water-filling algoritması) uygulanmaktadır

Guo ve diğ. (2014), elektrikli araçların özellikle yoğun saatlerde güç sistemlerini etkileyebileceği ve trafik koşulları değiştikçe bu etkilerin farklı konumlarda ortaya çıkabileceğine değinilmiştir. Bu sorunları ele almak için, çalışmada hem trafik koşullarını hem de elektrik şebekesinin durumunu dikkate alan entegre bir hızlı şarj navigasyon stratejisi tanımlanmıştır. İstasyonlar kendileriyle alakalı merkezi sisteme bilgi gönderir ve araca toplam yolculuk süresini en aza indirgeyen rota hesaplanıp önerilmektedir. Çalışmada şarj istasyonlarının şarj güçlerinin güç ağını dengelemek için değiştirebildiği varsayılmıştır.

Tian ve diğ. (2016) mevcut durumda elektrikli taksilerin sezgisel olarak şarj olacakları istasyonu seçtiği durumların verilerine kıyasla bekleme süresini azaltacak elektrikli taksiler için bekleme süresini azaltacak en doğru istasyonu önerme sistemi geliştirilmiştir. Her taksinin anlık konum verileri ve geçmiş şarj olma verileri kullanarak taksi istasyon önerisi istediğinde gerçek zamanlı olarak minimum bekleme süresine dayalı istasyon önerisi yapılmaktadır.

Bayram ve diğ. (2013) tarafından ele alınan çalışmada ilk olarak tek bir şarj istasyonu için fiyatlandırmaya dayalı bir kabul kontrol mekanizması önerilmiştir. Daha sonra, bir oyun teorisi modeli kullanarak elektrikli araç sürücüleri için merkezi olmayan bir yönlendirme şeması geliştirilmiştir. Araç sürücülerinin istasyona yönlendirilmesinde fiyat teşvikleri yoluyla daha az yoğun istasyonlara yönlendirilmesi gözetilmiştir, böylece ağ genelinde gücün daha verimli kullanılmasına yol açarken, istasyonların kârı artırılabilir.

Cao ve diğ. (2016) araç hareketliliği belirsizliklerini ve araçların yolculuk süresini dikkate alan merkezi sistem tarafından yönetilen bir rezervasyon güncelleme şeması önermiştir. Önerilen şemada araçların planladıkları rezervasyon zamanına hareketlilik belirsizliklerinden dolayı yetişememesi durumunda, periyod rezervasyon güncellemesine imkân sunulmaktadır. Yapılan Helsinki gerçekçi durum senaryosunda, önerilen şarj planlama yönetimi şemasıyla araçların seyahat sürelerinin minimize edildiği ve hem istasyon hem araç yönünden şarj performanslarının iyi olduğu gözlemlenmiştir.

Son teknoloji elektrikli araç şarj yönetim şemaları ve hızlı şarj hizmetini etkinleştirmek için batarya anahtarı (battery switch) teknolojisi hakkında inceleme sunan bir çalışma Cao ve diğ. (2017) tarafından yapılmıştır. Sonrasında trafik yoğunluğu, sürücü tercihleri gibi seyahat belirsizliklerini göz önünde bulunduran tamamen dağıtık bir şarj yönetim şeması geliştirilmiştir. Sonuçlar yorumlandığında sürücü seyahat süreleri ve şarj bekleme sürelerinde iyileşmeler olduğu gözlemlenmiştir.

Cao ve diğ. (2019), ön ödemeli ve araçlar arası iletişim (V2V) tabanlı bir rezervasyon sistemi sunmaktadır. Çalışmada yüksek önceliğe ve düşük öncelikli araçların mevcut olduğu belirtilmiştir. Şemada şarj bekleme süresi minimize edilmesi amaçlanmıştır. Rezervasyon için varış zamanı ve talep edilen şarj süresi bilgileri istenmiştir. Geliştirilen şemanın düşük iletişim maliyetlerine kıyasla yüksek şarj yönetim performansına sahip olduğu gözlemlenmiştir.

2.2 Şarj İstasyonlarının Konumlandırılması ve Boyutlandırılması Konusundaki Çalışmalar

Şarj istasyonlarının nereye konumlandırılacağı ve kapasitesinin ne olacağı, elektrikli araçlara daha ulaşılabilir ve kaliteli hizmet vermek ve istasyondaki yoğunluğu yönetebilmek açısından önemlidir.

Yang ve diğ. (2018) yaptıkları çalışmada hızlı şarj istasyonlarında şarj cihazı ve bekleme alanı kapasitelerinin planlanmasına değinmektedir. Şarj olma talebinin doğru tahminin önemli yere sahip olduğu söylenmiş ve bu çalışmada da araç yolculuk davranış analizi ile şarj talebi belirlenmiştir. Şarj istasyonundaki araç dinamikleri bir Markov zinciri ve kuyruk teorisi ile modellenmiştir. Sonuç olarak, hızlı şarj istasyonlarındaki optimal şarj cihazı ve bekleme alanı sayısı, şarj hizmetinin kârı, bekleme ve reddetmenin ceza maliyeti yanı sıra tesislerin bakım maliyeti de dikkate alınarak operatör kârının beklenen değerini maksimize edecek şekilde ortak olarak belirleyebilecekleri belirtilmiştir.

İstasyon yer seçim problemi ve istasyon kapasitesi problemini aynı anda yavaş şarj istasyonu açısından Lu ve Hua (2015) tarafından yapılan çalışma örnek verilebilir. Çalışmada kuyruk teorisi baz alınmış ve bir müşterinin kabul edeceği en büyük bekleme süresi koşulu altında konum boyutlandırma modeli yeniden formüle

edilmiştir. Modelde şarj noktaları bu bekleme sürelerini aşmadan tahsis edilir ve aynı zamanda toplam şarj edilen araç akışı maksimize edilir.

Başka bir şarj istasyonu yer seçim problemi Hosseini ve Sarder (2019) tarafından ele alınmıştır. Probleme farklı olarak sadece sayısal faktörler değil niteliksel faktörler de ele alınmış ve risk değerlendirmesi ile belirsizlik altında karar vermede güçlü bir yöntem olan. Bayes Ağı modeli geliştirilmiştir.

Hosseini ve MirHassani (2015) kapasite, şarj dolun süresi ve bekleme süresinin dikkate alındığı şarj istasyonu yer seçim problemi üzerinde çalışmıştır. Sunulan model bir küme kapsama problemidir ve sezgisel bir algoritma ile çözüm geliştirilmiştir. Algoritma farklı koşullar altında iki ağda değerlendirilmiştir.

Öngörülemeyen, zamanla değişen yükün neden olduğu veri merkezlerinde ihtiyaç duyulan sunucu sayısını büyük ölçüde azaltan ve aynı zamanda hizmet seviyesi anlaşması ile söz verilen yanıt süresi karşılayan dinamik bir kapasite yönetimi politikası önerilmiştir (Ghandi ve diğ. (2012)). Önerilen yöntemde veri merkezi kapasitesi sunucu ekleme veya çıkartma ile ayarlanmaktadır. Ayrıca sistemde olağanüstü talep oranı artışıyla yaşanacak çökmeye karşı yeterli miktarda yedek kapasite barındırılmaktadır. Yöntemin yanıt sürelerini hızlandırdığı ve güç tüketimini azalttığı çıkarımı yapılmıştır.

Jung ve diğ. (2014) şarj istasyonu yer seçim problemini ele almıştır. Geliştirilen çerçevede ilk katmanda kuyruk gecikmeli çoklu-sunucu dağıtım modeli geliştirilmiştir. İkinci katmanda ise simülasyon tabanlı sevkiyat modeli geliştirilmiştir.

Karasan ve diğ. (2018) istasyon yer seçimi problemini çok kriterli karar verme problemi olarak ele almıştır. Yer seçiminde en sürdürülebilir konumu seçmek bazı çelişen kriterleri barındırmakta. Yer seçiminde bu kriterlerin dahil edilmesiyle karar verme metodolojisinde sezgisel bulanık kümeler kullanılmıştır.

Xiao ve diğ. (2020) kuyruk davranışlarını gözeten elektrikli araç altyapı yer seçim ve kapasite belirleme problemi üzerine bir çalışma yapmıştır. Çalışmada optimal lokasyonlar, istasyonda izin verilen maksimum kuyruk uzunluğu ve maksimum kapasiteyi belirleyecek optimizasyon problemi çözülmüştür.

Xiong ve diğ. (2017) hızlı şarj istasyonlarının yer seçimi problemine oyun teorisi çerçevesi ile yaklaşmıştır. Problem iki seviyeli optimizasyon problemi olarak modellenmiştir.

Elektrikli araç şarj altyapılarının planlanması ele alınan başka bir çalışma da Guo ve diğ. (2018) tarafından yapılmıştır. Çalışmada benzer çalışmalardan farklı olarak planlanan bölgedeki benzin istasyonlarının satış hacmi, yük kestirimi, ekonomik analiz gibi kriterler göz önüne alınmıştır.

Zhu ve diğ. (2017) çalışmasında, elektrikli araçların şarj gereksinimini, ekonomisini ve elektrik şebekesini dikkate alan bir model önermektedir. İlk önce istasyonun lokasyonu belirlenmiş, sonra istasyon kapasitesi minimum maliyet amaç fonksiyonu ve araç kullanıcılarının bekleme süresine karşı limit ve dağıtım şebekesinin güvenli çalışması kısıtları ile optimize edilmiştir. Son olarak istasyonun hizmet alanı Voronoi diyagramı ile bölümlenmiştir.

2.3 Şarj istasyonlarındaki Elektrikli Akıllı Şebeke Aracılığı ile Yönetilmesi ve Maliyet Minimizasyon Çalışmaları

Elektrikli araç şarj istasyonlarında, elektrikli araç ve akıllı şebeke arasındaki koordinasyonun sağlanması, gücün/enerjinin yönetilmesi, fiyatlandırma çalışmaları ve maliyetlerin azaltılması çalışmalarına literatürde sıklıkla rastlanmaktadır

Chung ve diğ. (2018) çalışmasında merkezi bir sistemle kontrol edilen bir dizi şarj istasyonunu ele almaktadır. İstasyon maliyetlerinin en küçüklenmesi ve araç kullanıcılarının mümkün olan en kısa süre içinde tamamen şarj olması amacı güdülen iki amaçlı optimizasyon problemi modellenmiştir. Çevrimiçi bir merkezi çizelgeleme algoritması önerilmiş ve Pareto-optimal çözüm elde edildiği kanıtlanmıştır. Algoritmalar simülasyon ile değerlendirilmiş ve literatürdeki çalışmalara göre şarj bekleme süresini yüzde 30 azalttığı gözlemlenmiştir.

Desaulniers ve diğ. (2016), yaptıkları çalışmada zaman pencereli elektrikli araç rotalama problemini ele almıştır. Her rotada sadece bir kez istasyona uğrayarak tamamen veya kısmi şarj olma ve her rotada birden fazla kez tamamen veya kısmi şarj olabilme olmak üzere 4 çeşit durum ele alınmıştır. Problem çözümü için kesin çözüm algoritmaları geliştirmiş ve örneklemeler üzerinde çözdürülmüştür. Sonuç olarak rotada birden fazla kez kısmi olarak şarj olmaya izin vermenin tek seferlik tam

doluma göre rotalama maliyetlerini ve filodaki araç sayısını azalttığı gözlemlenmiştir.

Chen ve diğ. (2019) çalışmasında elektrikli araç yükü ve şebeke koordinasyonundaki zorluk bağlamında optimal elektrikli araç şarjını planlamak için kullanıcının şarj seçimini dikkate alan çok amaçlı bir çizelgeleme problemini ele almıştır. Çalışmada araçların şarj olma maliyetini ve şebekenin yük varyansını etkileyecek üç tip kullanıcı şarj seçimi dikkate alınmıştır. Amaç beklenen çizelgeleme ile gerçekleşen çizelgeleme arasındaki çizelgeleme sapmasını azaltmak amacıyla, elektrikli araç şarj modunu belirlemek için kullanıcının şarj seçimini dikkate alan ekonomik bir elektrikli araç çizelgeleme yöntemi geliştirmektir.

Bolloor ve diğ. (2011) çalışmasında, performans ölçümlerinin bir parçası olarak yanıt sürelerinin yüzdelik dilimlerini içeren Hizmet Seviyesi Anlaşmaları (HSA) ele alınmıştır. Bulut servis sağlayıcılarına eğer anlaşma hedeflerine ulaşılmadıysa bir ceza yansıtılmaktadır. Çalışmada bu tip HSA'ları dikkate almanın temel motivasyonu, fiyat farklılaştırma potansiyelleridir. Ceza fonksiyonunun elde edilen yanıt süresi yüzdelik dilimleri üzerindeki etkilerine dair analiz yapılmış ve analiz NP-zor olduğundan dolayı bir sezgisel algoritma geliştirilmiştir. Sonuç olarak doğrusal ceza fonksiyonunun elde edilen yanıt süresi yüzdelik dilimlerini maksimize etmesi anlamında en iyi olduğu görülmüştür.

Birden fazla sunucuya sahip bir şarj istasyonunda elektrikli araçların optimal çizelgelemesi Zhang ve diğ. (2013) çalışmasında ele alınmıştır. Araçların varışlarındaki belirsizlik, enerjideki kesintiler ve şebeke güç fiyatındaki değişimler göz önünde bulundurulmuş ve her biri bağımsız olarak Markov süreçleri olarak tanımlanmıştır. Amaç maliyet üzerindeki uzun vadeli kısıtlama altında araçlar için ortalama bekleme süresini minimize etmektir. Kısıtlamalı stokastik optimizasyon problemi olarak ele alınan problemin araştırılmasında bir Markov Karar Süreci çerçevesi önerilmiştir. MKS'de sistem durumu değişkenleri olarak şarj kuyruğu uzunluğu, şebeke güç fiyatı, istasyon enerji batarya deposundaki enerji seviyesi, şarj talebinin varışı dikkate alınmıştır.

Akhavan-Rezai ve diğ. (2014) yaptıkları çalışmada koordineli şarj çizelgelemesinin gerçek zamanlı yönetimi için bir metot sunmuştur. Metot araçlara skor atama ve bulanık uzman sistem kullanılarak araçların önceliklendirilmesine dayalıdır.

Sistemsel ve operasyonel kısıtları ihlal etmeksizin elektrikli araçların kullanıcı memnuniyetinin maksimize edildiği optimal araç şarj planlaması çözümler bulunması amaçlanmaktadır.

Su ve diğ. (2017) elektrikli araç kullanıcıları açısından batarya kapasitesinde bozunumun, elektrik maliyetinin ve bekleme süresinin azaltılmasına yönelik olacak şekilde bir şarj planlama yöntemini ele almıştır. Yöntemin değerlendirilmesi için yapılan simülasyon sonucu yoğun istasyonlarda bekleme sürelerini %60, bozunum maliyetinin ise %80 azaldığı görülmüştür.

Xu ve diğ. (2016) çalışmasında toplam maliyeti minimize edecek şekilde bir araç şarj çizelgesi oluşturmaya çalışmaktadır. Çalışmada toplam şarj maliyeti ve talep edilen son tarihten önce şarjın tamamlanmamasına ilişkin ceza maliyeti göz önünde bulundurulmuştur. Yaklaşımında dinamik programlama formülasyonu ile bir algoritma geliştirilmiştir ve çeşitli sezgisel çizelgeleme algoritmalarıyla kıyaslanmıştır.

Qian ve diğ. (2019) toplam seyahat süresinin ve şarj olma maliyetinin minimize etmenin amaçlandığı derin pekiştirmeli öğrenme tabanlı elektrikli araç şarj yönlendirme metodu sunmuştur. Aracın ve istasyonların konumu, batarya şarj durumu, aracın hızı, şarj ücreti ve bekleme süresi/maliyeti gibi durumlar göz önüne alınmıştır.

Kumar ve Tseng (2016) elektrikli araçların şarj operasyonlarının güç sistemlerine entegre edilmesinde zaman tabanlı koordinasyon ve güç tabanlı koordinasyon stratejisi ele alınmış ve enerji verimliliği kıyaslanmıştır.

Elektrikli araç taleplerinin, hızlı şarj istasyonlarının servis yeterliliklerinin ve istasyonların günlük yük dalgalanmalarının göz önünde bulundurulduğu hiyerarşik güç kontrol stratejisi Niu ve diğ. (2018) tarafından önerilmiştir. Göz önünde bulundurulan talep, servis yeterliliği ve istasyon yük dalgalanmaları bir bütün olarak ağırlıklandırılmış dinamik öncelik katsayısı ve dalgalanma azaltıcı endeksi olarak ele alınmıştır.

Said ve diğ. (2019) makalesinde elektrikli araç ve şebeke arasındaki çift yönlü güç akışı incelenmiştir. Elektrikli araçların şarj ve deşarj çizelgelemesine yönelik her bir aracın hizmet alması gereken zaman, konum ve güç talebi dikkate alınarak bir yoğun yük yönetim modeli (peak load management) geliştirilmiştir. Elektrikli araç

şarj/deşarj talep çizelgelemesi için kuyruk teorisini baz alan matematiksel formülasyon geliştirilmiştir.

İstasyonların kârını artırmak için elektrikli araçların şarj davranışını yönlendirmek Li ve diğ. (2022) tarafından yapılan çalışmanın ana konusudur. Çalışmada önceikle LSTM kullanılarak şarj yükü kestirimi yapılmış ve Model Öngörülü Kontrol yöntemi ile birleştirilerek iki aşamalı enerji çizelgeleme formülasyonu yapılmıştır. Elektrikli araçların şarj davranışının yönlendirilmesi istasyondaki servis fiyatlandırmasının değiştirilmesiyle sağlanmıştır.

Aljafari ve diğ. (2023) şarj istasyonlarının en az bekleme süresi ve düşük müşteri elektrik fiyatlarıyla yönetilmesinin elektrikli araçların yaygınlaşmasındaki zorluklardan biri olduğunu belirtmiştir. Çalışmada batarya enerji yönetimi faktörlerinden batarya kapasitesi, ayrılış vakti, direksiyon süresi gibi faktörlerin dikkate alınmasıyla optimum şarj/deşarj çizelgeleme şemasının dinamik fiyatlandırma ile formüle edilebilmiştir. Problem bir Markov karar süreci tanımlanmış ve Çoklu Ajan Derin Sinir Ağı yöntemi çözüm için kullanılmıştır.

Nair ve Prabha (2022) Çalışmada dinamik fiyatlandırma ile öncelik tabanlı optimal şarj çizelgesi modeli geliştirilmiştir. İstasyonda, hızlı, orta hızda veya yavaş modda şarj olan üç öncelik sınıfı olduğu varsayılmıştır. Çalışmada toplam şarj olma maliyetini en aza indirmeye yönelik, modifiye edilmiş Tulumlular Sürü Algoritması (Tunicate Swarm Algorithm) tabanlı bir şarj çizelgeleme modeli kurulmuştur.

Keskin ve Çatay (2018) zaman pencereli elektrikli araç rotalama problemini ele almıştır. Rotalama probleminde rota üzerinde araçların şarj olmaya ihtiyaç duyduğunda normal, hızlı, ekspres şarj olmak üzere üç tip hizmet alabilmektedir. Amaç en az sayıda araç ile toplam şarj olma maliyetini en aza indirmektir. Bunun için adaptif büyük komşuluk arama yaklaşımı geliştirilmiştir.

2.4 Pekiştirmeli Öğrenme Yaklaşımını Elektrikli Araç Şarj İstasyonu Alanında Kullanan Çalışmalar

Tez kapsamında çözüm yöntemi olarak benimsenen pekiştirmeli öğrenme yaklaşımı literatürde elektrikli araç şarj yönetimi alanında pek çok farklı amaç için kullanıldığı görülmüştür. Aşağıda yer alan çalışmalarda bu yaklaşımın hangi problemlerin çözümü için kullanıldığı incelenmiştir.

Dang ve diğ. (2019) çok boyutlu elektrikli araç şarj çizelgeleme problemine yönelik çözüm yöntemi olarak Q-Öğrenme algoritması kullanmışlardır. Kullanım süresi fiyatlandırması, şarj esnekliği ve araçların Araçtan Şebekeye (V2G) kapasitesi göz önünde bulundurulmuştur. Çalışmada araç ve şebeke arasındaki çift yönlü güç akışı dikkate alınmıştır.

Silva ve diğ. (2019) bu çalışmalarında elektrikli araçların yeniden şarj olma maliyetlerini en aza indirirken trafoları aşırı yüklenmesini önleyecek bir Çok Ajanlı Sistem mimarisi önermişlerdir. Bu mimari, Çok Ajanlı Pekiştirmeli Öğrenmeye dayalıdır. Önerilen yöntemin koordineli şarj problemi çözümünde etkin bir “de performans gösterdiği deneylerle desteklenmiştir.

Blum ve diğ. (2019) sürücülere şarj istasyonu önerme problemi üzerinde bir çalışma yapmışlardır. Çalışmada yöntem olarak Q-Öğrenme kullanılmıştır. İstasyon konumu, istasyon şarj cihazlarının uygunluk durumu, sürücünün şarj olma isteğini gönderdiği konum ve zamanı ile ilgili bilgiler dikkate alınmıştır. Ve kullanıcıya yolculuk süresini ve istasyonda şarj olana kadar geçen sürenin en aza indirecek şekilde öneri yapılması gözetilmiştir.

Zhang ve diğ. (2020) şarj çizelgeleme problemi ve gerçek istasyon verilerine dayalı elektrikli araçlara şarj rotası önermek için Derin Q-Öğrenme tabanlı bir yaklaşım sunulmuştur. Yolculuk mesafesi sınırlamaları, lokasyon ve kullanıcı şarj istekleri ve çeşitli şarj hızı kısıtları gibi faktörler dikkate alınmıştır. Şarj dolumu bitiş süresi ve kullanıcı yolculuk süresini dikkate alan esnek bir ödül fonksiyonu kullanılmıştır ve yaklaşım gerçek istasyon verisi ile test edilmiştir.

Li ve diğ. (2021) tarafından yapılan çalışmada şarj çizelgeleme problemi için Derin Pekiştirmeli Öğrenme tabanlı bir metot geliştirilmiştir. Geliştirilen metot sayesinde şarj stratejisi elektrik fiyatına göre kullanıcının şarj olma maliyetini ayarlayacak şekilde ayarlanabilmektedir.

Wan ve diğ. (2018) araç şarj çizelgeleme problemini bir Markov Karar Süreci olarak formüle etmiştir. Optimal şarj stratejisini belirleyebilmek için de problemi model tabanlı olmayan derin pekiştirmeli öğrenme tabanlı bir yaklaşım ile çözmüştür. Yaklaşım geçiş olasılıklarını adaptif olarak öğrenmektedir ve herhangi bir sistem modeli bilgisine ihtiyaç duymamaktadır.

Qian ve diğ. (2021) çalışmasında çoklu ajanlı derin pekiştirmeli öğrenme metodu kullanılarak şehir içi elektrikli araç ulaşım ağında tek bir şarj istasyonu için optimal şarj fiyatlandırmasının belirlenmesi için fiyatlandırma oyunu modellenmiştir. Önce şarj istasyonu talepleri, esnek seyahat talepleri e farklı şarj fiyatları altında kullanıcı dengeli trafik atama problemi (UE-TAP) ile analiz edilmiştir. Sonrasında fiyat rekabet problemi belirsiz market ortamında bir oyun olarak formüle edilmiştir. Çoklu ajanlı derin pekiştirmeli öğrenme yaklaşımı ile şarj fiyatlandırma stratejilerinin öğrenilmesi ve fiyatlandırma oyununun Nash dengesine yaklaşması beklenmektedir.

Wang ve diğ. (2019) makalesinde istasyonda şarj fiyatlandırması ve şarj çizelgelemesi problemi için pekiştirmeli öğrenme yaklaşımı kullanılmıştır. Aracın istasyona geldiği an, kalan şarj talebi gibi durumlar göz önünde bulundurulmuş ve şarj olma fiyatı, her araç için şarj hızına karar verilmiştir. Modelde kullanılan ödül fonksiyonu ise istasyonun toplam kârı olarak belirlenmiştir.

Dabbaghjamesh ve diğ. (2020) yaptıkları çalışmada elektrikli araç şarj istasyonu yük kestirimi için Yapay Sinir Ağı ve Yinelemeli Sinir Ağı tabanlı Q-Öğrenme tekniği kullanmışlardır. 3 farklı şarj senaryosu (akıllı, koordineli, koordinesiz) için yöntem test edilmiştir.

Zhang ve diğ. (2021) çalışmasında derin pekiştirmeli öğrenme tabanlı her istasyonun bireysel bir ajan olarak tanımlandığı bir istasyon öneri çerçevesi sunmuşlardır. Problem bir Çok Amaçlı Çoklu Ajanla Pekiştirmeli Öğrenme görevi olarak formüle edilmiştir. Amaç aynı anda, şarj olmayı bekleme süresinin, şarj olma ücretinin ve şarj başarısızlık oranının minimize edilmesi olarak belirlenmiştir. Simülasyon ile yöntemin etkinliği test edilmiştir.

Elektrikli araçların stokastik davranışlarından dolayı uygun olmayan şarj stratejileri sonucunda bir bölgedeki voltaj güvenliği ihlal edilebilir. Bu sebeple, Ding ve diğ. (2020) tarafından yapılan çalışmada bir dağıtım ağında dağıtım sistemi operatörünün kârını maksimize etmek amacıyla Pekiştirmeli öğrenme tabanlı optimal şarj stratejisi modeli önerilmiştir. Çalışmada araç kullanıcılarının kararını etkileyecek hava durumu bilgisi, trafik durumu, şarj istasyonu yoğunluk eviyesi gibi durumlar dikkate alınmıştır.

Lee ve diğ. (2018) tarafından pekiştirmeli öğrenme tabanlı bir istasyon yönetim modeli geliştirilmiştir. Modelde elektrikli araç kullanıcılarının aldığı servis kalitesi

garantilenirken istasyona gelen araçların kabul olasılığının maksimize edilmesi amaçlanmıştır.

Liu ve diğ. (2021) pekiştirmeli öğrenme tabanlı bir şarj servis çizelgeleme yönetim modeli sunmuştur. Hızlı şarj istasyonu ve elektrikli araçlara arasındaki etkileşim için önce bir akıllı ulaşım sistemi önerilmiştir. Sonrasında elektrik araç şarj navigasyon modeli kurulmuştur. Bu şemaların kombinasyonu sayesinde istasyondaki kaynakların optimize kullanımı için elektrikli araç çizelgelemesi problemi çözülmüştür.

Moghaddam ve diğ. (2020) ağ dengesizliğini ve güç kesintilerini engellemek için pekiştirmeli öğrenme tabanlı bir çevrimiçi fiyatlandırma stratejisi önerilmiştir. Önerilen yöntemde, elektrikli araç yük kaydırma mekanizması kullanılmaktadır. Önce elektrikli araçların istasyona olan talebi ajan yardımıyla monitör edilir ve değerlendirilir, sonrasında istasyonun fiyatlandırılması her aralık için güncellenir. Bu güncelleme sayesinde ağ en yoğun saatlerden önce araçları istasyona daha fazla çekebilmek için sürücülere daha ucuz fiyatlar sunar.

2.5 Şarj İstasyonlarında Öncelikli Şarj Alanında Yapılan Çalışmalar

Araçların elektrikli şarj istasyonundan aldığı hizmet sırasında kuyruğun belirli bir seviyede kalması, araçların bekleme süresini veya şarj tamamlanma süresini en aza indirilmesi, şebekenin yükünü dengelemek veya azaltmak gibi hedefleri bulunan çalışmalar mevcuttur.

CPU işlem kuyruğu sıralaması, hedeflenen amaca göre farklı kuyruk disiplinleri kullanılarak CPU'nun işleyeceği sıradaki işin belirlenmesine yönelik bilgisayar bilimleri alanında yapılan çalışmalardır. CPU çizelgelemesinde CPU kullanım oranının artırılması, birim zamanda tamamlanan iş sayısının artırılması, işlerin bekleme ve tamamlanma süresinin azaltılması gibi çeşitli hedefler olabilir. Kullanılan çizelgeleme algoritmalarına ilk giren ilk çıkar (FIFO), en kısa süren iş önce çıkar (shortest job first), yanıt süresi oranı öncelikli (Highest response ratio next, HRRN) örnek gösterilebilir. Chopra (2009) tarafından yapılan çalışmada CPU çizelgelemede yaygın şekilde kullanılan HRRN yöntemi ilk kez elektrikli şarj alanında Kakillioglu ve diğ. (2022) tarafından yapılan çalışmada kullanılmıştır. Bu çalışmada ekspres şarj istasyonundaki kaynakların farklı önceliğe sahip araçlar arasında bekleme sürelerinin birbirine oranı belirli bir seviyede tutulacak şekilde

dinamik olarak atamasının yapıldığı simülasyon tabanlı bir metot geliştirilmiştir. Kakillioglu ve diğ. (2022) tarafından yapılan çalışma ve tez kapsamında geliştirilen yöntem arasındaki en önemli fark, tez çalışmasında geliştirilen yöntemin istasyona gelen araçların talep ettikleri şarj olma süresi bilgisinin bilinmemesidir. Kakillioglu ve diğ. (2022) çalışmasında ele alınan yöntem Bölüm 3'te detaylı olarak anlatılmıştır.

Fescioglu-Unver ve diğ. (2021) çalışmasında öncelikli servis veren ekspres şarj istasyonunda PI (orantısal integral) kontrol metodu tabanlı bir kaynak yönetim modeli geliştirmiştir. Yöntem kaynaklardan hizmet alacak öncelik sınıfını dinamik olarak değiştirmekte ve bu sayede iki öncelik sınıfının bekleme sürelerinin oranı belirli bir seviyede tutulmaya çalışılmaktadır.

Peng ve diğ. (2012) çalışmasında istasyona gelen araçları önceliğe göre sıralı tek bir kuyrukta bekletmekte ve belirli zamanlarda kuyruğu kalan zaman (slack time) kuralına göre tekrar sıralamaktadır. Gelen araçlar, sistemden çıkacakları zamanı bildirmekte sistem de aracın ihtiyaç duyduğu şarj süresini hesaplayarak kalan zamanı belirlemektedir.

Wei ve diğ. (2016) da çalışmalarında tek kuyrukta araçlar arası önceliklendirme yaparak kuyruğu dinamik olarak tekrar sıralamıştır. Öncelik katsayısı, sürücünün bildirdiği sistemden çıkma zamanının yanı sıra aracın şarj ihtiyacı ve toplam bekleme süresinin yer aldığı bir formül ile hesaplanmıştır.

Koordine şarj yöntemi güç sistemlerine elektrikli araçların verimli biçime entegre edilmesini sağlamaktadır. Kumar ve diğ. (2015) yaptıkları çalışmada koordine şarj stratejilerinden güç tabanlı ve zaman tabanlı stratejileri benimsemiştir. Elektrikli araçların şarj edilmelerinin çizelgelenmesi için ise kalan şarj durumu ve kalan zaman gibi kriterler kullanılmıştır. Bu farklı öncelik kriterlerinin elektrikli araçların şarj edilebilirliği ve adaletli şarj olma durumu açısından etkisi her iki koordine stratejisi için de incelenmiştir. Performansları simülasyon aracılığı ile değerlendirilmiştir.

Zheng ve Jian (2016) tarafından yürütülmüş bu çalışmada şebeke üzerindeki olumsuz etkiyi hafifletmek için akıllı şebeke çerçevesinde dinamik şarj önceliğini dikkate alan bir algoritma önerilmektedir. Araçların şarj öncelikleri kalan şarj süresi, araçlar için şarj edilecek kalan elektrik enerjisine ve şarj cihazının maksimum çalışma gücüne göre tanımlanmıştır. Son olarak algoritmanın etkinliği simülasyon ile incelenmiştir.

2.6 Diğer Alanlarda Yapılan Sunucu Sayısını Dinamik Olarak Değiştiren Çalışmalar

Farklı hizmet sınıflarına hizmet verilen ve bekleme süresinin bir performans kriteri olarak kullanıldığı alanlarda, sunucu sayısının dinamik olarak değiştirilmesi sıklıkla başvurulan bir yöntemdir. Martonosi(2011) yaptığı çalışmada hava alanında iki farklı müşteri tipi için atanan sunucu sayısının dinamik olarak değiştirmiş ve müşterilerin toplam bekleme süresini en küçükmeyi hedeflemiştir. Çözüm yöntemi için akışkan kuyruk modeli dinamik programlama ile birlikte kullanılmış ve performansı simülasyon ortamında test edilmiştir.

Bennani ve Menasce (2005) değişken yük altında sunuculara uygulamaları dinamik olarak atayarak sistemdeki toplam yanıt süresini azaltmayı amaçlamıştır. Çalışmada işlemlerin sistemden kazandıkları fayda (utility) işlemin bekleme süresine bağlı bir fonksiyonla değerlendirilmektedir. Çalışmada toplam fayda sezgisel arama yöntemiyle sunucu ataması belirlenerek artırılmak istenmektedir.

Palmer ve Mitrani (2005) farklı iş tiplerinin geldiği çok sunuculu bir ortamda sunucuların iş tiplerine dinamik olarak ataması için sezgisel yöntemler önermektedir. Çalışmada sunucuların farklı işler arasında geçiş maliyeti vardır. Önerilen sezgisel yöntemler, Markov Karar Süreci yöntemiyle hesaplanan en iyi performansla karşılaştırılmaktadır.

Huang ve diğ. (2014) tarafından yapılan derleme çalışmasında sunucuların dinamik olarak atanması konusundaki araştırmalar yöntemlerine göre ikiye ayırmıştır: Kural tabanlı yöntemler (makine öğrenmesi, bulanık kontrol) ve model tabanlı yöntemler (kuyruk modelleri, kontrol teorisi). Çalışmada kontrol sistemleri modelleme tasarım ve analizinde kullanılan hali hazırda gelişmiş yöntemlerden faydalanabilmenin kontrol teorisi kullanan çalışmaların avantajına olduğunu belirtilmiştir. Kontrol teorisi yönteminin kullanıldığı geri beslemeli kontrol metodu ile sistem performansını kontrol eden çalışmalara Stankovic ve diğ. (1999), Parekh ve diğ. (2001), Abdelzaher ve diğ. (2002) ve Diao ve diğ. (2005) örnek gösterilebilir. Bu çalışmalarda, Hizmet Seviyesi Anlaşması ile önceden söz verilen yanıt süresine uyabilmek için sunucu sayısı veya gücünün dinamik olarak değiştirilmesi ve sisteme kontrol edilecek müşteri sayısının sınırlanması ele alınmıştır. Bahsedilen bu yöntemler elektrikli araç ekspres şarj problemine farklı araç tiplerine (öncelik sınıfı)

farklı servis seviyeleri ile hizmet vermenin ve buna uygun olarak sunucu sayısı gücünün dinamik olarak yönetilmesinin uygulanabiliridir. Ancak şarj istasyonuna kabul edilecek araç sayısının sınırlanması yani araçların şarj alma taleplerinin reddedilmesi elektrikli araç şarj alanında uygulanabilir değildir.

Sunucu sayısını dinamik olarak değiştiren başka iki çalışma da Lu ve diğ. (2001) ile Lu ve diğ. (2006) tarafından yapılmıştır. Bu iki çalışmada, farklı önem dereceli işler mevcuttur. Ve bu farklı öncelikli işlerin tamamlanma sürelerinin birbirlerine oranı bu işlere atanan sunucu sayısının dinamik olarak değiştirilmesi yoluyla kontrol edilmektedir. Geliştirilen algoritmada geri beslemeli kontrol yöntemi kullanılmıştır.

2.7 Bekleme Süresi Tahmini Yapan Çalışmalar

Literatürde farklı öncelik sınıfına sahip araçların istasyonda ortalama bekleme sürelerinin tahminine ait elektrikli araç şarj istasyonları alanında yapılmış bir çalışmaya rastlanmamıştır. Ancak bu bölümde hastane acilinde bekleme süresi, bankada bekleme süresi tahmini için, yapılan tahmin çalışmaları incelenmiştir.

Hastane alanında yapılan bekleme süresi tahmini çalışmalarına örnek olarak; Hijry ve Olawoyin (2021), Benevento ve diğ. (2019), Kuo ve diğ. (2020), Ang ve diğ. (2016), Sun ve diğ. (2012), Benevento ve diğ. (2023) tarafından yapılan çalışmalar gösterilebilir. Hastane alanında yapılan bekleme süresi tahmin çalışmalarında yaygın olarak hastanın yaşı, hastanın triyaj kodu ve tanısı, triyaj seviyesi, acil servisteki hasta ve tedavi yoğunluğu ve personel kaynağı bilgisi gibi tahminci değişkenler kullanılmıştır. Ang ve diğ. (2016) acil serviste hastaların bekleme süresi için Lasso metodu ve kuyruk teorisini birleştiren Q-Lasso adında bir metot benimsemişlerdir ve tahminlerini her 10 dakikalık zaman aralığında bir güncellemişlerdir. Kullanılan metot genellikle hastanelerce tercih edilen kayan ortalama metoduyla kıyaslanmış ve daha başarılı olduğu görülmüştür. Benevento ve diğ. (2019) ise yaptıkları çalışmada acil servis departmanında dinamik bekleme süresi tahmininde yeni kuyruk tabanlı değişkenlerin tahmin doğruluğuna olan etkisini incelemiştir. Örnek kırmızı, yeşil, sarı kodlu gelen ortalama hasta sayısı ve triyaj edilen ama henüz tedavi edilmeyen hasta sayısı, tedavi edilen ama sonuç bekleyen hasta sayısı gibi değişkenler kullanılmıştır ve tahmin doğruluğunu iyileştirebildiği gözlemlenmiştir. Hijry ve Olawoyin (2021) tarafından yapılan çalışmalarda derin öğrenme metotları

kullanılmıştır. Kuo ve diğ. (2020) makine öğrenmesi algoritmaları ve sistemik düşünce tabanlı bir yaklaşım kullanmıştır. Sun ve diğ. (2012) ise Kantil Regresyon yöntemi ile hastaların bekleme süresini tahmin etmişlerdir. Benevento ve diğ. (2023) acil servis departmanlarında bekleme süresi tahmini için farklı makine öğrenmesi algoritmalarını uyguladığı ve karşılaştırıldığı bir çalışma sunmuşlardır.

Kerner ve diğ. (2021) bazı müşterilerin tahminci tarafından görünmez olduğu kısmen görünür hizmet sistemlerinde müşterilerin beklenen bekleme süresini gerçek zamanlı olarak tahmin etme problemini incelemişlerdir. Çalışmada kuyruk teorisi bağlamında analitik bir çözüm üretilmiş ve bu çözüm kullanılarak veri-odaklı bir yaklaşım geliştirilmiştir. Yaklaşım gerçek veri ile kuyruk modeli simülasyonu ile değerlendirilmiştir.

Kyritsis ve Deriaz (2019) banka kuyruğu baz alınarak bekleme süresi tahminini makine öğrenmesi yaklaşımları kullanılarak gerçekleştirmişlerdir. Girdi olarak müşterinin kuyruğa girdiği gün, saat ve dakika bilgisi ile kuyrukta bekleyen kişi sayısı kullanılmıştır.

Bu tez çalışmasının literatürdeki diğer çalışmalardan farkları; sunucu sayısını dinamik olarak değiştiren çalışmalar arasında elektrikli araçlardan herhangi bir bilgi alınmamakta, istasyona gelen araçlar reddedilmemekte ve sunucu ataması Derin Q-Öğrenme yöntemine dayalı olarak yapılmaktadır. Buna ek olarak çalışmanın ikinci kısmı ile gerçekleştirilen ortalama bekleme süresi tahmini çalışması literatürde hızlı şarj alanında benzer bir çalışmaya rastlanmayan daha önce yapılmamış bir çalışmadır.

3. EKSPRES ŞARJ İSTASYONU YÖNETİMİ


Ekspres şarj istasyonu yönetim modeli, istasyondan servis almak için kuyrukta bekleyen araçların bekleme süresine gösterdikleri hassasiyete uygun olacak şekilde kaynak atamasını yapmayı amaçlamaktadır. Böylece daha kısa sürede şarj olmak isteyen kullanıcıların daha az bekleme süreleri sağlanır. Geliştirilen yöntem literatürdeki benzer çalışmalardan olan Fescioglu-Unver ve diğ. (2021), Kakillioglu ve diğ. (2022), bazı yönleri ile farklılaşmaktadır. Modeller arasında, elektrikli araçların istasyona vardıklarında kendileri ile ilgili vermeleri gereken bilgiler ve kullandıkları kaynak yönetim modeli açısından farklılıklar vardır. . Bu tez kapsamında geliştirilen yöntemde (RL-EXP), modelsiz pekiştirmeli öğrenme (Model-Free Reinforcement Learning) metotlarından biri olan Derin Q-Öğrenme (Deep Q-Learning) yöntemi kullanılmaktadır.

Bölüm 3.1’de geliştirilen ekspres şarj istasyonu yönetim modellerinin hepsi için geçerli olan istasyon yerleşim ve işleyiş mantığı anlatılmaktadır. Bölüm 3.2’de görece bekleme modelinin mantığı açıklanmaktadır. Bölüm 3.3’te ise karşılaştırma kullanılan istasyon yönetim modellerinin çalışma mantıkları kısaca özetlenmektedir.

3.1 Ekspres Şarj İstasyonu Yerleşim ve İşleyişi

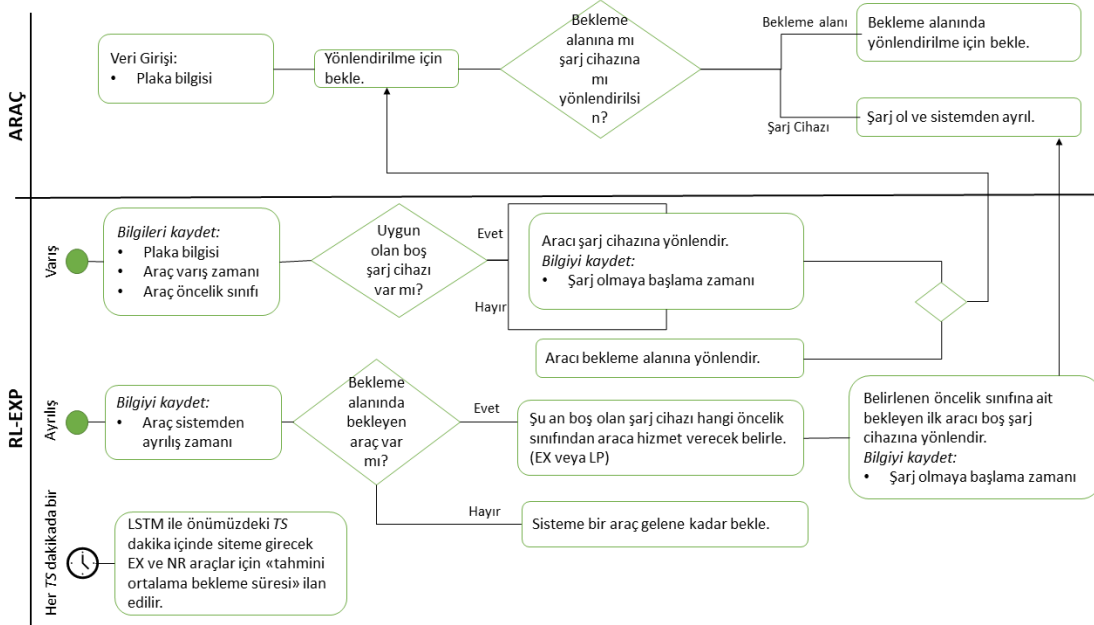
Çalışmada, şarj istasyonundan ekspres servis almak isteyen araçların diğer araçlardan görece daha az bekleme süreleri sağlayacak (bu araçlardan ilerleyen bölümlerde EX-Ekspres yani yüksek öncelikli araç ve NR-diğer araçlar) kaynak atamalarının dinamik olarak değiştirilebildiği gerçek zamanlı kaynak kontrol yöntemleri (ilerleyen kısımlarda ekspres şarj yöntemleri olarak bahsedilecektir) geliştirilmiştir.

Ekspres şarj yöntemlerinin uygulandığı istasyon yerleşim modeli aşağıda Şekil 3.1’de gösterilmiştir.



Şekil 3.1: Ekspres şarj istasyonu yerleşimi.

Şekil 3.2 derin pekiştirmeli öğrenme tabanlı kaynak yönetim modelinin (ilerleyen bölümlerde RL-EXP olarak anılmıştır) ve araçların aktivite akış diyagramını göstermektedir.



Şekil 3.2: Sistem aktivite diyagramı.

Araç ve RL-EXP'e ait aktivite diyagramında da yer alan sistem adımları aşağıdaki şekilde açıklanmaktadır:

Araç:

- i) İstasyona giriş yapan araç hangi öncelik sınıfı ile servis almak istediğini ve plaka numarası gibi diğer bilgileri istasyona bildirir.
- ii) Araç, o anda boş şarj cihazı varsa boş şarj istasyonuna direkt yönlendirilir. Boş şarj cihazı yok ise bekleme alanına yönlendirilerek beklemeye başlar.
- iii) Araç, ışıklı tabelada yanan plaka numarası-şarj cihazı numarası eşleşmelerinin arasından kendi plaka numarasını takip eder.
- iv) Kendi plakası tabelada ilan edildiğinde belirtilen şarj cihazına geçerek şarj olmaya başlar.
- v) Şarj olmayı bitiren araç sistemden ayrılır.

İstasyon:

- vi) İstasyon, sisteme giriş yapan aracın plakası, sisteme varış anı, aracın hangi öncelik sınıfından hizmet almak istediği vb. gibi bilgileri kaydeder.
- vii) Boşta bulunan şarj cihazı varsa, sisteme gelen aracı bu boş şarj cihazına yönlendirir. Araç servis almaya başlar.
- viii) Servis almaya başlayan aracın servise başlama zamanını kaydeder.
- ix) Boşta şarj cihazı yok ise istasyon gelen aracı bekleme alanına yönlendirir.
- x) Her şarj cihazı boşaldığında, boşalan şarj cihazının hangi öncelik sınıfına hizmet vereceğine RL-EXP kontrol mekanizması kullanılarak karar verilir.
- xi) İstasyon boşalan şarj cihazına, belirlenen öncelik sınıfına ait bekleme alanında bekleyen araçların arasından ilk gelen aracın plaka numarasını ışıklı tabelada ilan eder.
- xii) Araç ilgili şarj cihazından servis almaya başlar. İstasyon aracın servis almaya başladığı zamanı kaydeder.
- xiii) Servisi biten araç sistemden ayrılır. Sistemden ayrılan her araç için, istasyon ayrılış zamanını kaydeder.
- xiv) İstasyon, LSTM tahmin mekanizmasını kullanarak her TS dakikada bir gelecek TS dakika içinde sisteme giriş yapacak EX ve NR araçlar için “tahmini ortalama bekleme” süresi ilan eder.

3.2 Görece Bekleme Modeli

RL-EXP modeli, yüksek öncelikli araçların (EX-Araçlar) ve düşük öncelikli araçların (NR-Araçlar) ortalama kuyrukta bekleme sürelerinin birbirine oranının belirlenen bir hedef görece bekleme oranı (φ) ile aynı seviyede tutulmasını temel alan görece bekleme modeli yaklaşımını kullanmaktadır. Görece bekleme yaklaşımı bilgisayar bilimlerinde web-sunucu servisi alanında Lu ve diğ. (2006) tarafından kullanılmıştır. Görece bekleme, elektrikli araçlara öncelikli servis alanında ise Fescioglu-Unver ve diğ. (2021), Kakillioglu ve diğ. (2022) tarafından kullanılmıştır. Hedef görece bekleme oranı (φ) istasyonların kendi fiyatlandırma politikaları veya başka beklenti ve koşullarına uygun şekilde belirlenebilmekte ve açık bir şekilde herkese ilan edilmektedir. Belirlenen hedef görece bekleme oranı (φ) değeri her zaman 1'den büyük eşit olmalıdır ($\varphi \geq 1$). Bu bir zaman periyodu boyunca NR-Araçların, EX-Araçlardan φ kat daha uzun bir süre beklemesinin beklendiği anlamına gelir.

Bir aracın bekleme süresi, aracın sisteme girdiği andan servis almaya başlayıncaya kadar geçen süre ile ölçülür. $EX_{bekleme}(t)$ ve $NR_{bekleme}(t)$, t zaman periyodunda servis almaya başlayan sırasıyla EX ve NR araçların ortalama bekleme sürelerini ifade etmektedir. Denklem (3.1) ve (3.2) $EX_{bekleme}(t)$ ve $NR_{bekleme}(t)$ hesaplanışını göstermektedir. Denklem 3.1 ve 3.2de yer alan EXVehT ve NRVehT ifadeleri, t zaman periyodunda servis almaya başlayan EX ve NR araçlar kümesini, pay kısmında yer alan ifadede *vehicle* bir aracı, $vehicle_{bekleme}$ ise o aracın bekleme süresini ifade etmekte kullanılmıştır.

$$EX_{bekleme}(t) = \frac{\sum_{vehicle \in EXVehT} vehicle_{bekleme}}{|EXVehT|} \quad (3.1)$$

$$NR_{bekleme}(t) = \frac{\sum_{vehicle \in NRVehT} vehicle_{bekleme}}{|NRVehT|} \quad (3.2)$$

Görece hedef bekleme oranı değerinden olan sapma $diff(t)$ olarak adlandırılmıştır. $diff(t)$ Denklem 3.3'te hesaplanmaktadır. Denklemde, $EX_{bekleme}(t) * \varphi$ ile ifade edilen, düşük öncelikli araçlar için hedeflenen ortalama bekleme süresi iken $NR_{bekleme}(t)$ düşük öncelikli araçların gözlemlenen ortalama bekleme süresidir. Bu

iki deęer arasındaki fark deęeri, hedef bekleme oranından sapma $diff(t)$ olarak adlandırılmaktadır.

$$diff(t) = EX_{bekleme}(t) * \varphi - NR_{bekleme}(t) \quad (3.3)$$

RL-EXP modeli, her řarj cihazı boşaldığında bu kaynağın hangi araç sınıfına hizmet vereceğini dinamik bir şekilde yöneterek, sapma miktarı $diff$ 'i sıfır (0) seviyesinde tutarak görece bekleme hedefi deęerini başarılı şekilde izlemeyi amaçlar.

3.3 Karşılařtırmada Kullanılan Modeller

Çalıřma kapsamında geliştirilen RL-EXP modeli ile karşılařtırmada kullanılacak olan 3 model (sırasıyla SC-EXP, FC-EXP, sabit sunucu) olarak adlandırılacaktır. RL-EXP metodu ile dięer metotların arasındaki en önemli fark, boşalan kaynağa atanacak olan araç sınıfı belirlenirken kullanılan yöntemler ve metotların kullandığı ek bilgi tipleridir (örneğin RL-EXP metodu servis süresi bilgisine ihtiyaç duymazken SC-EXP yöntemi bu bilgiyi araç istasyona girdiği anda, FC-EXP yöntemi de řarja başladığı anda talep eder). Yöntemler uygulanırken hangi bilgiye ihtiyaç duyulduğu ařağıda Çizelge 3.1'de verilmiştir.

SC-EXP çalışmasında benimsenen yöntem açık çevrim kontrolü (open-loop control) yöntemi iken FC-EXP ve RL EXP metotlarında kapalı çevrim kontrol yöntemi benimsenmiştir. Açık çevrim kontrolünde sistem yaptığı işten geri dönüt almazken kapalı çevrim kontrol yönteminde (closed-loop control) sistem yapılan eylemin sonucuyla ilgili geri dönüt almaktadır.

Çizelge 3.1: Yönetim metotlarının karşılařtırılması.

Yöntem	řarj Süresi Bilgisi	Bilgi Veriř Zamanı
SC-EXP	Evet	Araç istasyona girdiğinde
FC-EXP	Evet	Araç servise başladığında
Sabit sunucu	Hayır	-
RL-EXP	Hayır	-

3.3.1 SC-EXP (Açık çevrim) kontrol yöntemi

Kıyaslamada kullanılacak olan çalışmalardan birisi SC-EXP kontrol yöntemidir (Kakillioglu ve dię. (2022)). Çalışmada öncelik bazlı servis veren řarj istasyonunda

kaynak yönetimi için görece hedef bekleme modeli temel alınmıştır. SC-EXP modeli, şarj kaynaklarının kullanıcı sınıflarına atamasını görece hedef bekleme oranı ve gerçekleşen bekleme oranı değerleri birbirini izleyecek şekilde dinamik olarak kontrol etmektedir. Çalışmada geliştirilen yöntem, simülasyon tabanlı bir kontrol yöntemidir. Gelecek olay listeleme yöntemi ile gerçekleşen bekleme oranı tahmin edilmektedir. SC-EXP modelinde, her şarj ünitesi boşaldığı anda, bu boşalan kaynağın hizmet vereceği yeni öncelik sınıfı belirlenir. Boşalan şarj noktasının hangi öncelik sınıfına atanacağını belirlemek için her iki atama durumunu da içeren simülasyon koşulları yapılır. Koşullar sonunda iki atama alternatifinden hangisinin hedef bekleme oranından sapma yani *diff* değeri hedef değer olan 0'a daha yakın ise o atama seçilir.

3.3.2 FC-EXP (Kapalı çevrim) kontrol yöntemi

RL-EXP ile kıyaslamada kullanılacak bir diğer yöntem FC-EXP yöntemidir Fescioglu-Unver ve diğ. (2021). Çalışmada görece hedef bekleme modeli benimsenmiştir. Kapalı çevrim kontrol (closed-loop control) metodu, yüksek ve düşük öncelikli araçların ortalama bekleme sürelerinin oranının önceden belirlenerek ilan edilen hedef bekleme oranı değerinde tutmayı hedefler. Bunu gerçekleştirebilmek için, her 1,5 dakikada bir PI (orantısız integral) kontrolörü aracılığı ile kaynaklardan hizmet alacak öncelik sınıfını dinamik olarak değiştirir. Çalışmada kullanılan PI kontrolörünün K_p ve K_i parametreleri Yüzey Tepki metodu ile belirlenmiştir.

3.3.3 Sabit sunucu yöntemi

Karşılaştırmada kullanılan bir diğer yöntem ise sistemde sabit sunucunun bulunduğu durumdur. Sistemde yüksek ve düşük öncelikli araç sınıflarına hizmet verecek şarj cihazı sayısı sabit olarak belirlenmektedir. Sabit sunuculu sistem iki farklı şekilde hizmet verebilir. İlk durumda, yüksek öncelikli sınıfa hizmet vermek üzere atanmış sunucu boş olsa bile düşük öncelikli araçlara ve aynı şekilde düşük öncelikli sınıfa atanmış sunucular da boş olsa bile yüksek öncelikli araçlara hizmet verememektedirler. İkinci durumda ise yüksek veya düşük öncelikli sınıfa atanmış bir sunucu, gelen aracın sınıfına bakılmaksızın eğer boş ise ve o an kendi sınıfına ait bekleyen araç yok ise gelen farklı sınıf araca hizmet verebilmektedir. “Boş sunucu varsa gelen araçları bekletmeme” politikasına “sunucu paylaşımı kuralı” adını

vermekteyiz. Sunucu paylaşımı kuralı sunucunun ait olduđu sınıfı deęiřtirmeden diđer sınıfa hizmet vermesine olanak tanır. Karřılařtırmalarda ikinci durumda belirtilen sistem kullanılmıřtır.





4. SİMÜLASYON MODELİ

Tez kapsamında geliştirilen Derin Q-Öğrenmesi tabanlı model olan RL-EXP, eğitilmesi, gerekli parametrelerinin belirlenmesi ve performansının test edilebilmesi için MATLAB ortamında kodlanmış simülasyon modeli kullanılmıştır. Çizelge 4.1’de simülasyon modelinin değişkenleri ve açıklamaları yer almaktadır.

Çizelge 4.1: Simülasyon modeli değişkenleri.

Parametre	Açıklama	Değeri
λ	Variş oranı	0,58 ... 0,69 araç/dk
μ	Ortalama servis verme oranı	0,053 araç/dk
totCharg	İstasyondaki şarj cihazı sayısı	14
ρ	İstasyon doluluk oranı	0,80 ... 0,95
p_e	Yüksek öncelikli araç oranı	0,1 ... 0,9
p_n	Düşük öncelikli araç oranı	$1-p_e$
φ	Hedef göreceli bekleme oranı	1, 1.1 ... 1.9, 2

λ parametresi düşük ve yüksek öncelikli araçlar için birleşik variş oranını ifade etmektedir. Sistemde birbiriyle özdeş 14 şarj pompası bulunmaktadır. Araçların şarj süresi üçgensel dağılıma sahiptir ve en fazla 30, sıklıkla 18 ve en az 10 dakika değerini alabilir (TRIA(10,18,30) dakika). Bu dağılım kullanılarak ortalama servis verme oranı $\mu=0.053$ araç/dakika olarak hesaplanmaktadır. Varişlar arası süre Üssel dağılıma sahiptir ve varişlar arası geçen ortalama süre $\frac{1}{\lambda}$ ’ya eşittir. Farklı variş oranı değerleri farklı istasyon doluluk oranına sebep olmaktadır. İstasyonun genel doluluk oranı λ ve μ parametrelerinin bir fonksiyonu olarak karşımıza çıkmaktadır. Farklı λ ve μ değerlerinin oluşturduğu doluluk oranı Eşitlik 4.1 ile açıklanmıştır. Farklı senaryolarda kullanılan λ değeri, hedeflenen doluluk oranını elde edecek şekilde Eşitlik 4.2’deki gibi hesaplanmaktadır.

$$\rho = \lambda / (totCharg * \mu) \quad (4.1)$$

$$\lambda = \rho * (totCharg * \mu) \quad (4.2)$$

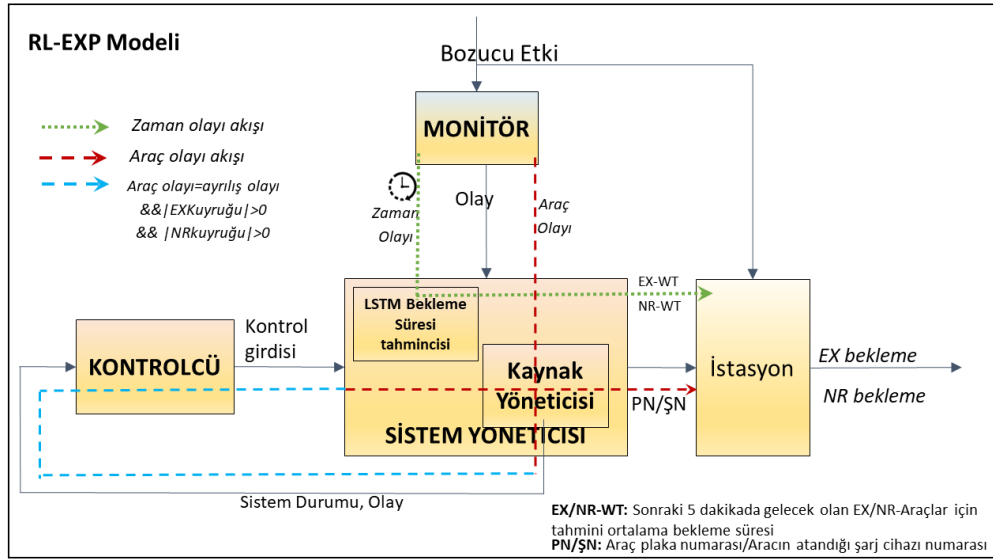
Sisteme giren bir aracın yüksek veya düşük öncelikli olacağı araç sınıf oranı sırasıyla p_e ve p_n ile belirtilmiştir. $p_e + p_n = 1$ olmak üzere bir araç p_h olasılığı ile yüksek öncelikli, p_n olasılığı ile düşük öncelikli araç sınıfını tercih ediyor olacaktır.

Simülasyon modeli her aracın istasyona teker teker gelmesiyle başlar. Araçların varış zamanları arasında geçen süre üssel dağılmaktadır. Gelen her araca sisteme girdikleri anda rastgele biçimde öncelik sınıfı ve belirtilen üçgensel dağılım ile servis süreleri atanır. Aracın hangi öncelik sınıfına ait olduğu rastgele p_e olasılığı ile yüksek öncelikli, $1 - p_e$ olasılığı ile düşük öncelikli olacak şekilde atanır. Sisteme giriş yapan aracın varış zamanı ve öncelik sınıfı istasyon tarafından kaydedilir. Servis almaya başlayan aracın sunucuyu tutma zamanı, sistemden ayrılan aracın ise ayrılış zamanı simülasyon modelinde tutulmaktadır. Bir araç istasyona geldiğinde kuyruklar boş ise ve herhangi bir araca servis vermeyen boş bir kaynak varsa performans karşılaştırmasında kullanılan tüm kaynak yönetim modellerinde, bu araç beklemeden boş sunucudan servis almaya başlar. Eğer araç geldiğinde birden fazla boşta kaynak varsa, bu boş kaynaklar arasından rastgele seçim yapılır. Sunucuların tamamı doluyorsa, gelen araç kendi öncelik sınıfına ait kuyruğa geçip servis alacağı anı beklemeye başlar. Herhangi bir sunucu boşladığında, eğer sadece tek sınıfta araç beklemekteyse bu araç boş sunucuya geçerek servis almaya başlar. Ancak, sunucu boşaldığında hem yüksek hem düşük öncelikli araçlar kuyrukta bekliyorsa boşalan kaynaktan düşük veya yüksek öncelikli sınıftan hangisinin servis almaya başlayacağı RL-EXP Derin Q-Öğrenmesi ile karar verilir. RL-EXP algoritmasının karar mekanizması Bölüm 5.4'te detaylı olarak anlatılmaktadır. Verilen karar, istasyon tarafından uygulanır ve belirlenen öncelik sınıfına ait araç kaynağa yönlendirilir. İşlemi biten araç sistemden ayrılır ve servis aldığı kaynak boşalmış olur. RL-EXP Derin Q-Öğrenmesi algoritması, her kaynak boşaldığında ve hem yüksek hem de düşük öncelikli sınıf kuyruğunda bekleyen araçlar olduğunda çalışır. Simülasyon modelinin çıktısı her iki öncelik sınıfına ait araçların her biri için bekleme süresidir.

Her simülasyon koşurumunda, replikasyon uzunluğu 30.000 dakika, ısınma periyodu ise 3000 dakikadır. Tüm deney testleri ve performans karşılaştırmaları 30 replikasyon üzerinden yapılmıştır.

5. PEKİŞTİRMELİ ÖĞRENME İLE KONTROL METODU (RL-EXP)

Tez kapsamında pekiştirmeli öğrenmeye dayalı Derin Q-Öğrenmesi tabanlı bir kaynak yönetim modeli olan RL-EXP modeli geliştirilmiştir. Şekil 5.1 RL EXP modelinin bileşenlerini göstermektedir.



Şekil 5.1: RL-EXP modeli bileşenleri.

RL-EXP modeli Monitör, Kontrolcü ve Sistem Yöneticisi olmak üzere 3 ana bileşenden oluşmaktadır. Sistem Yöneticisinin üstlendiği görevler, LSTM Bekleme Süresi Tahmincisi ve Kaynak Yöneticisi olarak iki alt bileşen tarafından yerine getirilmektedir.

Monitör, araçların sisteme varış, sistemden ayrılış, servise başlama gibi olayları dinler ve sistem zamanını kaydeder. Monitör, belirlenen zaman dilimlerinde (her “TS” dakikada bir) “Zaman Olayı” ve bir araç hareketi gerçekleştiğinde “Araç Olayı” olaylarını sistem yöneticisine iletir.

Sistem Yöneticisinin amacı Araç Olay Akışı ve Zaman Olay Akışını yönetmek ve zaman olayı olduğunda “Bekleme Süresi Tahmincisi”ni ve araç olayı olduğunda “Kaynak Yöneticisi”ni aktive etmektir.

- i) Araç Olayı Akışı: Bir aracın sisteme varışı, ayrılışı veya servis almaya başlayışı ile tetiklenir. Bu durumda Sistem Yöneticisi gerçekleşen olayı içerecek biçimde sistem durumunu günceller ve olay tipine göre gereken yönlendirmenin yapılması için Kaynak Yöneticisi bileşenini kullanır. Gerçekleşen olay bir aracın sisteme varışı ise mevcut kaynak durumuna göre araç bekleme alanına veya şarj ünitesine yönlendirilir. Olay, bir aracın ayrılışı ile kaynağın boşalması ise, ve kuyrukta sadece bir sınıftan araç varsa, Kaynak yöneticisi o aracı boşalan sunucuya yönlendirir. Olay araç ayrılışı ise ve kuyrukta iki sınıftan da araç beklemekteyse, Kaynak Yöneticisi, Kontrolcüyü çağırarak boşalan sunucunun hangi sınıftan araca hizmet vereceğini belirler. Kontrolcünün belirlediği sınıfa ait kuyruğun en ön sırasındaki aracı sunucuya yönlendirir.
- ii) Zaman Olayı Akışı: Monitör tarafından sistem zamanı tutulur ve önceden belirlenmiş belirli bir zaman aralığı için (her TS dakikada bir) zaman olay akışı başlatılır. Zaman akışı ile, Sistem Yöneticisi LSTM Bekleme Süresi Tahmincisi ara bileşenini kullanarak, önümüzdeki TS dakikada sisteme giriş yapacak araçlar için tahmin edilen EX-WT (yüksek öncelikli araçlar için) ve NR-WT (düşük öncelikli araçlar için) ortalama bekleme sürelerini ilan eder.

Bekleme Süresi Tahmincisinin görevi, aktive edildiğinde önümüzdeki “TS” dakika içinde gelecek yeni araçlar için ortalama bekleme süresi tahmini yaparak Sistem Yöneticisi aracılığıyla ilan etmektir.

Kaynak Yöneticisinin görevi, aktive edildiğinde, gerçekleşen araç olayı ve o anki istasyon durumunu inceleyerek gerekiyorsa Kontrolcüyü çağırdıktan sonra, Kontrolcü gerekmiyorsa hemen araç plaka numarası (PN)/şarj kaynağı numarası (ŞN) bilgisini ışıklı tabela üzerinde ilan ederek araçları doğru şekilde şarj pompalarına yönlendirmektir.

Kontrolcünün görevi ise boşalan şarj cihazının hizmet verdiği öncelik sınıfını dinamik ve gerçek zamanlı olarak kontrol etmektir.

Bölüm 5.1’de RL-EXP modelinin bileşenlerinden Monitöre ait bilgiler, 5.2’de Sistem Yöneticisi ve alt bileşenleri Bölüm 5.3’te ise Kontrolcü bileşenine ait bilgilere yer verilmiştir. Bölüm 5.4’te RL-EXP’de kullanılan Pekiştirmeli Öğrenme yaklaşımının prensipleri anlatılmıştır. Son olarak Bölüm 5.5’te ise RL-EXP

kontrolcüsünün hiper parametrelerinin belirlenmesi ve ajanın eğitim aşamasıyla alakalı bilgiler aktarılmıştır.

5.1 Monitör

Monitör bileşeninin temel görevi sistemdeki araç varış, ayrılış, servis almaya başlayış gibi olayları dinlemek, sistem durumunu ve sistem zamanını izlemek ve belirli zaman aralıkları ile (TS dakikada bir) Sistem Yöneticisini uyararak yeni periyot için yüksek ve düşük öncelikli araçlara yönelik tahmini ortalama bekleme süresinin belirlenmesine yönelik Zaman Olayı Akışını başlatmaktır.

Monitör sistemde şu anda bulunan tüm araçları (*Veh*) içeren bir araç listesi ($Veh \in VehList$) tutar ve sistemde her araç kaynaklı bir olay olduğunda bu listeyi günceller. Sisteme her yeni araç girdiğinde monitör yeni bir *Veh* nesnesi yaratır. Yaratılan *Veh* nesnesine plaka numarası ($Veh.pn \leftarrow plakaNo$), sisteme varış zamanı ($Veh.at \leftarrow sistemZamanı$), öncelik sınıfı ($Veh.cl \leftarrow 1 (HP)$ veya $2 (LP)$), ortalama servis süresi ($Veh.sd \leftarrow TRIA(10,18,30)$, servis başlama zamanı ($Veh.ss \leftarrow 0$, başlangıçta 0 atanır) sistemden ayrılma zamanı ($Veh.dt \leftarrow 0$, başlangıçta 0 atanır) ve tahmini ortalama bekleme süresi ($Veh.pred \leftarrow$ öncelik sınıfına uygun şekilde *HPWT* veya *LPWT*) aracın servisi almayı tamamlayıp tamamlamadığını belirten ($Veh.sc \leftarrow 0$, ilk başta 0 atanır servisi almayı tamamladığında 1) özellikleri atanır. Bu yeni aracı *VehList* listesine kaydeder ($VehList \leftarrow Veh \cup VehList$). Araç şarja başladığında şarja başlama anını kaydeder ($Veh.ss \leftarrow sistemZamanı$). Araç servisini tamamlayıp sistemden ayrıldığında servisin tamamlandığını gösterir ($Veh.sc \leftarrow 0$) ve sistemden ayrılış zamanını kaydeder ($Veh.dt \leftarrow sistemZamanı$). Sistemden ayrılan araç, araç listesinden çıkartılır ($VehList \leftarrow Veh \setminus VehList$). Monitör sistemde gerçekleşen tüm araç kaynaklı olayları gerçekleştikleri anda Sistem Yöneticisine iletir. Araç kaynaklı olaylar şu şekilde sıralanabilir: $AT(Veh)$, Veh aracının sisteme varışı, $SS(Veh, \mathcal{N})$, Veh aracının \mathcal{N} numaralı şarj kaynağından servisi almaya başlaması, $DT(Veh, \mathcal{N})$, Veh aracının \mathcal{N} numaralı kaynaktan servisi almayı tamamlayıp sistemden ayrılışı.

5.2 Sistem Yöneticisi

Sistem Yöneticisi sistemin anlık durumunu tutar ve kaynakları yönetir. İki ana görevi vardır. İlk görevi, belirli (TS) zaman aralıkları ile istasyonun ilan edeceği yüksek ve düşük öncelikli araçlara ait tahmini ortalama bekleme sürelerini (EXWT ve NRWT) belirlemektir. Sistem Yöneticisi bu iş için LSTM Bekleme süresi tahmincisi ara bileşenini kullanır. İkinci görevi ise sistemde bulunan araçları doğru bir şekilde boşalan kaynağa veya bekleme kaynağına yönlendirmektir. Bu görev için de Kaynak Yöneticisi alt bileşeninden faydalanılır. Kaynak Yöneticisi ve LSTM Bekleme süresi tahmincisi alt bileşenlerinin çalışma mekanizmaları sırasıyla Bölüm 5.2.1 ve 5.2.2’de anlatılacaktır.

Monitörün Araç Olayı Akışı ile tetiklediği Sistem Yöneticisi başlangıçta her araç varışı ve araç ayrılış olayı için bir *Event* nesnesi, servis almaya başlayış olayı için ise servis almaya başlayan *Veh* aracının tutulduğu bir *ServList* yaratır. Her yeni Araç Olayı olduğunda *Event* nesnesine olayın varış olayı mı ayrılış olayı mı olduğunu belirten olay tipi (*Event.tip* ← varış olayı için 1, ayrılış olayı için 2), olayın gerçekleşme zamanı (*Event.zamanı* ← *sistemZamanı*) ve olay eğer ayrılış ise hangi numaralı şarj ünitesinin boşalacağını gösteren (*Event.bosKaynak* ← varış olayı ise 0, ayrılış olayı ise boşalan kaynak numarası $\$N$) özellikler atanır.

Monitör ünitesi Zaman Olayı Akışını başlattığında Sistem Yöneticisi, anlık sistem durumunu (kuyruk durumları, kaynak doluluk durumları, istasyon tarafından ilan edilen hedef göreceli bekleme oranı ϕ) LSTM Bekleme Tahmincisine gönderir, Tahminden aldığı tahmini ortalama bekleme süreleri olan EXWT ve NRWT değerlerini ilan eder. Bir sonraki zaman diliminin başlangıcına kadar sisteme giriş yapacak araçlar için bu tahmini ortalama bekleme sürelerini ilan eder. Monitör bir sonraki tahmin periyoduna kadar gelecek olan araçların *Veh.pred* değerlerini, ilan edilmiş bu tahmini ortalama bekleme süreleri ile doldurur.

5.2.1 Kaynak yöneticisi

Kaynak yöneticisinin görevi, istasyondaki araçları şarj kaynaklarına yönlendirmek ve sunucuların hizmet verdiği araç öncelik sınıflarını takip etmektir.

Kaynak yöneticisi sistemde bir araç varış olayı *AR(Veh)* gerçekleştiğinde *servList*’i kontrol eder. Eğer boş durumda şarj kaynağı varsa ve kuyrukta bekleyen iki öncelik

sınıfından da araç yoksa gelen araç direkt olarak boş sunucuya yönlendirilir. Servis almaya başlayan araç servise başlayan araçlar listesine eklenir ($(servList \leftarrow SS(Veh, \mathcal{N}) \cup servList)$). Araç varış olayı gerçekleştiğinde, boş sunucu olmaması durumunda ise Kaynak Yöneticisi gelen aracı aracın öncelik sınıfına ait bekleme alanına yönlendirir (tabelada PN/0 ilanı, 0 bekleme alanını temsil etmektedir).

Sistemde bir araç ayrılış olayı $DP(Veh, \mathcal{N})$ gerçekleştiğinde, eğer bekleme alanında sadece tek öncelik sınıfına ait bekleyen araçlar var ise (sadece EX veya NR araçları bekliyorsa) boşalan \mathcal{N} numaralı sunucuya bekleyen araçlar arasında sisteme diğerlerinden en önce gelen aracı tabeladan PN/ \mathcal{N} ilanı ile yönlendirilir ve araç servise başlayan araçlar listesine eklenir ($(servList \leftarrow SS(Veh, \mathcal{N}) \cup servList)$). Ancak $DP(Veh, \mathcal{N})$ olayı gerçekleştiğinde her iki öncelik sınıfına ait bekleyen araçlar var ise boşalan \mathcal{N} numaralı sunucunun hangi öncelik sınıfından araca hizmet vereceğinin belirlenmesi gerekir. Kaynak Yöneticisi bu durumda sunucunun hizmet vereceği öncelik sınıfının belirlenmesi için Kontrolör bileşenini çağırır ve girdi olarak anlık sistem durumunu gönderir. Gönderilen sistem durum değişkenlerinin anlık değerleri, kuyrukta beklemekte olan EX ve NR araçlara ait bilgilerdir. Kontrolör boşalan sunucudan hizmet alacak öncelik sınıfını (kontrol girdisi) belirler. Kaynak Yöneticisi, Kontrolörün gönderdiği kontrol girdisine göre boşalan sunucudan hizmet alacak öncelik sınıfının ilk aracını sunucuya yönlendirir ve aracı $servList$ 'e ekler ($(servList \leftarrow SS(Veh, \mathcal{N}) \cup servList)$).

5.2.2 LSTM bekleme süresi tahmincisi

RL-EXP modelinde kullanılmakta olan LSTM bekleme süresi tahmincisi, sistemden düzenli aralıklarla (TS dakikada bir) bilgi alarak önümüzdeki TS periyodunda sisteme girecek olan EX ve NR araçlara tahmini ortalama bekleme süresi bilgisini verir. Tahmini ortalama bekleme süresi bilgisi hesaplanırken TS dakikada bir güncellenen sistem durum değişkenleri kullanılır. Sistem durum değişkenleri sırasıyla şunlardır: hedef bekleme oranı (φ), şu an kuyrukta bekleyen EX araçların ortalama bekleme süresi (EXQ_{avg}), şu an kuyrukta bulunan EX araç sayısı (EXQ_{count}), kuyrukta bekleyen NR araçların ortalama bekleme süresi (NRQ_{avg}), kuyrukta bekleyen NR araç sayısı (NRQ_{count}) ve boş sunucu sayısı. Bekleme süresi tahmincisi, Uzun Kısa Süreli Bellek (LSTM) metodu ile çalışır. LSTM sıralı gözlemlerden yararlanan ve gelecekteki kalıpları anlamak için önceki zaman-

adımlarından öğrenen özel bir tür Özyinelemeli Sinir Ağı (RNN) yapısıdır. Her TS dakikada bir düzenli aralıklarla kaydedilen anlık sistem durumu değişkenleri, bir Zaman Serisi yapısı yani sıralı gözlemler özelliği göstermektedir. Zaman Serilerinde mevcut zaman adımının çıktısı önceki zaman adımlarına bağlıdır. LSTM, zaman serisinin bu bağımlılık özelliğini çözmek için zaman serisinin önceki adımlarını takip eden geri besleme yapısını kullanabilmektedir. LSTM modeline ait detaylar ve hiper parametreler Bölüm 7’de detaylı olarak paylaşılacaktır.

5.3 Kontrolcü

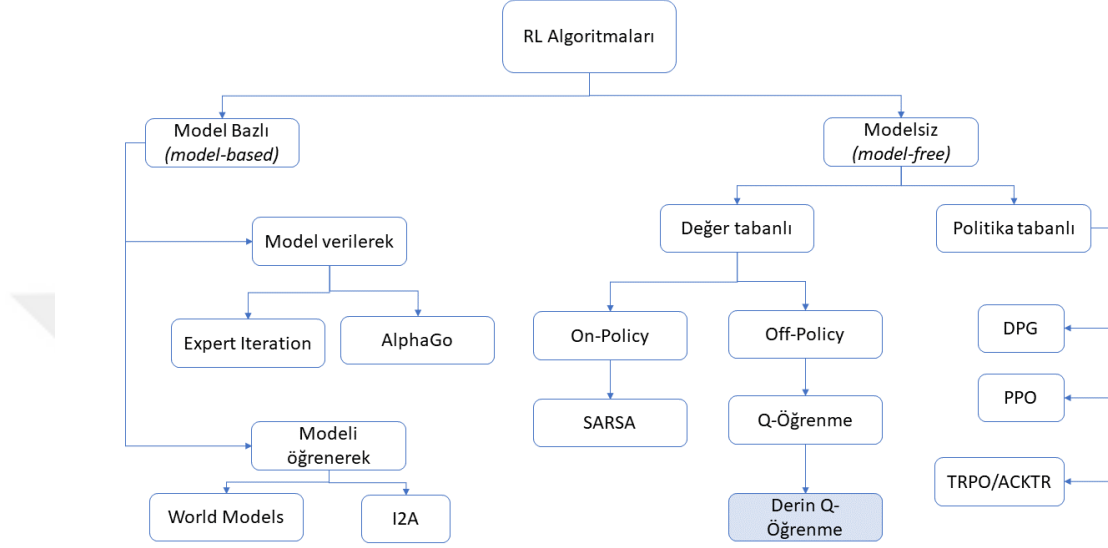
Kontrolcünün görevi, düşük öncelikli araçlar için hedeflenen ortalama bekleme süresi ile ($EX_{bekleme} * \varphi$) gerçekleşen ortalama bekleme süresi ($NR_{bekleme}$) arasındaki sapma değerini ($diff$) 0’a yakın tutmaktır. Kontrolcü bunu sunuculardan hizmet alacak araç öncelik sınıflarını dinamik şekilde gerçek zamanlı değiştirerek yapmayı hedefler. Sistemde her araç ayrılışı olayı ($DP(Veh, \text{ŞN})$) yaşandığında ve her iki öncelik sınıfının da kuyruklarında bekleyen araç var ise (bekleyen hem EX araçlar hem NR araçlar varken) Kaynak Yöneticisi Kontrolörü çağırarak araç ayrılışı olayını ve sistemin anlık durumunu bildirir. Sistemin durum değişkenleri, şunlardır: istasyon görelî hedef bekleme oranı (φ), kuyrukta bekleyen EX ve NR araçların ortalama bekleme süreleri ($EXQavg$ ve $NRQavg$), kuyrukta bekleyen EX ve NR araç sayıları ($EXQcount$ ve $NRQcount$) ve Eşitlik 5.1’de nasıl hesaplandığı gösterilen kuyrukta bekleyen EX ve NR araçların oluşturduğu hedef görelî bekleme oranından sapma değeridir ($diffQ$).

$$diffQ = EXQavg * \varphi - NRQavg \quad (5.1)$$

Kontrolcü, sistemin anlık durum bilgilerini kullanarak Pekiştirmeli Öğrenme tabanlı Derin Q-Öğrenmesi algoritmasını çalıştırır ve boşalan ŞN numaralı sunucudan hizmet alacak araç öncelik sınıfını belirler. Özetle kontrolörün girdisi sistem durum değişkenleri, çıktısı ise istasyonu kontrol etmede kullanılacak kontrol girdisi olan sunucu/sınıf atama bilgisidir. Kullanılan RL-EXP yöntemine dair detaylar Bölüm 5.4’te açıklanmıştır.

5.4 RL-EXP modeli

RL-EXP modeli Pekiştirmeli Öğrenme metodu olan Derin Q-Öğrenme algoritmasını kullanır. Aşağıdaki Şekil 5.2’de görüleceği üzere kullanılan Derin Q-Öğrenme modeli, modelsiz değer tabanlı ve off-policy bir yaklaşımdır.



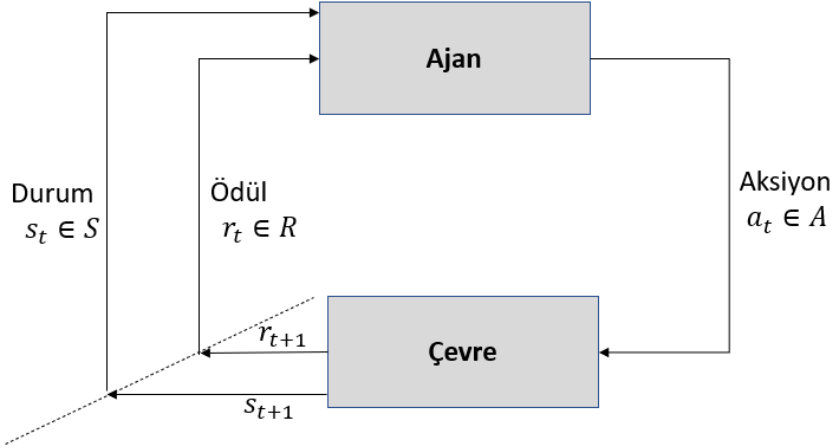
Şekil 5.2: Pekiştirmeli öğrenme algoritma sınıflandırması.

Modelsiz Pekiştirmeli Öğrenme (RL) algoritmalarında model tabanlı algoritmalar gibi ortam dinamikleri modellenmeye çalışılmaz, algoritma çevreyi öğrenmeye gerek duymadan aksiyon alır ve optimal politikaya ulaşır. Model tabansız sınıflandırmanın alt basamağı olan değer tabanlı RL algoritmalarında, her durum ve aksiyon çiftine dair ne kadar iyi olduğunu tanımlayan aksiyon-değer fonksiyonuna göre seçim yapılır. Bölüm 5.4.1’de Pekiştirmeli Öğrenmeye ait teorik detaylar yer almaktadır.

5.4.1 Pekiştirmeli öğrenme (RL)

Pekiştirmeli Öğrenme (RL), makine öğrenmesinde bir algoritma kategorisidir. Pekiştirmeli Öğrenme, etiketlenmiş eğitim verilerini kullanmaması veya herhangi bir etiket keşfetmeye çalışmaması bakımından benzersizdir. Bunun yerine RL yalnızca bir çevreden elde edilen bir ödülü maksimize etmeye odaklanır (Sutton ve Barto, (2018)). Son zamanlarda karmaşık sıralı karar verme süreci problemlerini çözmek için RL oldukça başarılı olarak kabul edilmiştir.

Pekiştirmeli Öğrenme modeli temel olarak ajan (agent), durum değişkenleri (states), aksiyonlar (actions), ödül (reward), çevre veya ortam (environment) bileşenlerinden oluşur. Ajan çevreyi gözlemler ve bu gözleme dayanarak alınan aksiyonları uygular. Ajan ve çevre arasındaki etkileşim Şekil 5.3'te verilmiştir.



Şekil 5.3: Ajan ve çevre etkileşimi.

Ajanın bir gözlem-aksiyon döngüsü bir ayrık zaman adımı (discrete time-step) olarak adlandırılabilir. Ajanın eğitilmesi için gerçekleştirilen her aksiyon sonrası ajana aksiyona ait bir ödül değeri sağlanır. Pozitif ödül değeri eylemin arzu edilen bir eylem olduğuna, negatif ödüller ise daha az olumlu eylemlere işaret eder. Yapılan sıralı aksiyonların getirdiği ödül miktarını toplamak için ajan yapılması belirlenen aksiyonları mevcut duruma uygulayarak ortam ile etkileşime geçer. Bir RL algoritmasının amacı, simülasyonun tamamı boyunca (bu süre bölüm (episode) olarak adlandırılır) toplam ödülü maksimize edecek politikayı öğrenmektir.

Bir RL ortamı şu dördü ile tanımlanır (S, A, R, δ), bunlar:

- S: ortam durum değişkeni vektörü. s belirli bir durumu belirtir ($s \in S$);
- A: Ajanın alabileceği aksiyon vektörü. a bir aksiyonu belirtir ($a \in A$);
- R: Ödül fonksiyonu. $R(s, a) = r$, s durumunda a aksiyonunu almanın ödül miktarının r olduğunu belirtir.

- δ : Bir durum değişkeninden diğer durum değişkenine geçiş olasılığını gösterir. $\delta(s, a) = s'$ ifadesi s durumunda a aksiyonunu aldıktan sonra yeni durumun s' olma olasılığını belirtir.

Ajan ortam ile ayırık zaman adımlarında $t = 0, 1, \dots, T$ etkileşime geçer. T bir bölümün sonlanma zamanını gösterir. Ajan her zaman adımında bir a_t aksiyonu alır ve ortam yeni durum değişkenine geçiş olasılık fonksiyonu $\delta(s_t, a_t) = s_{t+1}$ güncellenir. Ajana mevcut durumda uyguladığı aksiyonun getirisi ödül miktarı ödül fonksiyonu $R(s_t, a_t) = r_t$ ile sağlanır.

Pekiştirmeli öğrenmede amaç tüm zaman adımlarında elde edilen ödül miktarının maksimize edilmesidir. Maksimize edilmesi hedeflenen bu değer beklenen getiri (expected return) olarak adlandırılır ve Eşitlik 5.2'deki gibi hesaplanır:

$$R_t = r_t + \gamma r_{t+1} + \gamma^2 r_{t+2} \dots + \dots = \sum_{k=0}^T \gamma^k r_{k+t} \quad (5.2)$$

Eşitlik 5.4.1'de yer alan γ ($0 \leq \gamma \leq 1$) parametresi azaltma faktörü (discount factor) olarak adlandırılır. Azaltma faktörü, ajanın uzak gelecekteki ve anlık verilecek ödüllere verilecek önemi dengeleyen bir katsayıdır. Eğer $\gamma = 0$ ise ajan tamamen miyopik olacaktır ve yalnızca doğrudan ödül veren aksiyonlara dayalı bir öğrenme gerçekleştirecektir. Tam tersi durumda $\gamma = 1$ olursa ise ajan gelecekteki ödüllerin toplamına dayalı olarak aksiyonlarından her birini değerlendirecektir.

Ajan elde edeceği sıralı ödül miktarlarını kesin olarak bilseydi ek hesaplamalara gerek duyulmazdı. Ancak her bir zaman adımındaki ödül miktarları hem ortamın durum değişkenine hem de ajanın seçtiği aksiyona bağlı durumdadır. Bu sebeple, spesifik aksiyon-durum değişkeni çiftlerinin değerlerini yaklaşık olarak bilmemize yardımcı olan bir aksiyon-değer fonksiyonu tanımlanmıştır. Bu fonksiyon *Q-fonksiyonu* Bellman denklemi olarak adlandırılır ve fonksiyondan elde edilen değerlere de *Q-değerleri* denir. Fonksiyon Eşitlik 5.3'te verilmiştir.

$$Q(s_t, a_t) = \mathbb{E} \left[r_t + \gamma \max_{a'} Q(s_{t+1}, a') \right] \quad (5.3)$$

$Q(s_t, a_t)$ ifadesi s_t durumunda a_t aksiyonunu almanın doğrudan ödül miktarı (immediate reward) ile a_t aksiyonunun alınması ile değişen yeni durumda (s_{t+1}) elde edilecek beklenen maksimum getirisi ve azaltma faktörünün çarpımının toplamıdır. İteratif bir güncelleme süreciyle Q -değerlerini öğrenen pekiştirmeli öğrenme

algoritması Q-Öğrenme olarak adlandırılır. Q-Öğrenme algoritmasına ait detaylar bir sonraki bölümde verilmiştir.

5.4.2 Q-öğrenme

Q-Öğrenme algoritması Q-fonksiyonunu temsil eden bir arama tablosu *Q-Tablosu* oluşturarak başlar. Sonrasında her bir zaman adımı t için aşağıdaki adımlar gerçekleştirilir:

Adım 1: Mevcut durum s_t gözlemlenir

Adım 2: Bir a_t aksiyonu seçilir ve uygulanır

Adım 3: Yeni durum s_{t+1} gözlemlenir

Adım 4: Yapılan a_t aksiyonunun getirdiği doğrudan ödül miktarı elde edilir

Adım 5: Q-Tablosu Eşitlik 5.4'e göre güncellenir

$$Q_t(s_t, a_t) = (1 - \alpha)Q_{t-1}(s_t, a_t) + \alpha \left[r_t + \gamma \max_{a_{t+1}} Q_{t-1}(s_{t+1}, a_{t+1}) \right] \quad (5.4)$$

Eşitlikte yer alan α parametresi öğrenme hızı parametresini (learning rate) gösterir. Öğrenme hızı, ajan tarafından kabul edilecek yeni ve eski bilginin oranını ifade eder. Bir öğrenme oranı olmasaydı, Q-tablosunda yer alan Q-değerleri düzensiz biçimde değişir ve hiçbir zaman yakınsamazdı. Öğrenme oranı α 'nın kullanılmasıyla $Q_t(s, a) \rightarrow Q^*(s, a); t \rightarrow \infty$ kanıtlanabilir (Watkins ve Dayan (1992)). Burada Q^* optimal Q-tablosunu temsil eder.

Durum vektörünün çok boyutlu ve çok büyük olduğu durumlarda, tüm Q-tablosunu hafızada tutmak ve işlemek mümkün bir yöntem olmayabilir. Bu durumda Q-değerlerini bir tabloda tutmak yerine bir fonksiyon yaklaşılama (function approximator) kullanılır. Bu fonksiyon yaklaşılama sıklıkla sinir ağı yapısını almaktadır (Mnih ve diğ. (2013)). Farklı durumlarda alınacak aksiyonlar ve karşılığında elde edilecek değerlerin bir ağ yapısı içinde öğrenildiği bu metot Derin Q-Öğrenmesi olarak adlandırılır. Bu yönteme ait detaylar Bölüm 5.4.3'te verilmiştir.

5.4.3 Derin Q-öğrenmesi

Derin Q-Öğrenmesi, derin sinir ağlarının Q-Öğrenme algoritmasına uygulanması olarak ifade edilebilir. Derin Q-Öğrenme aksiyon-değer tablosu kullanmak yerine derin sinir ağı kullandığı için, parametrize edilmiş Q-Fonksiyonu kullanılır

$Q(s, a; \theta) \approx Q(s, a)$. Burada θ derin sinir ağının parametreleridir. Derin Q-Öğrenmesinde aksiyon uzayı (action space) kesikli değerler, durum uzayı (state space) ise sürekli değerler alabilmektedir. Ağ parametreleri, kaybı minimize edecek yönde güncellenir. Q-değerlerinin iteratif bir güncelleme süreciyle Q-Öğrenmedeki gibi öğrenilmesi yerine Derin Q-Öğrenmesinde kayıp fonksiyonunu minimize eden stokastik gradyan iniş yöntemi (stochastic gradient descent) benimsenir. Kayıp fonksiyonu (loss function) Eşitlik 5.5 ile tanımlanır.

$$L_t(\theta_t) = (y_t - Q(s_t, a_t; \theta_t))^2 \quad (5.5)$$

Eşitlik 5.5'te tanımlanan y_t ise Eşitlik 5.6 ile ifade edilir:

$$y_t = r_t + \gamma \max_a Q(s_{t+1}, a; \theta_t) \quad (5.6)$$

Eğitim boyunca, ajanın seçebileceği en iyi aksiyonun her zaman en yüksek Q-değerine sahip aksiyon değerini seçmek olduğunu düşünürüz. Ancak eğitimin başlangıç anlarında, Q-değeri tahminleri öğrenilen deneyimin değil modelin başlatılmasının ürünüdür. Bu sebeple Q-Öğrenme algoritması ε -açgözlü (ε -greedy) strateji kullanır (Mnih ve diğ. (2013)). Bu stratejide ajan ε olasılığı ile rastgele bir aksiyon seçer. ε parametre değeri eğitimin başlangıcında 1'e yakın bir değer olarak belirlenir. Ve eğitim ilerledikçe bir azaltma faktörü ile çarpılarak Eşitlik 5.7'de belirtildiği şekilde güncellenir.

$$\varepsilon = \varepsilon * (1 - \varepsilon_{decay}) \quad (5.7)$$

Her bir zaman adımında ajan mevcut duruma bağlı olarak sinir ağından elde edilen aksiyon-değere göre epsilon-açgözlü stratejisine dayalı bir aksiyon seçer ve ajanın hafızası olarak adlandırabileceğimiz yeniden oynatma belleğine (replay memory buffer) bu deneyimi (s_t, a_t, r_t, s_{t+1}) bilgileriyle kaydeder. Kaydedilen deneyimlerden örneklemeler (mini-batch) alınarak Q-değeri hesaplanır ve ağ parametreleri kaybı minimize edecek şekilde güncellenir. Şekil 5.4 Derin Q-Öğrenmesine ait adımları göstermektedir.

Algorithm 1 Deneyim Tekrarı ile Derin Q-Öğrenme

```
1: Tekrar hafızası  $D$ 'yi  $N$  kapasite ile başlangıç durumuna getir
2: Aksiyon-değer fonksiyonu  $Q$ 'yu rastgele ağırlıklarla başlangıç durumuna
   getir
3: for  $episode = 1, \dots, M$  do
4:    $s_1$ =rastgele bir durum ile ortam başlangıç durumuna getirilir
5:   for  $t = 1, \dots, T$  do
6:      $\epsilon$  olasılığı ile rastgele bir aksiyon  $a_t$  seç
7:      $1-\epsilon$  olasılığıyla  $a_t = \max_a Q^*(s_t, a; \theta)$ 
8:     aksiyon  $a_t$ 'yi emülatörde uygula  $r_t$  ödülünü ve  $s_{t+1}$  durumunu
       gözlemler
9:      $(s_t, a_t, r_t, s_{t+1})$  deneyimi tekrar hafızası  $D$ 'de tutulur
10:     $D$ 'den rastgele mini-batch deneyim örneklemini alınır
11:     $y_t$  şu şekilde belirlenir:


$$y_t = \begin{cases} r_t, & s_{t+1} \text{ terminal state ise} \\ r_t + \gamma \max_{a'} Q(s_{t+1}, a'; \theta), & s_{t+1} \text{ terminal state değilse} \end{cases}$$


12:    Kaybı hesapla  $(y_t - Q(s_t, a_t; \theta))^2$ 
13:    Kaybı minimize edecek şekilde ağ parametrelerine gradyan iniş
       adımı uygula
14:   end for
15: end for
```

Şekil 5.4: Derin Q-Öğrenmesi algoritmasının sözde kodu.

5.5 Kontrolör Parametrelerinin Belirlenmesi

Tez kapsamında, Ekspres Elektrikli Araç Şarj İstasyonunda Kaynak Yönetimi problemi durum uzayı S , aksiyon uzayı A , geçiş olasılığı T ve ödül fonksiyonu R olarak modellenmiş ve çözüm yaklaşımı olarak model-tabanlı olmayan Derin Pekiştirmeli Öğrenme benimsenmiştir. Tez kapsamında ele alınan problemde, belirtilen S, A, R ve T bileşenleri aşağıdaki şekilde açıklanmıştır.

- Durum uzayı (S): Ajan, boşalan sunucudan hangi öncelik sınıfının hizmet alacağına karar verirken kuyruk durumunu gözetir. Tez kapsamında kullanılan yöntem olan Pekiştirmeli Öğrenmede, ajanın her bir zaman-adımında hangi aksiyonun alınacağına karar verirken gözettiği mevcut durum vektörü sırasıyla şu kuyruk durumu değerlerinden oluşmaktadır; şu an kuyrukta beklemekte olan EX-Araçların tutulduğu kümede ($EXQset$) bulunan araç sayısı ($|EXQset|$), kuyruktaki NR-Araçların tutulduğu kümede ($NRQset$) bulunan NR-Araçların sayısı ($|NRQset|$), kuyrukta beklemekte olan yüksek öncelikli EX-Araçların oluşturduğu ortalama bekleme süresi ($EXQAvWT$), kuyrukta beklemekte olan

düşük öncelikli NR-Araçların oluşturduğu ortalama bekleme süresi ($NRQAvWT$), kuyrukta beklemekte olan EX ve NR araçların oluşturduğu hedef görece bekleme oranından sapma ($diffQ$) ve istasyonun ilan ettiği hedef görece bekleme oranı değeri (φ). Durum uzayı sürekli değerlerden oluşur. Durum vektörünü oluşturan bileşenlerin nasıl hesaplandığı aşağıdaki Eşitliklerde belirtilmiştir.

$$EXQAvWT(t) = \frac{\sum_{vehicle \in EXQset} vehicle_{bekleme}}{|EXQset|} \quad (5.8)$$

$$NRQAvWT(t) = \frac{\sum_{vehicle \in NRQset} vehicle_{bekleme}}{|NRQset|} \quad (5.9)$$

$$diffQ(t) = EXQAvWT * \varphi - NRQAvWT \quad (5.10)$$

- Aksiyon uzayı (A): t zaman adımında, ajanın uygulamaya karar verdiği aksiyon boşalan sunucudan öncelik alacak öncelik sınıfının EX veya NR olması şeklindedir. Aksiyon uzayı EX-Araç sınıfının seçilmesi (1) veya NR-Araç sınıfının seçilmesi (2) olacak şekilde kesikli durumdadır.
- Ödül Fonksiyonu (R): Ajanın sistemin mevcut durumuna bakarak karar verdiği aksiyonun ne gibi bir sonuca sebep olduğunu tanımlayan ödül değeri $R(s_t, a_t)$ fonksiyonu ile hesaplanır. Ödül fonksiyonu Eşitlik 5.11'de belirtilmiştir.

$$R(s_t, a_t) = (|diffQ(t-1)| - |diffQ(t)|) + (bound - |diffQ(t)|) \quad (5.11)$$

Ödül fonksiyonunda, problemde, kaynak yönetimiyle temel olarak amaçladığımız durum olan hedef görece bekleme değerinden sapma miktarını azaltmak (sıfıra olabildiğince yakın tutmak) formüle edilmiştir. Sapma miktarının yönünden yani negatif veya pozitif değerli olmasından çok sıfıra yakınlığı ile ilgilenildiği için, sapma değerinin büyüklüğü yani mutlak değeri önemlidir. Yapılan aksiyon sonucu kuyrukta bekleyen araçların ortalama bekleme sürelerinin oluşturduğu sapmanın büyüklüğü $|diffQ(t)|$, aksiyon alınmadan önceki $|diffQ(t-1)|$ büyüklük değerine göre azalmış olması bu azalma miktarı kadar pozitif ödül değerindedir. Ancak, yapılan aksiyon sonucu sapmanın büyüklüğü önceki zaman-adımına göre arttı ise, bu artış miktarı kadar negatif ödül miktarı yansıtılır.

Problemde amaç, sapmayı sadece azaltacak yönde aksiyonlar almak değil sapmayı sıfıra olabildiğince yaklaştıracak şekilde aksiyonları seçerek kaynakları yönetimini gerçekleştirmektir. Bu sebeple, t zaman-adımında alınan aksiyon ile elde edilen

$|diffQ(t)|$ 'nin bir sınır değerden daha küçük olması pozitif ödül miktarına sebep olacak şekilde $(bound - |diffQ(t)|)$ ifadesi ödül fonksiyonuna eklenmiştir. Burada $bound$ için 0.1, 0.3 ve 0.5 gibi değerler denenmiş ve ajanın en iyi 0.5 değeri ile öğrenme gerçekleştirdiği görülmüştür. Liang ve diğ. (2019) yaptığı çalışmada, toplam bekleme süresini azaltmayı hedeflediği problem için t anı ve $t-1$ zaman-adımındaki değerleri kullanarak bu forma benzer bir ödül fonksiyonu tanımladığını görebiliriz. Ancak, bizim problemimizden farklı olarak Liang ve diğ. (2019) ödül fonksiyonunda kullanılan toplam bekleme süresi metriğinin sıfıra yakın olması gibi bir amaç gütmendiğinden, bizim ödül fonksiyonumuzda yer alan $(bound - |diffQ(t)|)$ ifadesi gibi bir ifadeye yer vermemişlerdir.

- Geçiş Olasılık Fonksiyonu (T): s_t durumundan s_{t+1} durumuna geçiş olasılık fonksiyonu Eşitlik 5.12'deki gibi ifade edilir:

$$s_{t+1} = f(s_t, a_t, \omega_t) \quad (5.12)$$

Durum geçiş olasılığı, sadece aksiyon a_t 'den etkilenmekle kalmaz ayrıca rastgelelikten de (ω_t) etkilenir. Bu rastgeleliğe elektrikli araçların istasyonlara varış zamanları, servis sürelerinin rassallığı, istasyona giriş yapacak aracın öncelik sınıfının rastgeleliği gibi durumlar örnek gösterilebilir. Benimsenen model-tabanlı olmayan metot ile, çevre dinamikleri modellenmeye gerek duyulmaz ve geçiş olasılığı çevreyle etkileşime geçilerek üstü kapalı olarak öğrenilir.

Yukarıda belirtilen aksiyon, durum, ödül fonksiyonu pekiştirmeli öğrenme ortamı ile tanımlanan Derin Q-Öğrenme ajanının öğrenme eylemini gerçekleştirdiği eğitim aşamasında kullanılan parametreler ise aşağıda Çizelge 5.1'de verilmiştir.

Eğitim aşamasında, ajan büyük bir ε değeri ($\varepsilon = 1$) ile iterasyona başlar. ε azaltma faktörü kullanılarak Eşitlik 5.13 denklemi ile her zaman-adımı sonunda ε güncellenir. ε -açgözlü yaklaşımın benimsendiği eğitim aşamasında başlangıçta büyük ε değeri sebebiyle ajan ortamı bir süre keşfeder (exploration), daha sonra ise deneyim kazanmasıyla birlikte sömürü (exploitation) yöntemine başvurur.


$$\varepsilon = \varepsilon * (1 - \varepsilon_{azaltma}) \quad (5.13)$$

Derin pekiştirmeli öğrenme yönteminde, aksiyon-durum çiftlerinin Q-değer fonksiyonuna yaklaşım için derin sinir ağı yapısı kullanılmaktadır.

Çizelge 5.1: RL-EXP derin pekiştirmeli öğrenme metodunun parametre ve değerleri.

Parametre	Değer
Bölüm sayısı	2000
Her bölümdeki maksimum adım sayısı	30
Yeniden oynatma belleği kapasitesi	10000
Mini-Batch büyüklüğü	64
γ ödül azaltma faktörü	0.99
α öğrenme hızı	0.001
Gradyan eşiği	1
Başlangıç ε	1
Bitiş ε	0.0005
ε azaltma faktörü	0.02
Tam bağlantılı katman sayısı	2
Her katmandaki nöron sayısı	24

RL-EXP modeli için kullanılan derin sinir ağı yapısında 2 tam bağlantılı katman ve bu 2 katmanda 24'er adet nöron kullanılmıştır. Aktivasyon fonksiyonu olarak ReLU uygulanmıştır. Giriş katmanı gözlem vektörü Çıkış katmanında ise aksiyon sayısı kadar (2) nörondan oluşan tam bağlantılı katman yapısı kullanılmıştır. Ağ parametrelerinin güncellenmesi için tercih edilen optimize edici olarak Adam seçilmiştir. Ajan her bölümde maksimum 30 adım olacak şekilde 2000 bölüm (iterasyon) boyunca tanımlanan pekiştirmeli öğrenme ortamında eğitilmiştir. Ajanın eğitim aşamasında ortam/çevre her bölümün başında reset fonksiyonu ile sıfırlanmakta ve başlangıç durumuna getirilmektedir. Eğitim sırasında gerçekleşen bu reset aşamasında, ajan her bölümde $[0, 0.1, \dots, 0.9]$ değerleri arasından rastgele seçilen bir p_e ve $[1, 1.1, \dots, 2]$ değerleri arasından rastgele seçilen bir φ ile ve $\rho = 0.95$ doluluk oranı ile eğitilir. Ajan ayrıca, eğitimi sırasında tepki süresi için sisteme 20 adet EX-Aracın hepsinin birden giriş yapması gibi bir durumla hiç karşılaşmaz, araçlar teker teker Üssel dağılıma uygun olarak gelmektedir. Şekil 5.5'te ajanın belirtilen parametreler ve belirtilen koşullarla eğitimi sonucu bölüm sayısına karşılık ortalama ödül miktarı verilmiştir.



Şekil 5.5: Derin pekiştirmeli öğrenme yönteminde ajanın eğitimi aşamasında bölüm sayısına karşılık topladığı ortalama ödül miktarı.

6. RL-EXP KAYNAK YÖNETİM MODELİ PERFORMANS ANALİZİ

RL-EXP modelinin performansı, ekspres şarj istasyonunda kaynak yönetim performansı ve bekleme süresi tahmin performansı olmak üzere iki açıdan analiz edilmektedir.

Bu bölümde, RL-EXP kaynak yönetim performansı sırasıyla Fescioglu-Unver ve diğ. (2021) ile Kakillioglu ve diğ. (2022) tarafından geliştirilen FC-EXP ve SC-EXP metotlarıyla ve sabit sunuculu yönetim (klasik metot olarak anılacaktır) metoduyla karşılaştırmalı olarak verilmektedir. Kaynak yönetim performansı üç açıdan analiz edilmiş ve karşılaştırılmıştır: Kararlı hâlde (uzun vadede) görelî gecikme performansı, gerçek zamanlı görelî gecikme performansı ve sistemde ani değişikliklere karşı tepki süresinin ölçümü ile ilgili karşılaştırmalar sırasıyla Bölüm 6.1, 6.2 ve Bölüm 6.3'te verilmiştir.

Karşılaştırmada farklı araç varış oranları (λ), farklı istasyon doluluk oranları (ρ), farklı istasyonun hedef göreceli bekleme oranları (φ) ve farklı yüksek öncelikli araç oranları (p_e) koşulları altında deneyler yapılmıştır. Kararlı hâlde görelî gecikme performansı, gerçek zamanlı görelî gecikme performansı ve sistemde ani değişikliklere karşı tepki süresi karşılaştırmalarında bu parametrelerin aldıkları farklı değerler Çizelge 6.1'de gösterilmiştir.

Çizelge 6.1: Simülasyon parametrelerinin farklı performans karşılaştırma yönleri için aldığı farklı değerler.

Parametre	Kararlı Hâl	Gerçek Zamanlı	Tepki Süresi
λ ($\frac{\text{araç}}{\text{dakika}}$)	0.58, ..., 0.69 (Üssel)	0.58, ..., 0.69 (Üssel)	0.69 (Sabit)
ρ	0.80, ..., 0.95	0.80, ..., 0.95	0.95
φ	1.0, ..., 2.0	1.5	1.0, ..., 2.0
p_e	0.1, ..., 0.9	0.5	0.5

Geliştirilen RL-EXP kaynak yönetim modeli MATLAB R2021a programı kullanılarak kodlanmıştır. Koşuturumlar Intel Core i5-10300H 2.5GHz işlemcili, 8 GB RAM'e sahip 4 çekirdekli bilgisayarda alınmıştır. Performans analizlerindeki tüm

güven aralığı hesaplamalarında kullanılan α (tip 1 hata olasılığı) değeri 0.10 olarak kabul edilmiştir.

6.1 Kararlı Hâlde Görelî Gecikme Performansı

RL-EXP modelinin kararlı hâl performansı, gerçekleşen görelî gecikme oranı (φ_r) kullanılarak ölçülmüştür. Gerçekleşen görelî gecikme oranı, Eşitlik 6.1’de belirtildiği üzere NR-Araçların ortalama bekleme sürelerinin EX-Araçların ortalama bekleme sürelerine oranını ifade etmektedir. Eşitlikte yer alan t zaman periyodu kararlı hal performansı hesaplamalarında t=1 değerini almaktadır. Bu t=1 tek zaman periyodunun uzunluğu ısınma periyodu hariç simülasyon koşturum uzunluğuna eşittir.

$$\varphi_r(t) = NR_{bekleme}(t)/EX_{bekleme}(t) \quad (6.1)$$

Farklı istasyon doluluk oranı ve farklı istasyon hedef görece bekleme oranı (φ) koşulları altında, yüksek öncelikli araç oranı (p_{EX}) 0.5 iken EX-Araçlar ve NR-Araçlara ait ortalama bekleme süreleri için (EX_b ve NR_b) %95 güven aralığı değerleri Çizelge 6.2’de gösterilmiştir.

Çizelge 6.2: RL-EXP Kararlı durum performansı – $p_e = 0.50$ iken farklı istasyon doluluk oranı ve farklı hedef görece bekleme oranı koşulları altında RL-EXP için gerçekleşen görece bekleme oranı (φ_r) değerleri.

φ	ρ	0.80	0.85	0.90	0.95
1.1	EX_b	1.31 ± 0.05	2.29 ± 0.12	4.42 ± 0.24	12.04 ± 1.01
	NR_b	1.45 ± 0.06	2.59 ± 0.14	4.96 ± 0.25	12.98 ± 1.02
	φ_r	1.10 ± 0.01	1.13 ± 0.01	1.13 ± 0.01	1.08 ± 0.01
1.3	EX_b	1.16 ± 0.04	2.08 ± 0.11	3.95 ± 0.23	11.59 ± 0.89
	NR_b	1.52 ± 0.06	2.72 ± 0.15	5.19 ± 0.29	14.76 ± 1.11
	φ_r	1.31 ± 0.01	1.31 ± 0.01	1.31 ± 0.009	1.28 ± 0.009
1.5	EX_b	1.14 ± 0.04	1.98 ± 0.08	3.83 ± 0.29	10.99 ± 1.33
	NR_b	1.64 ± 0.06	2.90 ± 0.12	5.64 ± 0.41	16.10 ± 1.89
	φ_r	1.44 ± 0.01	1.46 ± 0.01	1.47 ± 0.01	1.47 ± 0.01
1.7	EX_b	1.04 ± 0.05	1.70 ± 0.07	3.42 ± 0.19	9.25 ± 0.93
	NR_b	1.77 ± 0.06	2.94 ± 0.13	5.78 ± 0.32	15.62 ± 1.59
	φ_r	1.71 ± 0.02	1.73 ± 0.02	1.69 ± 0.01	1.68 ± 0.009

Sonuçlara göre, RL-EXP kaynak yönetim modeliyle farklı istasyon doluluk oranı koşulları altında elde edilen gerçekleşen görece bekleme değerlerinin (φ_r) hedef görece bekleme oranlarını (φ) oldukça yakın değerler ile takip ettiği görülmektedir.

Spesifik olarak, hedef değere en az yakın φ_r değerleri hedef değer 1.5 iken ölçülmüştür. Diğer hedef değerlerde gerçekleşen görece bekleme oranı değerleri 1.5'e göre daha yakın olduğu gözlemlenmiştir. Doluluk oranı değişimine karşı da RL-EXP başarılı yanıt vermektedir. İstasyon doluluk oranı 0.80, 0.85 ve hatta 0.90'ı bulduğunda φ ve φ_r değerlerinin birbirine oldukça yakın olduğu görülmektedir. Doluluk oranı 0.95'e yükseldiğinde ise bazı hedef görece bekleme oranı değerlerine göre gerçekleşen bekleme oranının az da olsa hedeften saptığı görülmüştür.

Ortalama bekleme süreleri incelendiğinde, arzulandığı gibi yüksek öncelikli EX-Araçlarını düşük öncelikli NR-Araçlara göre daha az bekletme politikasının başarıyla izlendiği görülmektedir.


RL-EXP'nin performansını $\rho = 0.95$ seviyesinde daha detaylı incelemek için farklı istasyon hedef görece bekleme oranları (φ) ve EX-Araç oranlarıyla (p_e) deneyler yapılmıştır. Detaylı analiz için hedef görece bekleme oranından sapma miktarı ölçütü ($diff$) kullanılmıştır. Her bir simülasyon replikasyonunun çıktısı olarak hesaplanan değer $diff_{run}$ olarak Eşitlik 6.2'de ifade edilmiştir. Eşitlik 6.3'te ise performans kıyaslamasında kullanacağımız ortalama sapma miktarı \widehat{diff} gösterilmiştir.

$$diff_{run} = EX_{bekleme}(t) \times \varphi - NR_{bekleme}(t) \quad (6.2)$$

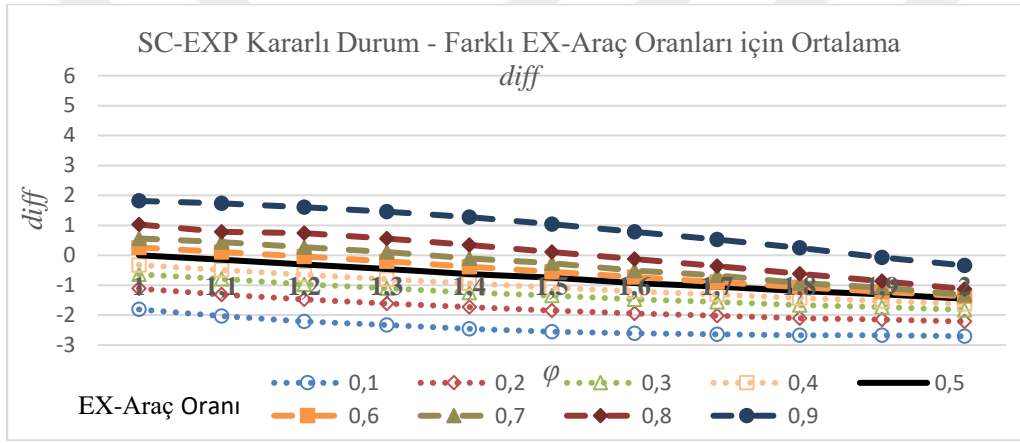
$$\widehat{diff} = \frac{\sum_{run=1}^{totRun} diff_{run}}{totRun} \quad (6.3)$$

Gerçekleşen görece bekleme oranının hedef görece bekleme oranı değerinde tutulmaya çalışılması, \widehat{diff} sapma değerinin sıfıra yakın değerler alması anlamına gelir. Aşağıda verilen Şekil 6.1'de sırasıyla (a), (b) ve (c)'de $\rho = 0.95$ iken RL-EXP, SC-EXP ve FC-EXP modellerined \widehat{diff} değerlerinin farklı φ ve p_{EX} koşulları altında aldığı değerler gösterilmiştir. Şekil 6.1 (a), (b) ve (c)'de yatay eksen φ değerlerini dikey eksen ise \widehat{diff} değerlerini ifade etmektedir. Şekildeki grafiklerde yer alan her bir çizgi farklı p_e oranlarına ait sonuçları ifade etmektedir ve hangi p_e değerine karşılık geldiği Şekil 6.1 üzerinde belirtilmiştir.


Pozitif $diff$ değeri EX-Araçların planlanandan daha uzun beklediğini gösterirken negatif $diff$ değeri NR-Araçların planlanandan daha çok beklediğini gösterir.



(a)



(b)



(c)

Şekil 6.1: (a) RL-EXP, (b) SC-EXP (c) FC-EXP Kararlı durum performansı – $\rho = 0.95$ iken farklı EX-Araç oranları (p_e) ve farklı hedef görece bekleme oranları (φ) için \overline{diff}

Şekilde görüldüğü üzere, \widehat{diff} değeri 0,85 ve -0,78 dakika değerleri arasında yayılım göstermektedir. Maksimum pozitif ve negatif \widehat{diff} değerleri EX-Araç oranının $p_e = 0.10$ ve $p_e = 0.90$ olmak üzere uç değerleri aldığı noktalarda gözlemlenmiştir. Şekil 6.1’de görüldüğü üzere RL-EXP’ye ait \widehat{diff} değerlerinin 0’a yakın biçimde yayılım göstermesi, hedef değerden sapma miktarının sıfıra yakın tutulmaya çalışılması amacıyla paralellik göstermektedir.

Şekil 6.1’de yer alan grafiklerde görülmektedir ki, hem SC-EXP hem FC-EXP modellerine ait sonuçlarda farklı p_e ve φ koşulları altında \widehat{diff} RL-EXP modeline göre daha geniş bir aralıkta yayılım göstermektedir. FC-EXP modelinde maksimum \widehat{diff} değeri 5.36, SC-EXP modelinde -2.7 seviyesinde iken RL-EXP yöntemine ait bu en büyük sapma değeri 0.85’tir.

RL-EXP metodu, $\rho = 0.95$ ve $p_e = 0.50$ durumunda sabit sunucu (klasik), SC-EXP ve FC-EXP metotlarıyla farklı φ hedef değerleri altında detaylı olarak kıyaslanmıştır. Her iki öncelik sınıfına ait ortalama bekleme süreleri ve gerçekleşen bekleme oranı değerleri Çizelge 6.3’te verilmiştir.

Çizelge 6.3: Kararlı durum performansı – $\rho = 0.95$ ve $p_e = 0.50$ durumunda RL-EXP ile diğer metotların kıyaslaması – farklı hedef görece bekleme oranlarına ait gerçekleşmiş görece bekleme oranları (φ_r)

φ		RL-EXP	Sabit Sunucu	FC-EXP	SC-EXP
1.1	EX_b	12.04 ± 1.01	11.79 ± 0.71	11.54 ± 0.96	11.37 ± 0.66
	NR_b	12.98 ± 1.02	12.23 ± 0.81	12.72 ± 1.05	12.66 ± 0.73
	φ_r	1.08 ± 0.01	1.04 ± 0.051	1.10 ± 0.007	1.11 ± 0.005
1.3	EX_b	11.59 ± 0.89	5.75 ± 0.17	10.52 ± 0.88	10.25 ± 0.60
	NR_b	14.76 ± 1.11	18.24 ± 1.25	13.73 ± 1.13	13.78 ± 0.89
	φ_r	1.28 ± 0.009	3.14 ± 0.15	1.31 ± 0.008	1.345 ± 0.007
1.5	EX_b	10.99 ± 1.33	5.75 ± 0.17	9.67 ± 0.81	9.31 ± 0.54
	NR_b	16.10 ± 1.89	18.24 ± 1.25	14.57 ± 1.2	14.72 ± 0.85
	φ_r	1.47 ± 0.01	3.14 ± 0.15	1.51 ± 0.01	1.58 ± 0.008
1.7	EX_b	9.25 ± 0.93	3.87 ± 0.08	8.94 ± 0.75	8.51 ± 0.495
	NR_b	15.62 ± 1.59	20.12 ± 1.33	15.30 ± 1.26	15.51 ± 0.90
	φ_r	1.68 ± 0.009	5.17 ± 0.27	1.71 ± 0.01	1.82 ± 0.009

Kıyaslamada kullanılan klasik metotta yüksek öncelikli EX-Araçlara hizmet verecek sabit sunucu sayısı, 1.1, 1.3, 1.5 ve 1.7 hedef görece bekleme oranı değerleri için sırasıyla 7, 8, 8 ve 9 olarak belirlenmiştir. Klasik metotta $\varphi = 1.3$ ve 1.5 için EX-Araçlara hizmet verecek sunucu sayısının aynı (8) kullanılmıştır. Ancak bu sayının 7 veya 9 olarak değiştirilmesinin de gerçekleşen görece bekleme oranının Çizelge 6.3'te görüldüğü üzere RL-EXP seviyesinde iyileştiremediği görülmüştür. RL-EXP metodu, klasik metoda göre hedef bekleme oranını çok daha yakın şekilde tutturmaktadır.

Hedef görece bekleme oranı değeri arttıkça, gerçekleşen görece bekleme oranının hedeflenen değerden sapması SC-EXP modelinde RL-EXP modeline göre daha fazladır. 0.95 istasyon doluluk oranında, RL-EXP tatmin edici ve FC-EXP ile de neredeyse başa baş düzeyde bir performans göstermektedir.

RL-EXP yönteminin istasyon doluluk oranı 0.95 iken diğer yöntemlere göre daha güçlü yanı olan durum ise EX-Araç oranı ve hedef bekleme oranı değerlerinin uç değerler aldığı durumlardır. Çizelge 6.4, $\rho = 0.95$ koşulu altında, hedef görece bekleme oranının (φ) ve EX-Araç oranının (p_{EX}) uç değerler aldığı noktalarda RL-EXP metoduna ait \overline{diff} değerlerini FC-EXP ve SC-EXP ile kıyaslamaktadır.

Çizelge 6.4: RL-EXP Kararlı durum performansı- $\rho = 0.95$ iken uç noktalardaki \overline{diff} değerlerinin FC-EXP ve SC-EXP ile kıyaslanması

φ	p_e	RL-EXP	FC-EXP	SC-EXP
1.0	0.1	0.64	-1.99	1.809
1.0	0.9	-0.52	2.01	-1.815
2.0	0.1	-0.11	-2.53	-2.704
2.0	0.9	-0.78	5.36	-0.34

φ ve p_{EX} parametrelerinin uç noktalarda değer aldığı sistem koşullarında, sistemin gerçekleşen bekleme oranını hedef değerde tutması zorlayıcı olabilmektedir. Ancak Çizelge 6.4'te de görüldüğü gibi bu zorlayıcı sistem koşullarında, RL-EXP modeli FC-EXP modelinden tüm uç değer durumlarında daha iyi performans göstermektedir. Bu karşılaştırmada RL-EXP ve FC-EXP metotlarının \overline{diff} değerleri arasındaki farkın 5 dakikaya ulaşabildiği görülmektedir.


RL-EXP ve SC-EXP modeli kıyaslandığında ise $\varphi = 2.0$, $p_{EX} = 0.9$ durumunda RL-EXP 0,44 dakika fark ile daha az iyi performans göstermiştir. Ancak diğer her 3 durumda en yüksek fark 2.7 dakikaya yakın bir değer olmak üzere RL-EXP çok daha iyi performans göstermektedir.

6.2 Gerçek Zamanlı Görelî Gecikme Performansı

RL-EXP yönteminin performansı ve diğer modeller ile karşılaştırılmasında, belirli bir zaman penceresi içerisinde bekleme eylemini sonlandırıp servis almaya başlayan araçlara ait ortalama bekleme süreleri ölçütü kullanılmıştır. Gerçek zamanlı performans için ortalama bekleme süreleri, 1.5 dakika kayan 9 dakika uzunluğunda pencere ile ölçülmüştür. Yani, $t=1$ için $EX_{bekleme}(1)$ ile $[0,9]$ dakikalık pencerede servis almaya başlayan EX-Araçların ortalama bekleme süresi ifade edilmektedir. Aynı şekilde $EX_{bekleme}(2)$ ise, $[1.5, 10.5]$ dakika penceresi içerisinde servis almaya başlayan EX-Araçların ortalama bekleme süresini göstermektedir.

Aşağıda Şekil 6.2’de, tek bir replikasyonunun $[10579, 11115]$ ’inci zaman periyotlarına ait ($[15907,15507]$ ’inci dakika penceresi) $EX_{bekleme}(t)$ ve $NR_{bekleme}(t)$ gösterilmektedir. Gösterilen ortalama bekleme süreleri, $\varphi = 1.5$ ve $p_e = 0.5$, $\rho = 0.95$ koşulları altında ölçülmüştür. Kesikli çizgi $NR_{bekleme}$ ’yi düz çizgi ise $EX_{bekleme}$ ’yi göstermektedir. Eğer verilen bir t zaman periyodu içerisinde, bir öncelik sınıfından hiçbir araç beklemesini tamamlayamazsa (şarj olmaya başlayamazsa) o öncelik sınıfının gecikme süresi bu t süresince grafikte 0 olarak çizilir. Şekil 6.2, RL-EXP modeli ile ortamdaki değişikliklere etkin yanıt verilebildiği ve hedef görece bekleme değerinin gerçek zamanlı olarak izlenebildiğini göstermektedir.

Çizelge 6.5’te t ’ninci 9 dakikalık kayan pencereye ait ortalama bekleme süreleri olan $EX_{bekleme}(t)$ ve $NR_{bekleme}(t)$ ’nin oluşturduğu gerçek zamanlı $diff(t)$ analiz edilmektedir. Bir t zaman penceresinde, eğer iki öncelik sınıfından herhangi birinden veya öncelik sınıflarının her ikisinden hiçbir araç bu t zaman penceresi içerisinde bekleme eylemlerini sonlandırıp şarj olmaya başlamadıysa $diff(t)$ sıfır olarak kabul edilmektedir.



Şekil 6.2:Gerçek zamanlı performans – $\varphi = 1.5$, $p_e = 0.5$ ve $\rho = 0.95$ koşulları altında 9 dakikalık zaman penceresinde $EX_{bekleme}(t)$ ve $NR_{bekleme}(t)$

$diff(t)$ ölçümü ısınma periyodunun sonunda (w periyodu) başlar ve simülasyon süresinin sonuna ($simUzunluk$) kadar devam eder. \overline{diff}_{rep} her bir replikasyon için $diff(t)$ lerin ortalamasını, \overline{diff} ise her bir replikasyonun ortalamaları olan \overline{diff}_{rep} lerin toplam replikasyon sayısı üzerinden ortalamasını ifade eder. \overline{diff}_{rep} ve \overline{diff} , \overline{Min} , \overline{Max} hesaplanması sırasıyla Eşitlik 6.4, Eşitlik 6.5 ve Eşitlik 6.6 ile Eşitlik 6.7'e gösterilmiştir.

$$\overline{diff}_{rep} = \frac{\sum_{t=w}^{simUzunluk} diff(t)}{(simUzunluk-w)} \quad \forall rep, rep \in \{1, \dots, totRep\} \quad (6.4)$$

$$\overline{diff} = \frac{\sum_{repl=1}^{totRep} \overline{diff}_{rep}}{totRep} \quad (6.5)$$

$$Min_{rep} = \min_{t=w \dots simUzunluk} (diff(t)) \quad \forall rep, rep \in \{1, \dots, totRep\} \quad (6.6)$$

$$\overline{Min} = \frac{\sum_{repl=1}^{totRep} Min_{rep}}{totRep} \quad (6.7)$$

Çizelge 6.5'te RL-EXP'ye ait %95 güven aralığında \overline{diff} , minimum ve maksimum $diff(t)$ değerlerinin tüm koşuturumlar üzerinden ortalaması olan \overline{Min} , \overline{Max} değerleri gösterilmiştir. Farklı istasyon doluluk oranı koşulları altında RL-EXP ve diğer 3 yöntemin sonuçları gerçek zamanlı görel gecikme performans karşılaştırılması için verilmiştir. Sonuçları gösterilen sabit sunuculu klasik metotta

EX-Araçların kullandığı sabit sunucu sayısı 8'dir. Tüm testler ortam koşulları $\varphi = 1.5$ ve $p_{EX} = 0.5$ iken gerçekleştirilmiştir.

Çizelge 6.5'te görüldüğü üzere, RL-XP ortalama gerçek zamanlı *diff* değerini tüm istasyon doluluk oranı koşulları altında çok düşük seviyelerde tutabilmiştir. Özellikle, doluluk oranları 0.80, 0.85 ve 0.90 iken *diff* değeri 0 değerine oldukça yakın değerlerde tutulmuştur.

Çizelge 6.5: Gerçek Zamanlı Performans – $\varphi = 1.5$, $p_{EX} = 0.5$ ve farklı istasyon doluluk oranları koşulu altında RL-EXP ve SC-EXP, Klasik, FC-EXP yöntemi için \overline{diff} , \overline{Min} , \overline{Max} değerleri

ρ	Yöntem	\overline{diff}	\overline{Min}	\overline{Max}
0.95	RL-EXP	0.31 ± 0.05	-23.81 ± 2.19	33.65 ± 4.11
	SC-EXP	-0.72 ± 0.05	-27.34 ± 1.40	20.6 ± 0.90
	Klasik	-9.29 ± 1.00	-123.07 ± 10.58	45.03 ± 2.55
	FC-EXP	-0.28 ± 0.03	-39.24 ± 3.00	32.93 ± 2.26
0.90	RL-EXP	0.06 ± 0.01	-15.11 ± 1.12	19.39 ± 1.95
	SC-EXP	-0.17 ± 0.018	-20.38 ± 0.65	16.94 ± 0.79
	Klasik	-1.26 ± 0.18	-60.38 ± 3.95	34.97 ± 2.46
	FC-EXP	-0.19 ± 0.01	-29.73 ± 2.13	24.53 ± 1.40
0.85	RL-EXP	0.04 ± 0.009	-11.87 ± 0.87	15.55 ± 1.34
	SC-EXP	-0.01 ± 0.01	-14.94 ± 0.77	12.93 ± 0.67
	Klasik	-0.1 ± 0.05	-37.73 ± 2.58	29.15 ± 1.99
	FC-EXP	-0.1 ± 0.01	-21.87 ± 1.62	19.34 ± 1.22
0.80	RL-EXP	0.03 ± 0.006	-10.56 ± 0.63	13.10 ± 0.83
	SC-EXP	0.03 ± 0.006	-12.4 ± 0.58	12.15 ± 0.57
	Klasik	0.09 ± 0.03	-28.00 ± 2.45	24.01 ± 1.56
	FC-EXP	-0.07 ± 0.01	-18.97 ± 1.75	15.94 ± 0.99

4 farklı doluluk oranı koşulu altında elde edilen *diff* değerleri diğer 3 yöntemle elde edilen *diff* değerlerinden daha düşüktür, yalnızca $\rho = 0.85$ iken RL-EXP metoduna ait *diff* değeri SC-EXP'den az bir fark ile daha büyüktür (0.04 ve 0.01).

İstasyon doluluk oranı arttıkça \overline{diff} değerinin de arttığı tüm yöntemler için gözlemlenmiştir. İstasyon doluluk oranı %95 olduğunda RL-EXP modelinde \overline{diff} diğer doluluk oranlarına göre kendisinin en büyük değeri olan 0.31 değerini

almaktadır. Ancak bu değer, SC-EXP ve klasik yöntemin \overline{diff} değerinden çok daha düşük FC-EXP yöntemine ait değer büyüklüğüne ise ($|-0.28|$) oldukça yakındır.

\overline{Min} ve \overline{Max} değerlerinin mutlak değerleri istasyon doluluk oranının azalışı ile azalmaya ve 0'a yaklaşmaya başladığı görülmektedir. RL-EXP yöntemi kullanılarak elde edilen \overline{Min} sonuçları incelendiğinde, tüm koşullar altında RL-EXP yöntemiyle elde edilen \overline{Min} mutlak değerleri, klasik yöntem, SC-EXP ve FC-EXP sonuçlarından daha küçük değerlere sahiptir. \overline{Max} değerleri incelendiğinde ise, RL-EXP yönteminin tüm koşullarda klasik yöntemden daha iyi performans gösterdiği görülür. \overline{Max} değerlerine göre RL-EXP yönteminin SC-EXP yöntemine göre tüm doluluk oranı koşulları altında oldukça yakın performans gösterdiği çıkarımı yapılır. Yalnızca $\rho = 0.95$ koşulu altında elde edilen değer arasındaki fark diğer ρ değerlerine göre biraz daha fazladır.

RL-EXP ve FC-EXP kıyaslanmak istenirse, RL-EXP modelinin 0.95 doluluk oranında FC-EXP ile benzer \overline{Max} değerini aldığı görülürken diğer 3 doluluk oranı koşulu altında FC-EXP yönteminden daha iyi performans göstermiştir.


Kısaca gerçek zamanlı performans karşılaştırmasına dair sonuçlar göstermektedir ki, RL-EXP yöntemi tüm koşullar altında klasik yöntemden daha iyi performans göstermektedir. RL-EXP tüm koşullar altında FC-EXP yönteminden daha iyi \overline{diff} performansına sahiptir. $\rho = 0.95$ ve $\rho = 0.90$ şartları altında RL-EXP yine SC-EXP yönteminden de daha iyi \overline{diff} performansı göstermiştir $\rho = 0.85$ ve $\rho = 0.80$ istasyon doluluk oranlarında ise SC-EXP ile benzer performans göstermektedir. Bunların yanında, tüm koşullar altında RL-EXP metoduyla hem FC-EXP hem SC-EXP yönteminden daha küçük \overline{Min} değerleri elde edilmiştir. \overline{Max} değerleri açısından ise, tüm koşullar altında FC-EXP yönteminden daha iyi performans gösterilirken SC-EXP ile yakın performans gösterilmiştir.

6.3 Tepki Süresi Performansı

Tepki süresi, sisteme bir basamak girişi uygulandığında nihai çıktı değerinin belirli bir aralığa girmesi ve bu aralıkta kalması için gereken süre olarak tanımlanmaktadır (Ogata ve Yang, 2002). RL-EXP modelinde, tepki süresi ölçütü için koşturumun 15000'inci dakikasında istasyona ek olarak 20 EX-Araç gönderilerek anlık bir etki

yaratılır. Tepki süresi ölçümü için test koşulları Çizelge 6.1’de verilmiştir ve test parametreleri şu değerleri almaktadırlar; $\rho = 0.95$, $\varphi = 1, \dots, 2$ arasındaki tüm değerler, $p_e = 0.5$ ve $\lambda = 0.69 \frac{\text{araç}}{\text{dakika}}$ (sabit).

Aşağıda Şekil 6.3’te, $\varphi = 1.5$ durumunda RL-EXP modelinin sistemde yaratılan ani etkiye yanıtı görülmektedir. Yatay eksen sistem zamanını, dikey 1.5 dakikalık periyotlarla ölçülmüş olan 30 koşturum üzerinden ortalaması alınan $diff_Q(t)$ göstermektedir. Kesikli çizgi %95 güven aralığı sınırlarını göstermekteyken, düz çizgi ortalama değeri ifade etmektedir. Tepki süresi performans ölçümü için kullanılan sabit varış zamanı test koşulu altında, tüm modeller için (RL-EXP, FC-EXP, klasik ve SC-EXP) ortalama $diff_Q(t)$ ani etkiden önce 0.25 civarındadır. Şekil 6.3’te $t = 15000$ ’inci dakikada 20 EX-Aracın sisteme aniden giriş yapmasıyla birlikte ortalama $diff_Q(t)$ 13 dakikaya çıkar.

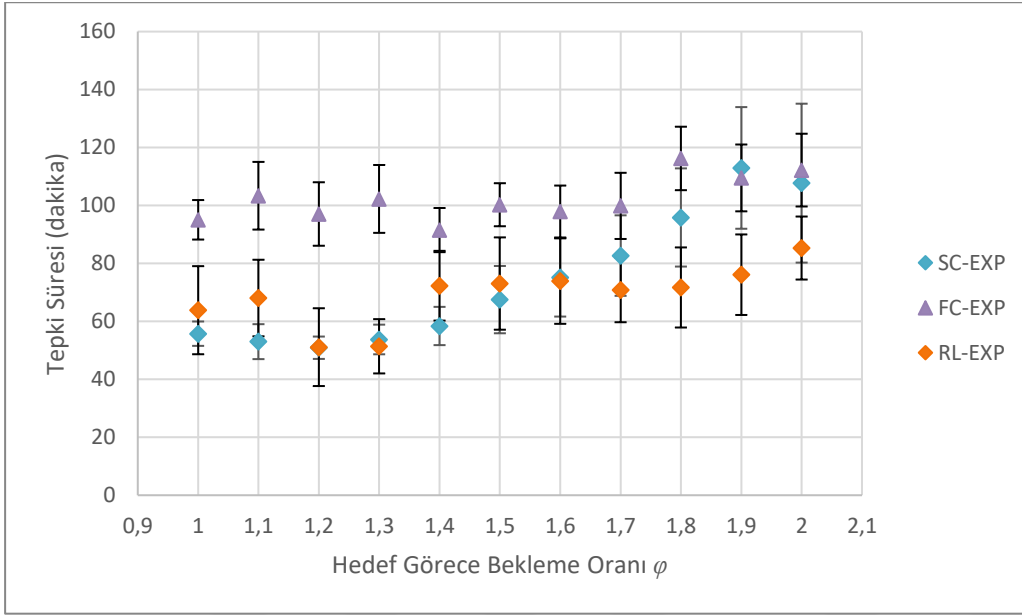


Şekil 6.3: Tepki süresi performansı – 20 EX-Araç varışının ortalama $diff_Q(t)$ üzerindeki etkisi ($\rho = 0.95$, $p_{EX} = 0.5$, $\varphi = 1.5$)

Şekil 6.4, RL-EXP yönteminin $\rho = 0.95$ ve $p_e = 0.5$ durumunda farklı hedef görece bekleme oranı koşulları altında ortalama tepki süresini göstermektedir. Eğer ortalama $diff(t)$ değeri en az 20 ardışık zaman periyodu başka bir deyişle 30 dakika süresince $[-6,6]$ aralığında kalmayı başarıyorsa, sistemin dengeye ulaştığı kabul edilmiştir. Ek olarak SC-EXP ve FC-EXP için de tepki süresi performansları Çizelge 6.11’de performans karşılaştırması için gösterilmiştir. Şekilde noktalar 30 koşturum

üzerinden alınan ortalama tepki süresini, çizgiler ise %95 güven aralığı sınırlarını ifade etmektedir.

Sabit sunuculu klasik metot için tepki süresi en düşük 300 ± 20 dakika ile hedef görece bekleme oranı 1.3 iken, en yüksek 470 ± 20 dakika ile hedef görece bekleme oranı 1.1 değerini aldığında gerçekleşmiştir.



Şekil 6.4: Tepki süresi performansı – Farklı hedef görece bekleme oranları için %95 güven aralığı ile tepki süresi karşılaştırması ($\rho = 0.95$, $p_e = 0.5$)

Şekil 6.4'te, hedef görece bekleme oranı 1 değerinden 2'ye doğru gittikçe RL-EXP yönteminin ortalama tepki süresi değeri 63'ten 85'e çıkmaktadır. Klasik metodun ortalama tepki süresi ise en düşük hedef görece bekleme oranında 448 ile başlar ve hedef görece bekleme oranı 2 olduğunda 452 olmuş durumdadır. FC-EXP modelinde ise $\phi = 1$ durumunda tepki süresi 95 iken $\phi = 2$ olduğunda bu değer 112'ye çıkmaktadır. SC-EXP modelinin ise $\phi = 1$ 'den 2'ye doğru değiştiğinde 55'ten 112'ye çıkmaktadır. Sonuçlar incelendiğinde RL-EXP FC-EXP'ye göre tüm hedef bekleme oranları koşullarında daha kısa sürede reaksiyon göstermektedir. RL-EXP ve SC-EXP kıyaslandığında ise, $\phi = 1, 1.1$ ve 1.4 hedef bekleme oranlarında da oldukça yakın performans gösterirlerken bu değerler dışındaki hedef bekleme oranlarında RL-EXP'nin daha kısa ortalama tepki süresine sahip olduğu söylenebilir. Sonuçlar bütünüyle göstermektedir ki RL-EXP modeli beklenmeyen yoğunluk durumlarında dahi istasyonu kontrol altında tutabilmektedir.

7. BEKLEME SÜRESİ TAHMİNİ

Bu bölümde, RL-EXP modelinin Sistem Yöneticisi alt bileşeninden birisi olan ve Bölüm 5.2.2’de tanımlanan Bekleme Süresi Tahmincisine ait tahmin algoritmasının nasıl geliştirildiği ve çalışma mekanizması detaylı olarak anlatılacaktır.

Ele alınan ekspres şarj istasyonu modelinde, sisteme önümüzdeki TS dakika içinde giriş yapacak EX ve NR-Araçlar için ortalama kuyrukta bekleme süresi tahmini sunulması planlanmıştır. Tahmin için İleri Beslemeli Yapay Sinir Ağı (YSA) ve Uzun Kısa Süreli Bellek (LSTM) tabanlı olmak üzere iki yöntem geliştirilmiş ve karşılaştırılmıştır. Performans analizi sonucunda LSTM tabanlı model seçilerek RL-EXP modeline dahil edilmiştir.

İstasyona önümüzdeki TS dakika içinde varmayı düşünen araçların sürücülerine ortalama ne kadar süre bekleyeceklerinin bilgisinin tahmin edilip verilmesi, sürücülerin bekleme süresine dair endişelerini giderebilir. Rekabetçi bir ortamda ise kullanıcıların bu bilgiye sahip olması istasyonu tercih etmelerinin sebebi olabilir.

Literatürde bekleme süresine dair öngörüle bulunmak için elektrikli araçların şarjına yönelik çalışmalar mevcut değildir. Ancak hastane ve banka gibi alanlarda kullanılan bazı tahmin metotları vardır ve bu çalışmalarda makine öğrenmesi yöntemlerinin kullanıldığı da görülmüştür. Bu tez kapsamında, yapay sinir ağları (YSA) ve LSTM yöntemleri tercih edilmiş ve birbiriyle kıyaslanması amaçlanmıştır. Nihai olarak LSTM’in daha iyi performans gösterdiği açığa çıkmış ve sisteme entegre edilen Bekleme Süresi Tahmincisinin tahmin algoritması LSTM olarak seçilmiştir.

Geliştirilen LSTM ve Yapay Sinir Ağı tahmin modelleri MATLAB R2021a programı kullanılarak kodlanmıştır. Koşuturumlar Intel Core i5-10300H 2.5GHz işlemcili, 8 GB RAM’e sahip 4 çekirdekli bilgisayarda alınmıştır.

Bölüm 7.1’de, yapay sinir ağları ile ilgili altyapı için bazı teorik bilgilere yer verilmiştir. Bölüm 7.2’de ise Uzun Kısa Süreli Bellek Sinir Ağı yapısıyla alakalı teorik bilgiler anlatılmıştır. Bölüm 7.3 de eğitim veri setinin nasıl hazırlandığı anlatılmaktadır. 7.4 ve 7.5 de sırasıyla her iki modelin geliştirilmesi, parametrelerin

belirlenmesi ve eğitim performansına yer verilmiştir. Son olarak 7.6 da model kullanılarak elde edilen sonuçlara yer verilmiş ve performans analizi yapılmıştır.

7.1 Yapay Sinir Ağları

Sinir ağları, daha da spesifik olmak istenirse yapay sinir ağları bir dizi algoritma ile insan beynine benzer özellikler dikkate alınarak modellenmiştir (McCulloch ve Pitts, (1943).

En temel seviyede bir sinir ağı, 5 temel bileşenden oluşmaktadır: bunlar girdiler, ağırlıklar, toplama/birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktı olarak sıralanır (Öztemel, 2003). Ağırlıklar bir girdinin önemini, nöron üzerindeki etkisini gösterir ancak pozitif veya negatif olması ya da büyük veya küçük olması etki değerlerinin önemsiz olduğunu göstermez. Ağırlığın sıfır olması durumu herhangi bir etkinin olmadığını göstermektedir (Haykin (1994)). Kullanılan aktivasyon fonksiyonu, ağırlık girdi ve çıktı birimleri arasındaki ilişkinin oluşturulmasını sağlamaktadır (Hwang ve Ding, (1997)). Bu sebeple aktivasyon fonksiyonunun seçimi performans için önemli bir kriterdir. Aktivasyon fonksiyonu sonucuna göre, çıktı değerleri genellikle $[-1,1]$ veya $[0,1]$ arasında olmaktadır ve genellikle doğrusal olmayan fonksiyonlar kullanılır.

Doğrusal olmayan aktivasyon fonksiyonları yapay sinir ağlarının karmaşık problemlerin çözümünde uygulanabilirliğini artırmayı sağlamıştır. Çoğunlukla kullanılan 4 aktivasyon fonksiyonu vardır ve Şekil 7.1'de bu fonksiyonlar gösterilmiştir. En yaygın kullanılan sigmoid ve hiperbolik tanjant fonksiyonunun denklemleri ise sırasıyla Eşitlik 7.1 ve Eşitlik 7.2'de verilmiştir.

$$f(z) = \frac{1}{1+e^{-z}} \quad (7.1)$$

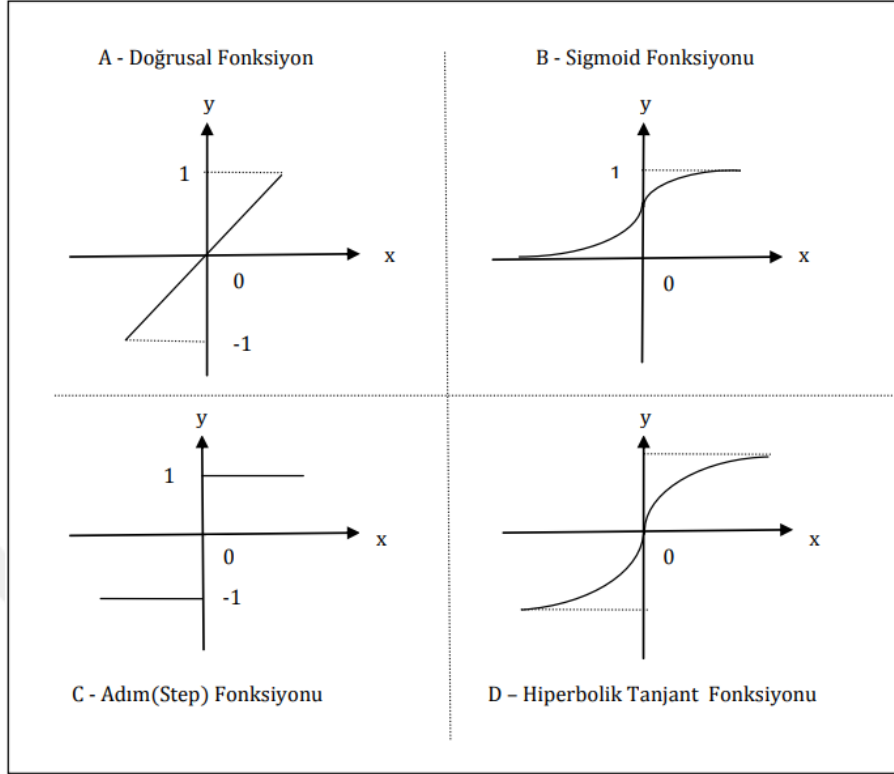
$$f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (7.2)$$

Eşitlik 7.3'te yapay sinir ağının bileşenlerinin oluşturduğu cebirsel denklem örnek olarak gösterilmiştir.

$$y = f(x) = \sum_{i=1}^m w_i * x_i + b = w_1 * x_1 + w_2 * x_2 + \dots + w_m * x_m + b \quad (7.3)$$

Eşitlikte girdiler x_i ile gösterilmiştir. Girdilerin her birinin w_i ağırlıkları ile çarpılması ve b hata değeri ile toplanması işlemine toplama işlevi denir, daha sonra y

çıktı değeri elde edilmek üzere aktivasyon $f(x)$ fonksiyonu ile işlem yapılır (Haykin, (1994)).



Şekil 7.1: Yapay Sinir Ağlarında kullanılan aktivasyon fonksiyonları (Yalçın (2012)).

Yapay sinir ağında karmaşık işlevlerin hesaplanabilmesi için sadece girdi ve çıktı katmanı yeterli olmayıp en az bir ara katmanın olması gereklidir, bu ara katmanlar gizli katman olarak da adlandırılır ve bu yapılar çok katmanlı ağlardır. (Elmas, (2003)).

Çok katmanlı ağların çalışma prensibi eğitim ve test aşamasından oluşmaktadır. Eğitim aşamasında, seçilen öğrenme algoritmasına dayalı olarak ve eğitim verisi kullanılarak ağırlıklar değiştirilir ve güncellenir. Başlangıçta rastgele atanan ağırlık değerleri eğitim verileri kullanılarak girdi ve çıktı arasındaki ilişki oluşturacak şekilde değişir ve güncellenir. Test aşamasında ise ağ hiç karşılaşmadığı bir test seti verisi ile test edilir (Ebrahimzadeh ve Ranaee (2010)). Problem karmaşıklığına göre farklılık gösterebilse de ağın olabildiğince çok ve yeterli ve miktarda veri ile eğitilmesi önerilmektedir (Baş, (2006)). Genellikle elde bulunan verilerin %80'i eğitim %20 si test için kullanılmaktadır. Yapay Sinir Ağları ağın mimarisi, öğrenme yöntemi ve bağlanma yapılarındaki farklılıklar gözetilerek yapılarına, öğrenme algoritmalarına ve öğrenme zamanlarına göre olmak üzere üç ana sınıfa ayrılabilir

(Temizel, (2012)). Mühendislik uygulamalarında en sık kullanılan sinir ağı yapıları ise İleri Beslemeli Sinir Ağları, Konvolüsyonel Sinir Ağları ve Yinelemeli Sinir Ağlarıdır.

İleri beslemeli sinir ağı bir girdi bir çıktı ve bir veya birden fazla gizli katmandan oluşan tam bağlantılı bir ağıdır. Bitişik katmandaki tüm nöronlar birbirine bağlıdır. Bilgi ileri beslemeli sinir ağında girdi katmanından çıktı katmanına doğrusal şekilde akar, herhangi bir döngü yoktur. Evrişimli Sinir ağı ise, evrişimli (konvolüsyonel) katmanlarla karakterize olmuş derin sinir ağı mimarisidir. Yinelemeli Sinir Ağları ise, zaman serileri, sensör ve metin verilerinde olduğu gibi girdideki sıralı bağımlılıkları modelleyen geri bildirim döngülerine sahip bir sinir ağı mimarisidir. En yaygın kullanılan türü de Uzun Kısa Süreli Bellek (LSTM) ağıdır.

Bir problem Yapay Sinir Ağları kullanılarak çözülmek istendiğinde genel çerçevede aşağıdaki adımlar uygulanır.


- i) Problemin girdileri ve çıktıları belirlenerek ağın eğitim ve test aşaması için kullanılacak olan veri toplanır. Girdiler ve çıktıların belirlenmesiyle, giriş ve çıkış katmanındaki hücre sayısı da belirlenmiş olur.
- ii) Toplanan veriler belli kabul gören bir oran olmamasına rağmen çokça kullanılan %80'e %20 kuralına uyacak şekilde eğitim ve test verisi olarak ikiye ayrılır.
- iii) Problemin türüne göre ağ yapısına karar verilir.
 - a. Bu tez çalışması kapsamında İleri Beslemeli Yapay Sinir Ağı yapısı ve Uzun Kısa Süreli Bellek yinelemeli sinir ağı yapısı problem çözümü için seçilmiş ve sonuçları kıyaslanmıştır.
- iv) Ağ parametreleri ve ağırlıkları başlangıç değerleri ile atanır.
- v) Veriler gerekli normalizasyon teknikleri ve gerekiyorsa başka veri ön işleme süreçlerinden geçtikten sonra ağın kullanabileceği hale getirilir ve giriş katmanına veriler eğitim aşaması için uygulanır.
- vi) Eğitim başlar ve gerçek çıktı ve tahmin arasında ölçülen hatayı en aza indirmek için ağırlıklar sürekli gözden geçirilir ve güncellenir.

vii) Hata kabul edilebilir sınırlar arasında girdiğinde eğitim durdurulur ve elde edilen ağırlıklar ile ağı test edilir.

Bu aşamalardan sonra sonuçlar tatmin edici ise eğitilmiş ve test edilmiş ağı kullanıma hazır durumdadır.

7.2 Uzun Kısa Süreli Bellek Sinir Ağları (LSTM)

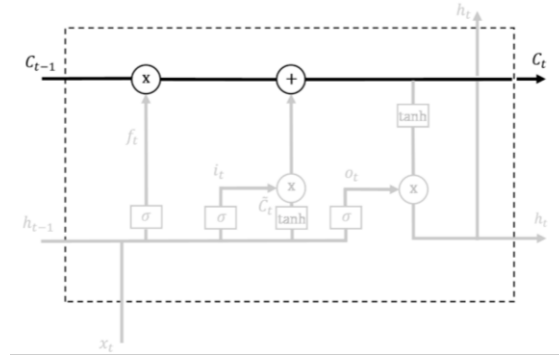
Uzun Kısa Süreli Bellek (LSTM) yapısı Yinelemeli Sinir Ağları yapısının özel bir dizinin sıralı bağımlılıklarını öğrenebildiği özel bir türüdür. Bir LSTM ağına temel bileşenleri, bir sıralı giriş katmanı ve bir LSTM katmanıdır. Bir regresyon problemi için basit bir LSTM ağı mimarisi Şekil 7.2’de gösterilmektedir.



Şekil 7.2: Regresyon problemi için basit LSTM mimarisi (Yu ve diğ. (2019)).


Yinelemeli ağlarda kısa süreli bellek eğer dizi uzunluğu yeterince uzunsa daha önceki adımlardaki bilgileri sonraki adımlara taşımada zorluk yaşatabilmektedir. Yinelemeli ağlarda geri yayılım sırasında bu sebeple kaybolan gradyan sorunu ortaya çıkabilmektedir. Kaybolan gradyan sorunu, ağı derinleştikçe kayıp fonksiyonunun kısmi türevinin ilerledikçe kaybolması, sifira yaklaşması ve ağırlıkların güncellenmesinde dolayısıyla öğrenmede problemler çıkması ile açıklanabilir. Hochreiter ve Schmidhuber, yinelemeli ağlarda kaybolan gradyanlar sorununa bir çözüm olarak uzun-kısa süreli bellek ağı mimarisini tanıtmıştır (Hochreiter ve Schmidhuber, (1997)). LSTM ağı yapısının temel ilkesi önemli bilgilerin uzun vadede hatırlanıp çoklu iterasyonlarda geleceğe aktarılabilmesidir (Buduma ve Locascio, (2017)).

LSTM yapısında bulunan hafıza bloklarına bir dizi kapı yapısı ve hücre durumu bilgisi kullanılarak kaybolan gradyan sorunu çözüme ulaşılmıştır. Yinelemeli sinir ağı ve LSTM’i ayıran temel nokta da LSTM hücresinde gerçekleşen işlemlerdir. Aşağıda Şekil 7.3’te hücre durumu LSTM yapısı içinde gösterilmiştir. LSTM’de bulunan kapı adı verilen yapılar tarafından düzenlenmiş hücre durumuna bilgi ekleme veya hücre durumundan bilgi çıkarma işlemleri yapılabilmektedir.



Şekil 7.3: LSTM hücre durumu (Olah, (2015)).

Kapılar, bir bilginin aktarılıp aktarılmayacağına izin vermek için kullanılan bir dizi sinir ağıdır ve eğitim sırasında kapılar hangi bilginin önemli olup hatırlanacağını hangisinin önemsiz olup unutulacağını öğrenebilir (Gültekin, (2021)). Örnek olarak Şekil 7.4'te gösterilmiş kapı sigmoid sinir ağı katmanı ve noktasal çarpma işleminden oluşur. Sigmoid katmanı bilgiyi 0 ile 1 arasında bir değere dönüştürür ve her bileşene bilginin ne kadarının aktarılacağını açıklar. “0” değeri hiçbir şeyin geçmemesine, “1” değeri her şeyin geçmesine işaret eder.

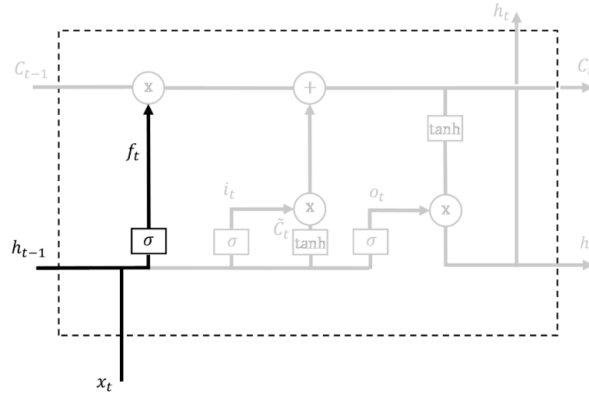


Şekil 7.4: LSTM ağ modelinde kapı gösterimi (Olah, (2015)).

LSTM, hücre durumunu kontrol etmek için 3 tip kapıya sahiptir: girdi kapısı, unutma kapısı ve çıktı kapısı (Olah, (2015)). Unutma kapısı, bilginin hatırlanması veya unutulması kararını vermekle yükümlüdür. Bu karar sigmoid katmanı tarafından gerçekleştirilir. Şekil 7.5 unutma kapısı katmanını göstermektedir.

h_{t-1} bir önceki bloğun çıktı değeri (gizli durum da denmektedir), x_t girdi değeri, olmak üzere f_t unutma kapısı fonksiyonu Eşitlik 7.4 ile hesaplanır. Unutma kapısı, h_{t-1} ve x_t 'ye bakarak ve sigmoid fonksiyonunu kullanarak c_{t-1} hücre durumundaki her sayı için $[0,1]$ arasında bir değer verir. “1” değeri bilgiyi tamamen koru, “0” değeri bilgiden tamamen kurtul anlamına gelmektedir. Tüm hesaplamalar boyunca kullanılan $W_{f,x}$, $W_{c,x}$, $W_{i,x}$, $U_{f,h}$, $U_{c,h}$, $U_{i,h}$ değerleri ilgili kapıların ağırlık değerleridir.

$$f_t = \sigma(W_{f,x} * x_t + U_{f,h} * h_{t-1}) \quad (7.4)$$




Şekil 7.5: LSTM unutmama kapısı katmanı (Olah, (2015)).

Bir sonraki karar ise hücre durumunda yeni bilgilerin hangilerinin saklanacağıdır. Bu karar süreci iki aşama yardımıyla gerçekleşir. İlk önce giriş kapısı olarak adlandırılan sigmoid katmanı girdinin taşıdığı yeni bilginin önemini ölçer, daha sonra hiperbolik tanjant katmanı hücre durumuna eklenecek yeni bilginin (\widehat{C}_t) vektörünü oluşturur. Şekil 7.6'da gösterildiği üzere hücre durumunun güncellenmesi için bu ikisi birleştirilir. Eşitlik 7.5 ve 7.6 ile sırasıyla i_t ve \widehat{C}_t denklemleri gösterilmektedir.

$$i_t = \sigma(W_{i,x} * x_t + U_{i,h} * h_{t-1}) \quad (7.5)$$

$$\widehat{C}_t = \tanh(W_{c,x} * x_t + U_{c,h} * h_{t-1}) \quad (7.6)$$



Şekil 7.6: Yeni bilginin hücre durumunda saklanması (Olah, (2015)).

Son olarak çıktının ne olacağı kararı verilmelidir. İlk olarak hücre durumunun hangi kısımlarının çıktısının verileceği sigmoid katman ile belirlenir. Sonra hücre durumuna hiperbolik tanjant fonksiyonu uygulanıp değerlerin -1 ile 1 arasında olması sağlanır. Son olarak güncel gizli durumun hesaplanması için hiperbolik tanjant fonksiyonu uygulanmış güncel hücre durumu ve çıktı kapısının değeri \otimes işlemi ile çarpılır. Eşitlik 7.8 ve 7.9 çıktı değerinin oluşturulmasına ilişkin denklemleri belirtmektedir.

$$o_t = \sigma(W_{o,x} * x_t + U_{o,h} * h_{t-1}) \quad (7.8)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (7.9)$$

7.3 Ortalama Bekleme Süresi Tahmin Modeli Eğitim Veri Setinin Hazırlanması ve Performans Ölçütleri

Ortalama bekleme süresi tahmincisinin amacı, her t- periyodu başında (TS dakika uzunluğunda periyotlar) o anki istasyon durumuna bakarak, önümüzdeki TS dakika içinde sisteme gelecek EX ve NR-Araçlar için ortalama bekleme süresi tahmini yapmaktır.

Bekleme süresi tahmin modeli için eğitim veri seti hazırlık aşamasında, RL-EXP kontrolörü ile yönetilen istasyon modelinden (simülasyon modelinden), her tahmin ilan periyodu başında (periyot uzunluğu TS dakikada) aşağıdaki girdiler elde edilmiştir.

Girdiler: Kuyrukta bekleyen EX-Araç sayısı, kuyrukta bekleyen NR-Araç sayısı, kuyrukta bekleyen EX-Araçların ortalama bekleme süresi, kuyrukta bekleyen NR-Araçların ortalama bekleme süresi, boşta olan sunucu sayısı. Ölçülen anlık girdilere hedef görece bekleme oranı (φ) da eklenerek tahmin modelinin girdileri oluşturulmuştur.

Çıktı: Ortalama EX-Araç bekleme süresi, Ortalama NR-Araç bekleme süresi. Eğitim aşamasında çıktıların elde edilmesi için girdilerin ölçüldüğü periyodun başından sonuna kadar geçen sürede, istasyona giriş yapan araçlar izlenmiş ve bu araçların servise başlayana kadar sistemde geçirdikleri bekleme süreleri ölçülerek sınıf başına (EX-NR) ortalamaları alınmıştır.

EX-Araç ve NR-Araç ortalama bekleme süreleri tahmini için iki farklı tahminci kullanılmaktadır. EX-Araç bekleme süresi çıktısı ilk tahmincide, NR-Araç bekleme süresi çıktısı da ikinci tahmincinin eğitiminde kullanılmaktadır.

Önümüzdeki “TS dakika” içinde sisteme girecek kullanıcılar için verilecek tahmini ortalama bekleme süresi bilgisi için, TS dakika parametresi 5 ve 15 dakika olacak şekilde iki ayrı veri seti hazırlanmıştır. Böylelikle sistemin yakın ve orta vadeli tahminleri karşılaştırılmıştır. Örneğin önümüzdeki 15 dakikada sisteme girecek araçların ortalama bekleme süresinin tahmin edildiği modelde, şehir içindeki veya

şehirler arası otoyollarda elektrikli araç kullanıcılarının istasyonlara ulaşacakları sürenin 15 dakika olması durumundaki performans incelenmektedir.

Ağ eğitimi aşamasında, farklı EX-Araç sınıfı oranı ve farklı istasyon hedef görece bekleme oranı parametreleri koşulları altında etkin çalışabilecek bir veri seti hazırlanmıştır. Alınan örneklemlerde istasyon hedef görece bekleme oranı 1.1, 1.3, 1.5 ve 1.7, EX-Araç sınıfı oranı ise 0.3, 0.4, ..., 0.8 olarak değişmektedir. Eğitim verisi, hazırlanırken her bir hedef görece bekleme oranının her bir EX-Araç sınıfı oranı (1.1 hedef oranının 0.3 EX-Araç oranı verisi vb.) için alınan 30 koşturumda belirlenen bir zaman adımı uzunluğunda (450 zaman adımı) bağımsız noktalardan alınmıştır. Sonuç olarak test verisi olarak her bir hedef görece bekleme oranı için bireysel 180'er adet 450 zaman adımı uzunluğunda dizi verisi oluşturulmuştur. Eğitim verisi olarak ise tüm hedef görece bekleme oranlarını içeren 720 adet 450 zaman adımlık dizi verisi kullanılmıştır.

Veri seti hazırlanırken istasyon doluluk oranının 0.95 olduğu simülasyon koşturumları kullanılmıştır. Aynı veri setleri kullanılarak hem EX-Araç ortalama bekleme süresi tahmincisi hem de NR-Araç ortalama bekleme süresi tahmincisi eğitilmiştir.

Tüm hedef görece bekleme oranlarının verisini içeren eğitim seti, istasyon doluluk oranı 0.95 ve diğer doluluk oranları karışık veya tek başına 0.90, 0.85 ve 0.80 koşulları altında alınan koşturumlardan oluşturulan eğitim verileriyle kıyaslanmıştır. Bu karşılaştırma için yapılan deneylerin sonuçları EK.1'de verilmiştir. 0.95 doluluk oranına sahip veri ile eğitilen ağın oldukça iyi performans gösterdiği görülmüş ve her doluluk oranı için bir ağ eğitilemeyeceğinden, 0.95 ile eğitilen ağın kullanılmasının avantajlı olacağına karar verilmiştir.

Kullanılan veriler, zaman sıralı dizisel veri (Sequential Data) özelliği göstermektedir. Girdi verileri Z-skor normalizasyon tekniği ile normalize edilmiştir. Test girdi verileri de eğitim verilerinin istatistikleri kullanılarak normalize edilmiştir. Z-skor yöntemiyle normalizasyonda eğitim verisinin her bir girdi kategorisi için ortalama değerleri ve standart sapma değerleri hesaplanır. Bulunan bu değerler kullanılarak aşağıdaki Eşitlik 7.10 Denklemine x normalize edilmemiş veri, μ ve σ ise eğitim verisinin her bir girdi kategorisinin istatistikleri olmak üzere uygun şekilde normalize edilir.

$$ZSkor = \frac{x-\mu}{\sigma} \quad (7.10)$$

Uygulanan yöntemlerin tahmin doğruluğunu test etmek için hata kareler ortalamasının karekökü (RMSE), normalize edilmiş hata kareler ortalamasının karekökü (nRMSE) kullanılmıştır. Bu hata ölçüm metriklerinin matematiksel ifadeleri Eşitli 7.11 ve 7.12’de verilmiştir.


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (7.11)$$

$$nRMSE = \frac{RMSE}{ortalama(y)} \quad (7.12)$$

Her iki model için ortak olan yukarıdaki bazı tanımlamalar ve detaylar ışığında Bölüm 7.4 ve Bölüm 7.5’te sırasıyla LSTM ve Yapay Sinir Ağı tahmin modellerinin geliştirilmesine ait ağ yapısı, ağ parametreleri ve eğitim performansına ait detaylara yer verilmiştir. Bölüm 7.6’da ise geliştirilen modellerin sayısal sonuçları ve performans karşılaştırmasıyla ilgili yorumlarda bulunulmuştur.

7.4 Uzun Kısa Süreli Bellek (LSTM) Tahmin Modeli Geliştirilmesi

Uzun kısa süreli bellek yöntemi, LSTM katmanı sayesinde zaman sıralı verilerin (dizi) zaman adımları arasında uzun vadeli bağımlılıkları öğrenen bir yinelemeli sinir ağı türüdür ve zamansal dizileri işlemek için en gelişmiş ağlardan biri olduğu belirtilmektedir (Yu ve diğ. (2019)). Bu özelliği sayesinde zaman sıralı verilere dayalı elektrikli araçların ortalama bekleme süresi tahmin problemi için LSTM kullanılarak tek adım ileriye yönelik (one-step ahead) tahmin modeli geliştirilmiştir. Geliştirilen ağın mimarisi basitçe aşağıda Şekil 7.7’de verilmiştir.



Şekil 7.7: LSTM tahmin modeli ağ yapısı

EX veya NR araçların ortalama bekleme süresi tahmini için girdi değişkenlerinin değerleri değişmemekte ancak çıktı değeri EX araçlar veya NR araçlara ait olacak şekilde değişmektedir. Bu sebeple EX ve NR araçlar için aynı mimariye ve parametre değerlerine sahip, ancak EX ve NR araçların ortalama bekleme süresi çıktı

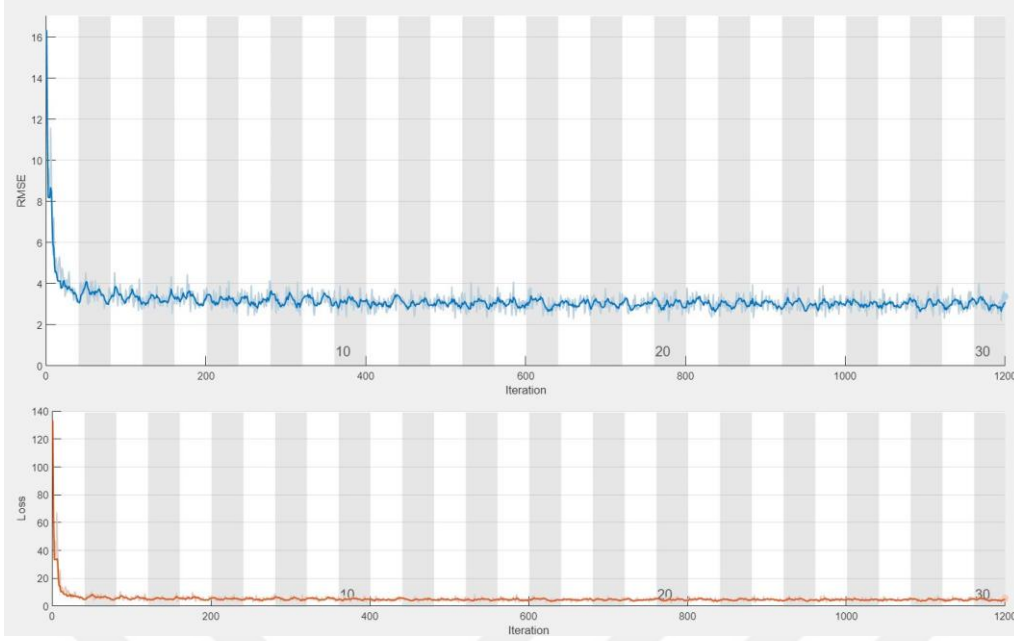
değerini içeren iki farklı veri serinin veri setlerinin kullanıldığı iki farklı ağ eğitilmiş ve RL-EXP istasyon kaynak yönetim modeline entegre edilmiştir.

İki LSTM ağında ortak olarak kullanılan hiper parametreler çeşitli değerler ile sınanmış ve iyi performans gösterdiğine karar verilen değerler aşağıdaki Çizelge 7.1’de verilen değerler olarak belirlenmiştir.

LSTM yinelemeli sinir ağı, hazırlanan eğitim verisi ve Çizelge 7.1’de bahsedilmiş hiper parametreler ile eğitilmiştir. Örnek olarak önümüzdeki 5 dakika içinde sisteme girecek EX-Araçların ortalama bekleme süresi tahmini için hazırlanmış eğitim verisiyle eğitildiği duruma ait tahmin hatasının ve kaybın aşağıda Şekil 7.8’deki gibi değiştiği görülmektedir. Tahmin hatası ve kayıp, ağ öğrenmeyi sürdürdükçe azalmaktadır.

Çizelge 7.1: LSTM ağ hiper parametreleri.

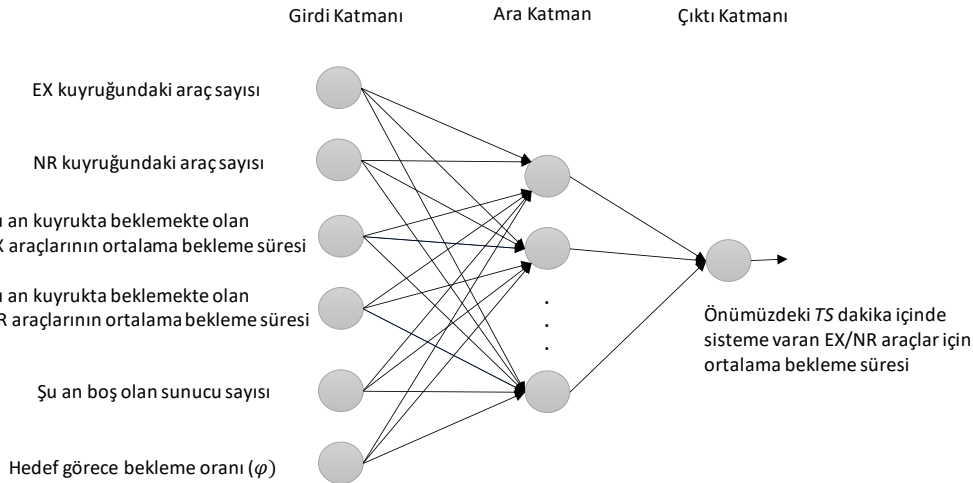
Hiper parametre	Değeri
LSTM katmanı gizli birim sayısı	100
Tam bağlantılı katman sayısı	2
Tam bağlantılı katmanlarda gizli nöron sayısı	50
Sönümlenme katmanı olasılık değeri	0.5
Optimize edici	Adam
Başlangıç öğrenme hızı	0.01
Öğrenme hızı azaltma periyodu	10
Öğrenme hızı azaltma faktörü	0.1
Epoch sayısı	18
Mini-batch büyüklüğü	30



Şekil 7.8: EX-Araçlara ait tahmin için LSTM ağı eğitim aşaması

7.5 Yapay Sinir Ağı Tahmin Modelinin Geliştirilmesi

İleri beslemeli yapay sinir ağı yöntemi ile araç öncelik sınıfları için tek adım ileriye yönelik (one-step ahead) ortalama bekleme süresi tahmini modeli geliştirilmiştir. Kurulan YSA tahmin modelinin çok katmanlı ağın gösterimi Şekil 7.9'daki gibidir. Girdi katmanında girdi sayısı kadar yani 6 adet nöron, çıktı katmanında ise 1 adet (EX veya NR çıktısı) nöron bulunmaktadır.




Şekil 7.9: YSA tahmin modeli için çok katmanlı ağın gösterimi.

EX ve NR araçların ortalama bekleme süresi tahmini için LSTM yönteminde olduğu gibi iki yapay sinir ağı eğitilmiştir. Bu iki ağda ortak olarak kullanılan hiper parametreler çeşitli değerler ile sınanmış ve iyi performans gösterdiğine karar verilen değerler aşağıdaki Çizelge 7.2’de verilen değerler olarak belirlenmiştir.

Çizelge 7.2: Yapay sinir ağı hiper parametreleri

Hiper parametre	Değeri
Tam bağlantılı katman sayısı	2
Tam bağlantılı katmanlarda gizli nöron sayısı	50
Aktivasyon fonksiyonu	tanh
Mini-batch büyüklüğü	18
Epoch sayısı	20
Başlangıç öğrenme hızı	0.01
Öğrenme hızı azaltma faktörü	0.1
Öğrenme hızı fonksiyonu	Parçalı
Gradyan eşik değeri	1
Optimize edici	Adam

İleri beslemeli yapay sinir ağı, hazırlanan eğitim verisi ve yukarıda bahsedilmiş hiper parametreler ile eğitilmiştir. Eğitim sırasında, örnek olarak önümüzdeki 5 dakika içinde sisteme girecek EX-Araçların ortalama bekleme süresi tahmini için hazırlanmış eğitim verisinin kullanıldığı duruma ait tahmin hatasının ve kaybın aşağıda Şekil 7.10’daki gibi değiştiği görülmektedir. Tahmin hatası ve kayıp, ağ öğrenmeyi sürdürdükçe azalmaktadır.



Şekil 7.10: EX-Araçlara ait tahmin için yapay sinir ağı eğitim aşaması

7.6 LSTM ve YSA Yöntemine Ait Sonuçlar ve Performans Karşılaştırması

Önceki bölümlerde anlatıldığı şekilde hazırlanan eğitim verileri ve ağ hiper parametreleri kullanılarak eğitilen LSTM ağı farklı koşullar altında elde edilen test verileri alınarak test edilmiştir. TS parametresinin 5 ve 15 dakika olduğu ve farklı φ ve p_e koşulları ve. 0.95 istasyon doluluk oranı koşulu altında simülasyon modelinden elde edilen test verileri ile test edilmiştir.

Çizelge 7.3'te Önümüzdeki 5 dakika içinde sisteme girecek olan EX ve NR-Araçlar için ($TS=5$ dakika) p_e oranına göre gruplandırılmış diziler üzerinden alınan ortalama ve maksimum RMSE değerleri gösterilmektedir.

Çizelge 7.3'e bakıldığında, hem 180 dizinin tümü üzerinden alınan ortalamaya göre maksimum hem de p_e oranına göre gruplandırılmış dizilerin ortalama RMSE değeri, φ değeri arttıkça EX-Araçlar için azalma eğilimindeyken, NR-Araçlar için artmaktadır. Bunun sebebi, φ değeri arttıkça sistemde NR-Araçlar EX-Araçlara göre daha fazla bekletilme eğilimi göstermektedir. Daha yüksek ortalama bekleme süresi de göreceli olarak daha yüksek RMSE değeri ile sonuçlanabilmektedir.

Dizinin ortalamasının ve diziye ait RMSE değerinin kıyaslamasının daha anlamlı olabilmesi için, test verisinde kullanılan 180 adet dizinin çıktı değerlerinin (Y_{test}) ortalamasına karşılık RMSE dağılım grafikleri incelenmiştir. LSTM ve YSA sonuçlarının incelendiği bölümlerde örnek olarak $\varphi = 1.7$, $TS= 5$ ve 15 olarak

değiştığı EX ve NR test verisi seçilmiş ve bunlara ait dağılım grafiği Şekil 7.11’de verilmiştir. LSTM ve yapay sinir ağının test edildiği diğer tüm test verilerine ait RMSE dağılım grafikleri sırasıyla LSTM için EK.2 YSA için EK.3’te yer almaktadır.

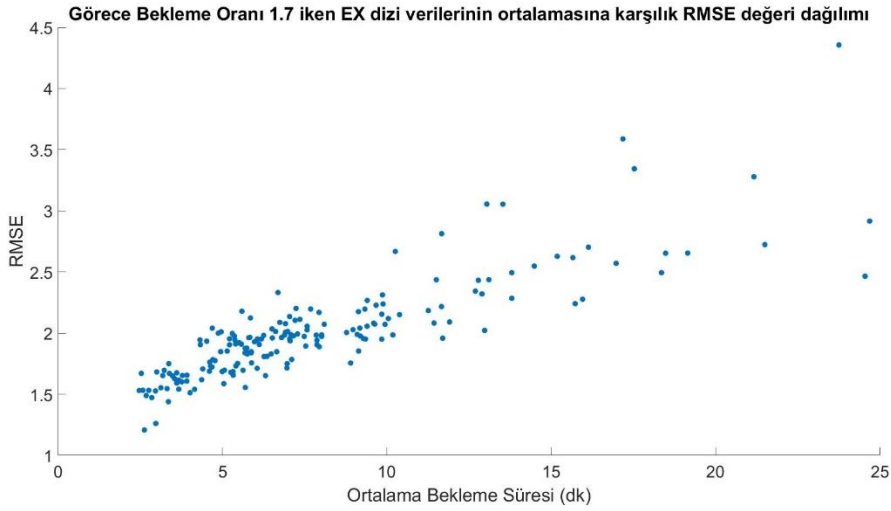
Çizelge 7.3: Önümüzdeki 5 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfına ait LSTM ile yapılan tahminlerin RMSE hata değerleri

Çıktı	φ	$p_e=0.3$ RMSE Ort.	$p_e=0.4$ RMSE Ort.	$p_e=0.5$ RMSE Ort.	$p_e=0.6$ RMSE Ort.	$p_e=0.7$ RMSE Ort.	$p_e=0.8$ RMSE Ort.	180 Dizi üzerinden Maks. RMSE
EX	1,1	2,657	2,601	2,506	2,337	2,139	2,154	5,093
EX	1,3	2,626	2,218	2,146	2,159	1,983	2,091	4,688
EX	1,5	2,391	2,046	2,027	2,032	1,927	2,052	4,043
EX	1,7	2,271	2,009	1,970	1,894	1,914	1,976	4,356
NR	1,1	2,439	2,542	2,825	3,023	3,295	3,847	5,430
NR	1,3	2,759	2,735	3,088	3,542	3,715	4,588	6,649
NR	1,5	2,962	3,002	3,379	3,898	4,381	5,435	8,032
NR	1,7	3,134	3,326	3,834	4,290	4,865	5,661	9,927


Şekil 7.11’de yer alan grafikte x eksenini önümüzdeki 5 dakikada sisteme giren EX araçlarının ortalama bekleme sürelerinin ortalamasını, y eksenini ise RMSE değerini belirtmektedir. Her bir nokta o diziye ait ortalama bekleme sürelerinin ortalamasına karşılık gelen RMSE değerini göstermektedir. En yüksek RMSE değeri aslında ortalaması en yüksek olan diziye aittir. RMSE değerleri 0 ve 2.5 değerleri arasında yoğunlaşmıştır ve dizinin ortalama bekleme sürelerinin ortalaması ile orantılı büyüklüktedir. Diğer φ değerlerini içeren test verilerinde RMSE dağılımı için paralel sonuçlar gözlemlenmiştir.

TS parametresinin 15 dakika olduğu eğitim verisi ile eğitilen LSTM ağına ait sonuçlar ise Çizelge 7.4’te verilmiştir. Eğitilen ağ farklı φ değerleri içeren test verisi ile test edildiğinde p_e oranına göre gruplandırılmış diziler üzerinden alınan ortalama

RMSE ve tüm diziler üzerinden maksimum RMSE değerleri aşağıda Çizelge 7.4'te verilmiştir.



(a) EX test verisi



(b) NR test verisi,

Şekil 7.11: LSTM için $TS=5$ dakika, $\varphi =1.7$ ve $\rho=0.95$ koşullarında EX ve NR dizi ortalamasına karşılık RMSE değeri dağılımı.


TS değerinin 15 dakika olduğu veriler ile eğitilmiş ve test edilmiş durum için dizi ortalamasına karşılık RMSE dağılım grafiği Şekil 7.12'de örnek olarak $\varphi =1.7$ olduğu EX test verisi üzerinden gösterilmiştir. En yüksek RMSE değeri olan 3.87 bekleme süresi ortalaması 24 civarında olan bir diziye aittir. RMSE değerleri 1 ile 3 aralığında yoğunlaşmış ve dizi ortalamalarının büyüklükleri ile orantılıdır.

Çizelge 7.4: Önümüzdeki 15 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfına ait LSTM ile yapılan tahminlerin RMSE hata değerleri


Çıktı	φ	$p_e=0.3$ RMSE Ort.	$p_e=0.4$ RMSE Ort.	$p_e=0.5$ RMSE Ort.	$p_e=0.6$ RMSE Ort.	$p_e=0.7$ RMSE Ort.	$p_e=0.8$ RMSE Ort.	180 Dizi üzerinden Maks. RMSE
EX	1,1	2,999	2,907	2,841	2,681	2,590	2,609	5,596
EX	1,3	2,839	2,376	2,436	2,472	2,369	2,534	4,982
EX	1,5	2,487	2,301	2,335	2,327	2,412	2,602	4,258
EX	1,7	2,413	2,146	2,171	2,226	2,211	2,364	3,872
NR	1,1	2,830	2,962	3,142	3,398	3,673	4,278	5,701
NR	1,3	3,261	3,124	3,523	3,985	4,203	5,042	6,408
NR	1,5	3,521	3,563	3,938	4,474	5,056	6,084	9,113
NR	1,7	3,787	3,829	4,445	4,956	5,367	6,330	10,908

5 ve 15 dakika olarak değişen TS parametresi incelendiğinde, RMSE değerlerinin 15 dakikalık test verisinde 5 dakikalık duruma göre arttığı görülmüştür. Bu durum, kuyruk durumunun 5 dakikada bir yani daha sık kontrol edilmesiyle anlık durumdaki değişikliklerin daha iyi gözlemlenmesiyle ilişkilendirilebilir.

Sonuçlar incelendiğinde EX araçlar için yapılan tahminlerin RMSE değerlerinin NR araçlar için yapılan tahminlere göre daha düşüktür. Kaynak yönetimi ile sistemde yüksek öncelikli EX-Araçları NR-Araçlara göre daha az bekletmeyi hedefleyen bir politika izlendiğinden NR-Araçlar için kullanılan test verisindeki dizilerin ortalama bekleme sürelerinin büyüklükleri EX test verilerinden daha büyüktür. RMSE de dizi ortalamasının büyüklük ölçeğinden kaynaklı NR-Araçlar için daha yüksektir çıkarımı yapılabilir.



(a) EX test verisi



(b) NR test verisi

Şekil 7.12: LSTM için $TS=15$ dakika, $\varphi =1.7$ olduğu EX ve NR test verisinde dizi ortalamasına karşılık RMSE değeri dağılımı.

7.7. Yapay Sinir Ağı Yöntemine Ait Sonuçlar

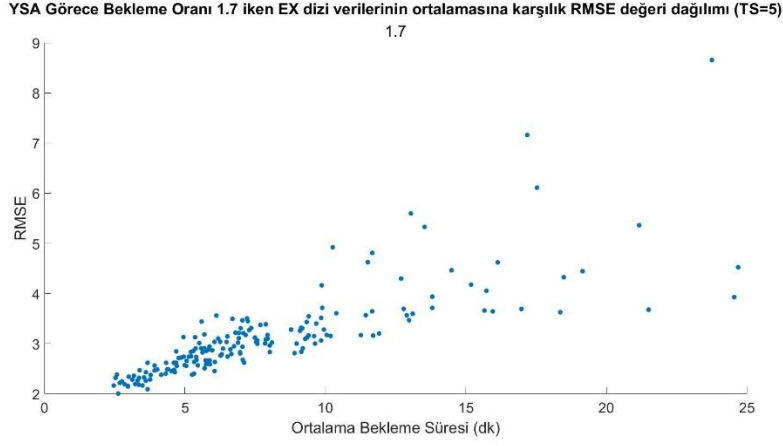
Geliştirilen yapay sinir ağı karar verildiği üzere 0.95 doluluk oranı verilerini içeren eğitim verileriyle ve belirlenen ağ hiper parametreleri kullanılarak eğitilmiştir. Eğitilen ağ, TS parametresinin 5 ve 15 dakikalık değerleri için ve farklı φ değerleri içeren test verisi ile test edilmiştir. Sonuçlara bakıldığında, 5 dakikalık test verileri için p_e oranına göre gruplandırılmış diziler üzerinden alınan ortalama RMSE değerleri aşağıda Çizelge 7.5'te verilmiştir.

Çizelge 7.5: Önümüzdeki 5 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfı için Yapay Sinir Ağı ile yapılan tahminlerin RMSE hata değerleri

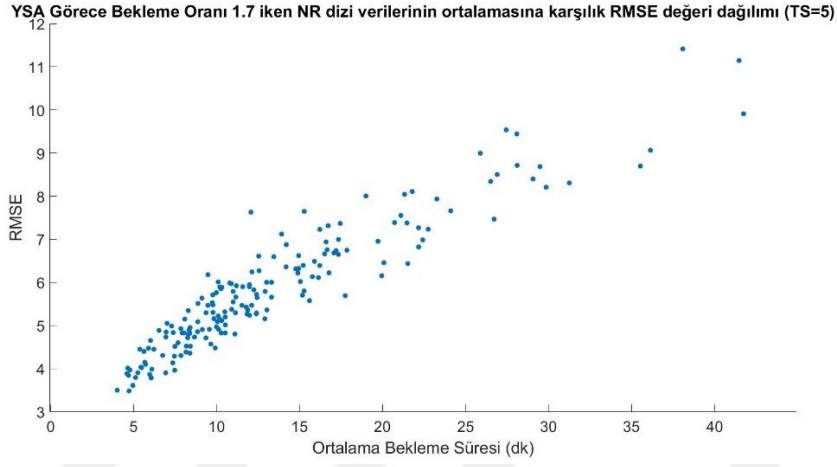
Çıktı	φ	$p_e=0.3$ RMSE Ort.	$p_e=0.4$ RMSE Ort.	$p_e=0.5$ RMSE Ort.	$p_e=0.6$ RMSE Ort.	$p_e=0.7$ RMSE Ort.	$p_e=0.8$ RMSE Ort.	180 Dizi üzerinden Maks. RMSE
EX	1,1	4,705	4,452	4,136	3,815	3,463	3,659	9,893
EX	1,3	4,706	3,629	3,530	3,437	3,177	3,509	8,569
EX	1,5	4,048	3,273	3,181	3,196	3,072	3,330	7,576
EX	1,7	3,689	3,105	3,077	2,995	2,982	3,049	8,024
NR	1,1	4,381	4,326	4,297	4,364	4,401	4,852	8,642
NR	1,3	5,223	4,467	4,604	4,990	4,950	5,712	8,913
NR	1,5	5,433	4,764	4,995	5,457	5,643	6,569	9,691
NR	1,7	5,667	5,200	5,585	5,976	6,185	6,625	11,121

Çizelge 7.5'e bakıldığında, hem 180 dizinin tümü üzerinden alınan ortalama göre maksimum hem de p_e oranına göre gruplandırılmış dizilerin ortalama RMSE değerinde görülen değişim LSTM sonuçlarıyla paralellik göstermektedir. φ değeri arttıkça RMSE değerleri EX-Araçlar için azalma eğilimindeyken, NR-Araçlar için artmaktadır. Bunun sebebi NR ortalama bekleme sürelerinin φ değeri arttıkça EX araçların ortalamasına göre artmasıdır.

Yapay Sinir Ağı yöntemi için de ortalama bekleme süresine karşılık RMSE dağılım grafiği LSTM ile paralel durum göstermektedir. Şekil 7.13'te örnek olarak $\varphi = 1.7$ olduğu EX ve NR test verisi için dağılım grafiği gösterilmiştir. En yüksek RMSE değeri olan 8.02 değeri ortalama bekleme süresinin ortalamasının 24 civarında olan diziye aittir. RMSE değeri 2 ve 4 değerleri arasında yoğunlaşmaktadır ve RMSE büyüklüğünün dizi ortalamasıyla orantılı olduğu söylenebilir.



(a) EX test verisi



(b) NR test verisi

Şekil 7.13: Yapay sinir ağı için TS=5 dakika, $\varphi = 1.7$ olduğu EX ve NR dizi ortalamasına karşılık RMSE değeri dağılımı

TS parametresinin 15 dakika olduğu eğitim verisiyle eğitilen yapay sinir ağı farklı φ değerleri içeren test verisi ile test edilmiştir. Çizelge 7.6'da test verisinde p_e oranına göre gruplandırılmış diziler üzerinden alınan ortalama RMSE ve tüm diziler üzerinden maksimum RMSE değerleri gösterilmiştir. Çizelge 7.6'ya göre, yine ortalama ve maksimum RMSE değerlerinin değişimi LSTM sonuçlarındaki değişimle paralellik göstermektedir ve sebebi NR ortalama bekleme sürelerinin φ değeri arttıkça EX araçların ortalamasına göre artmasıdır.

Dizi ortalamasına karşılık RMSE dağılım grafiği Şekil 7.14'te örnek olarak $\varphi=1.7$ durumu için gösterilmiştir. En yüksek RMSE değeri EX için dizi ortalamasının 24 civarında, NR için 40 dakika ortalama bekleme süresine sahip diziye aittir.

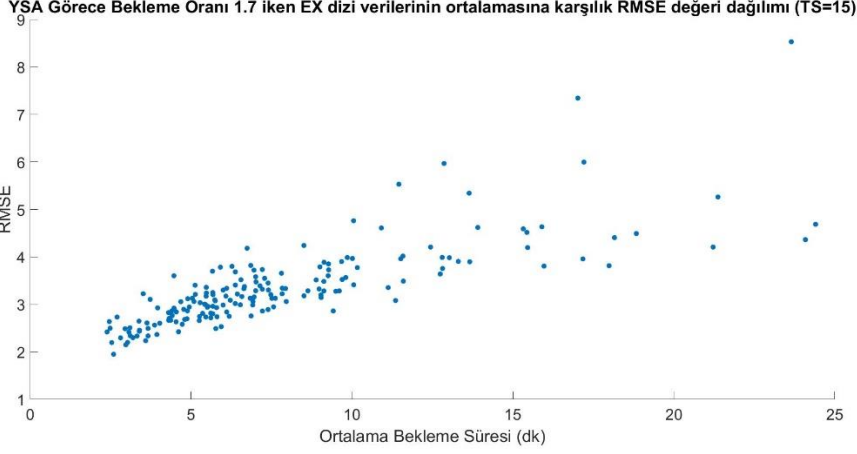
Çizelge 7.6: Önümüzdeki 15 dakika içinde sisteme girecek olan EX-Araç ve NR-Araç sınıfı için Yapay Sinir Ağı ile yapılan tahminlerin RMSE hata değerleri

Çıktı	φ	$p_e=0.3$ RMSE Ort.	$p_e=0.4$ RMSE Ort.	$p_e=0.5$ RMSE Ort.	$p_e=0.6$ RMSE Ort.	$p_e=0.7$ RMSE Ort.	$p_e=0.8$ RMSE Ort.	180 Dizi üzerinden Maks. RMSE
EX	1,1	4,766	4,514	4,260	3,997	3,776	3,883	10,115
EX	1,3	4,728	3,735	3,614	3,633	3,407	3,791	8,633
EX	1,5	4,096	3,389	3,343	3,422	3,470	3,741	7,740
EX	1,7	3,824	3,187	3,228	3,236	3,211	3,361	7,988
NR	1,1	4,702	4,514	4,424	4,545	4,599	5,043	9,511
NR	1,3	5,561	4,660	4,776	5,240	5,189	5,992	9,387
NR	1,5	5,748	5,048	5,222	5,777	6,145	6,937	9,911
NR	1,7	6,104	5,475	6,022	6,372	6,594	7,189	11,961


Yapay sinir ağı tahmin sonuçlarında 5 ve 15 dakika olarak değişen TS parametresi incelendiğinde, LSTM ile benzer nedenden dolayı RMSE değerlerinin 15 dakikalık test verisinde 5 dakikalık duruma göre arttığı görülmüştür. Yine LSTM ile benzer olarak EX araçlar için yapılan tahminlerin RMSE değerleri NR araçlar için yapılan tahminlere göre daha düşük olduğu görülmektedir.

Sonuç olarak, LSTM ve Yapay Sinir Ağı tahmin modellerinin farklı φ değerlerinin olduğu ve TS parametresinin 5 ve 15 olarak değiştiği verilerle test edilmesine ait sonuçlar Çizelge 7.7’de özetlenmiştir.

nRMSE metriği, RMSE büyüklüğüyle orantılıdır ve Eşitlik 7.12’de gösterildiği şekilde hesaplanmaktadır. Çizelge 7.7’de RMSE ve nRMSE metrikleri kıyaslandığında LSTM yönteminin hata metrik değerlerinin daha düşük olduğu görülmüştür. Özellikle maksimum RMSE değerlerinde iki model arasındaki farkın yüksek olduğu görülmektedir.



(a) EX test verisi



(b) NR test verisi

Şekil 7.14: Yapay sinir ağı için $TS=15$ dakika, $\varphi = 1.7$ olduğu EX ve NR test verisinde dizi ortalamasına karşılık RMSE değeri dağılımı

Çizelge 7.7'ye bakıldığında, TS değerinin 5 ve 15 dakika olduğu test seti ile alınan sonuçlar kıyaslandığında LSTM modeline ait hem EX hem NR araç sınıfı için yapılan tahmin değerlerinin Yapay Sinir Ağı modeline göre ortalama ve maksimum RMSE ve nRMSE değerlerinin daha düşük olduğu görülmüştür.

Gerçekleşen test değerleri ve LSTM ile yapay sinir ağı modelinin tahminlerinin görsel olarak kıyaslanabilmesi için $\varphi=1.5$, doluluk oranı 0.95 ve $TS=5$ dakika koşullarını taşıyan 180 adet dizi arasından örnek olarak gösterilmek üzere 1 diziye ait test verisi için sonuçların yer aldığı grafik Şekil 7.14'te gösterilmiştir.


Bu EX test verisi için tüm 180 dizi üzerinden ortalama RMSE yapay sinir ağı modeli için 3.35, LSTM için ise 2.07'dir. NR için ise ortalama RMSE değerleri YSA için

5.47 LSTM için 3.84'tür. Grafikten de LSTM tahminlerinin gerçek veri ile daha uyumlu olduğu görülmektedir.


Çizelge 7.7: LSTM ve yapay sinir ağı tahmin hataları için özet tablo

	Çıktı	φ	YSA Ort. RMSE	YSA Maks. RMSE	LSTM Ort. RMSE	LSTM Maks. RMSE	LSTM Ort. nRMSE	YSA Ort. nRMSE
TS=5 dakika verisi	EX	1,1	4,038	9,893	2,399	5,093	0,242	0,407
	EX	1,3	3,665	8,569	2,204	4,688	0,236	0,392
	EX	1,5	3,350	7,576	2,079	4,043	0,239	0,384
	EX	1,7	3,149	8,024	2,006	4,356	0,255	0,400
	NR	1,1	4,437	8,642	2,980	5,430	0,272	0,406
	NR	1,3	4,491	8,913	3,404	6,649	0,277	0,410
	NR	1,5	5,477	9,691	3,843	8,032	0,291	0,420
	NR	1,7	5,873	11,121	4,185	9,927	0,310	0,439
TS=15 dakika verisi	EX	1,1	4,199	10,115	2,771	5,596	0,283	0,429
	EX	1,3	3,818	8,633	2,505	4,982	0,271	0,413
	EX	1,5	3,577	7,740	2,411	4,258	0,281	0,416
	EX	1,7	3,341	7,988	2,255	3,872	0,291	0,431
	NR	1,1	4,638	9,511	3,380	5,701	0,312	0,432
	NR	1,3	5,236	9,387	3,857	6,408	0,319	0,436
	NR	1,5	5,813	9,911	4,439	9,113	0,341	0,451
	NR	1,7	6,292	11,961	4,786	10,908	0,360	0,476

Diğer test verilerine ait $\varphi= 1.1, 1.3$ ve 1.7 ve TS=5 ve TS=15 olan EX ve NR test verilerinden bir adet dizi seçilerek LSTM ve YSA tahminleriyle gerçekleşen değerlerin kıyaslandığı grafikler EK.4'te sunulmuştur.



(a) EX verisi



(b) NR verisi

Şekil 7.15: $\varphi=1.5$, doluluk oranı 0.95 ve TS=5 dakika koşullarını taşıyan bir EX ve NR test dizisi için gerçek ve tahmini değerlerin karşılaştırılması.

Sonuç olarak, LSTM modelinin önümüzdeki 5 ve 15 dakika içinde sisteme varacak EX ve NR araçlar için ortalama bekleme süresi tahminleri 4 farklı hedef görece bekleme oranlarıyla oluşturulan test verilerinin tümü için yapay sinir ağları ile yapılan tahminlere göre daha iyi sonuç göstermektedir. Bu nedenle, RL-EXP modeline entegre edilerek çevrimiçi olarak girdi verilerini kullanan ve araçlara ortalama bekleme süresi tahmini bilgisi sağlayan ağ LSTM olarak seçilmiştir.

8. TARTIŞMA VE GELECEK ÇALIŞMALAR

Günümüzde ulaşımda elektrikli araçların kullanımı giderek yaygınlaşmakta ve bununla beraber şarj altyapısı ve şarj istasyonu için yapılan çalışmaların sayısı da artmaktadır. Elektrikli araçların şarj dolum süresinin hızlı şarj istasyonlarında bile 30 dakikayı bulması, istasyonlarda bekleme süreleri ve kuyruk uzunluğunu artırması beklenmektedir. Bu soruna yönelik çalışmalarda, araçların şarj taleplerinin uygun istasyona yönlendirilmesi ve istasyonların konumunun ve kapasitesinin uygun şekilde belirlenmesi gibi yöntemler kullanılmaktadır. Bekleme süresini azaltmayı amaçlayan başka bir yöntem de araçların bir bölümü için öncelikli servis veren şarj istasyonlarının oluşturulmasıdır. İstasyonlarda fiyat ve bekleme süresi konusunda farklı hassasiyete sahip olabilecek kullanıcılara, yüksek öncelik (yüksek fiyat-düşük bekleme süresi) ve düşük öncelik (düşük fiyat- yüksek bekleme süresi) seviyelerinde servis verilmesi mümkündür. Bu çalışma, yüksek öncelikli araçların düşük öncelikli araçlara göre daha az bekletilmesi amacıyla istasyondaki sunucuları bu iki öncelik sınıfı arasında dinamik ve gerçek zamanda atayan bir kaynak yönetim modeli önermektedir.

Bu tez çalışması iki bölümden oluşmaktadır. İlk bölümde derin pekiştirmeli öğrenme tabanlı Derin Q-Öğrenme metodu ile sunucuların araç sınıflarına dinamik ve gerçek zamanda atamasının yapıldığı bir kaynak yönetim metodu geliştirilmiştir. Bu dinamik atama sayesinde iki araç sınıfının ortalama bekleme sürelerinin oranını belirlenen bir seviyede tutmak ve böylece yüksek öncelikli araç sınıfı için bekleme süresini azaltmak hedeflenmiştir. Geliştirilen yöntemde araçların istasyona varmadan önce istasyona bildirecekleri herhangi bir termin, konum ve varış zamanı bilgisine ihtiyaç duyulmamaktadır. Çalışmada kontrol yönteminin performansı tek istasyonlu ortamda çeşitli koşullar altında test edilmiştir. Ek olarak literatürde bu konuda yapılan çalışmalardan Fescioglu-Unver ve diğ., (2021) ve Kakillioglu ve diğ., (2022) ve sabit sunucu yöntemi ile kıyaslanmıştır. Çalışma MATLAB programının “Pekiştirmeli Öğrenme” aracı kullanılarak kodlanmış ve yine MATLAB ile kodlanmış simülasyon ortamında test edilmiştir

Bu çalışmanın ikinci bölümünde ise, RL-EXP kaynak yönetim modeli ile sunucuların dinamik ve gerçek zamanlı olarak yönetildiği bir istasyona önümüzdeki 5 veya 15 dakika içinde giriş yapacak EX ve NR araç sınıflarının ortalama bekleme sürelerinin tahmini için tahmin yöntemi geliştirilmiştir. Uzun Kısa Süreli Bellek (LSTM) yöntemi ve yapay sinir ağı kullanılarak geliştirilen tahmin modelleri birbiriyle kıyaslanmış ve LSTM yönteminin daha yüksek tahmin doğruluk oranına sahip olduğu görülmüştür. Geliştirilen tahmin modeli, RL-EXP kontrol yöntemi ile kontrol edilen istasyondan gerçek zamanda topladığı girdi verileri ile EX (Express-yüksek) ve NR (Normal) öncelik sınıflarına tahmini ortalama bekleme süresi bilgisi vermektedir. Araç kullanıcıları bu bilgi sayesinde bekleme süresi belirsizliğine dair endişelerini gidermekte ve ortalama ne kadar bekleyeceklerine dair öngörü sahibi olarak istasyondan servis almaktadırlar.

Sonuçlar incelendiğinde geliştirilen yöntemin farklı istasyon doluluk oranı farklı EX-Araç bekleme oranı ve farklı hedef görece bekleme oranı koşulları altında hedeflenen bekleme oranını hem kararlı durumda hem gerçek zamanda yapılan testlerde başarıyla gerçekleştirdiği görülmüştür. Yüksek öncelikli EX-Araç sınıfının ortalama bekleme süreleri NR-Araçlarınkine kıyaslandığında, RL-EXP modeli yüksek öncelikli sınıfı, hedeflenen bekleme oranına uygun şekilde daha az bekletmektedir. Ayrıca istasyona gelecek ani araç yüklenmeleri karşısında RL-EXP ile yönetilen sistem hızlı bir şekilde toparlanmaktadır.

Üç farklı yöntemle yapılan performans kıyaslamaları sonucunda ise RL-EXP yöntemi sabit sunuculu sistemlere göre dinamik bir metot kullanması sayesinde her performans kriterinde büyük farklarla daha iyi sonuçlar vermiştir. Fescioglu-Unver ve diğ., (2021) ve Kakillioglu ve diğ., (2022) tarafından geliştirilen yöntemlere kıyasla RL-EXP kararlı durumda farklı hedef görece bekleme oranı ve EX-Araç oranı koşulları altında ortalama *diff* değerleri sıfıra çok daha yakın dar bir alanda yayılım göstermektedir. Kararlı durumda özellikle hedef görece bekleme oranı ve EX-Araç oranı değerlerinin uç noktalarında SC-EXP ve FC-EXP'den çok daha düşük *diff* değerleri gözlemlenmiştir. Gerçek zamanlı performansı sınındığında, RL-EXP özellikle ortalama ve minimum *diff* değeri açısından diğer modellerden daha iyi, maksimum *diff* değerleri açısından ise diğer modellerle benzer performans göstermektedir. RL-EXP metodu için tepki süresine bakıldığında ise FC-EXP'ye

göre tüm hedef görece bekleme oranı koşullarında SC-EXP'ye göre ise özellikle $\varphi = 1.5$ 'un üstünde değerler aldığı daha iyi performans göstermiştir.

Bu tez çalışması iki açıdan özgündür. İlk olarak, öncelikli servis veren elektrikli araç şarj istasyonunda sunucu sayısının dinamik olarak değiştirilmesinde Derin-Q öğrenme yöntemi ilk kez bu çalışmada kullanılmıştır. Çalışmanın ikinci özgün yönü, elektrikli araçların şarj istasyonunda ortalama bekleme süresi tahmininin ilk kez yapılmasıdır.

Gelecek çalışmalarda, kaynak yönetim modeli RL-EXP'nin kullandığı ödül fonksiyonunda EX ve NR araç sınıflarına verilen tahmini ortalama bekleme süresi bilgisinin entegre edilmesi amaçlanmaktadır. Bu sayede bireysel araçların bu bildirilen ortalama tahmini bekleme süresinden sapması kullanılarak araçların ortalama bekleme süresinin birbirine oranını dikkate alan hem de öncelik sınıfındaki bireysel araçları, ilan ettiği ortalama bekleme süresine yakın sürelerde bekleteceğine söz verecek bir kaynak yönetim modeli oluşturulmaya çalışılacaktır. Bu şekilde sadece ortalama bekleme süre hedefinin tutturulması değil, araçların bekleme sürelerinin ilan edilen ortalama bekleme süresinden sapmalarının, yani varyansın da azaltılması hedeflenmektedir.

Bir istasyona gelecek araç sayısı günün saatine ve trafikteki yoğunluğa göre değişiklik gösterebilir, buna yönelik olarak istasyona gelecek EX ve NR araçların gün içindeki değişken varış oranlarının tahmin edilmesine yönelik model geliştirilmesiyle hem kaynak yönetimi modelinin performansı hem de ortalama bekleme süresi tahmininde iyileşmeler sağlanabilir.

Ayrıca gelecek çalışmalarda ikiden fazla öncelik sınıfı için deneyler yapılabilir. Ve geliştirilen kaynak yönetim modelinin performansının rekabetçi bir çoklu istasyon ortamında da test edilebilir.



KAYNAKÇA

- Abd Eldjalil, C. D., & Lyes, K.** (2017, May). Optimal priority-queuing for EV charging-discharging service based on cloud computing. In 2017 IEEE International Conference on Communications (ICC) (pp. 1-6). IEEE.
- Abdelzاهر, T. F., Shin, K. G., & Bhatti, N.** (2002). Performance guarantees for web server end-systems: A control-theoretical approach. *IEEE transactions on parallel and distributed systems*, 13(1), 80-96.
- Akhavan-Rezai, E., Shaaban, M. F., El-Saadany, E. F., & Karray, F.** (2014, July). Priority-based charging coordination of plug-in electric vehicles in smart parking lots. In 2014 IEEE PES General Meeting| Conference & Exposition (pp. 1-5). IEEE.
- Aljafari, B., Jeyaraj, P. R., Kathiresan, A. C., & Thanikanti, S. B.** (2023). Electric vehicle optimum charging-discharging scheduling with dynamic pricing employing multi agent deep neural network. *Computers and Electrical Engineering*, 105, 108555.
- Ang, E., Kwasnick, S., Bayati, M., Plambeck, E. L., & Aratow, M.** (2016). Accurate emergency department wait time prediction. *Manufacturing & Service Operations Management*, 18(1), 141-156.
- Anil, A., Azeem, S., Panicker, B., & Saifudeen, V. K.** (2020, April). Electric vehicle charging assistive system using internet of electric vehicles. In AIP Conference Proceedings (Vol. 2222, No. 1, p. 040016). AIP Publishing LLC.
- Baş N.**, 2006, Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi, İstanbul.
- Bayram, I. S., Michailidis, G., Papapanagiotou, I., & Devetsikiotis, M.** (2013, December). Decentralized control of electric vehicles in a network of fast charging stations. In 2013 IEEE Global Communications Conference (GLOBECOM) (pp. 2785-2790). IEEE.
- Benevento, E., Aloini, D., & Squicciarini, N.** (2023). Towards a real-time prediction of waiting times in emergency departments: A comparative analysis of machine learning techniques. *International Journal of Forecasting*, 39(1), 192-208.
- Benevento, E., Aloini, D., Squicciarini, N., Dulmin, R., & Mininno, V.** (2019). Queue-based features for dynamic waiting time prediction in emergency department. *Measuring Business Excellence*, 23(4), 458-471.
- Bennanist, M. N., Menasce, D.** 2005. "Resource allocation for autonomic data centers using analytic performance models", *IEEE Proceedings. Second International Conference on Autonomic Computing*, 229-240.

- Blum, C., Liu, H., & Xiong, H.** (2021). CoordiQ: Coordinated Q-learning for Electric Vehicle Charging Recommendation. arXiv preprint arXiv:2102.00847.
- Bolour, K., Chirkova, R., Salo, T., & Viniotis, Y.** (2011, December). Analysis of response time percentile service level agreements in soa-based applications. In 2011 IEEE Global Telecommunications Conference-GLOBECOM 2011 (pp. 1-6). IEEE.
- Bryden TS, Hilton G, Cruden A, Holton T.** 2018 “Electric vehicle fast charging station usage and power requirements.” *Energy* 2018;152:322e32.
- Buduma, N. and Locascio, N.,** “Fundamentals of Deep Learning. Designing Next-Generation Machine Intelligence Algorithms”, O’Reilly Media, 172-217
- Cao, Y., Jiang, T., Kaiwartya, O., Sun, H., Zhou, H., & Wang, R.** (2019). Toward pre-empted EV charging recommendation through V2V-based reservation system. *IEEE transactions on systems, man, and cybernetics: systems*, 51(5), 3026-3039.
- Cao, Y., Wang, N., Kamel, G., & Kim, Y. J.** (2015). An electric vehicle charging management scheme based on publish/subscribe communication framework. *IEEE Systems Journal*, 11(3), 1822-1835.
- Cao, Y., Wang, T., Kaiwartya, O., Min, G., Ahmad, N., & Abdullah, A. H.** (2016). An EV charging management system concerning drivers’ trip duration and mobility uncertainty. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 48(4), 596-607.
- Cao, Y., Yang, S., Min, G., Zhang, X., Song, H., Kaiwartya, O., & Aslam, N.** (2017). A cost-efficient communication framework for battery-switch-based electric vehicle charging. *IEEE Communications Magazine*, 55(5), 162- 169.
- Chen, J., Huang, X., Tian, S., Cao, Y., Huang, B., Luo, X., & Yu, W.** (2019). Electric vehicle charging schedule considering user's charging selection from economics. *IET Generation, Transmission & Distribution*, 13(15), 3388-3396.
- Chopra R.** 2009. *Operating System (A Practical App)*. New Delhi: S.Chand & Company PVT. LTD.
- Christopher Watkins and Peter Dayan.** “Technical Note: Q-Learning”. In: *Machine Learning* 8 (May 1, 1992), pp. 279–292. doi: 10.1007/BF00992698.
- Chung, H. M., Li, W. T., Yuen, C., Wen, C. K., & Crespi, N.** (2018). Electric vehicle charge scheduling mechanism to maximize cost efficiency and user convenience. *IEEE Transactions on Smart Grid*, 10(3), 3020-3030.
- Da Silva, F. L., Nishida, C. E., Roijers, D. M., & Costa, A. H. R.** (2019). Coordination of electric vehicle charging through multiagent reinforcement learning. *IEEE Transactions on Smart Grid*, 11(3), 2347-2356.
- Dabbaghjamesh, M., Moeini, A., & Kavousi-Fard, A.** (2020). Reinforcement learning-based load forecasting of electric vehicle charging station using Q-learning technique. *IEEE Transactions on Industrial Informatics*, 17(6), 4229-4237.

- Dang, Q., Wu, D., & Boulet, B.** (2019, June). A q-learning based charging scheduling scheme for electric vehicles. In 2019 IEEE Transportation Electrification Conference and Expo (ITEC) (pp. 1-5). IEEE.
- De Weerd, M. M., Gerding, E., Stein, S., Robu, V., & Jennings, N. R.** (2013). Intention-aware routing to minimise delays at electric vehicle charging stations.
- Desaulniers, G., Errico, F., Irnich, S., & Schneider, M.** (2016). Exact algorithms for electric vehicle-routing problems with time windows. *Operations Research*, 64(6), 1388-1405.
- Diao, Y., Hellerstein, J. L., Parekh, S., Griffith, R., Kaiser, G., & Phung, D.** (2005, April). Self-managing systems: A control theory foundation. In 12th IEEE International Conference and Workshops on the Engineering of Computer-Based Systems (ECBS'05) (pp. 441-448). IEEE.
- Ding, T., Zeng, Z., Bai, J., Qin, B., Yang, Y., & Shahidepour, M.** (2020). Optimal electric vehicle charging strategy with Markov decision process and reinforcement learning technique. *IEEE Transactions on Industry Applications*, 56(5), 5811-5823.
- EBRAHIMZADEH, Ata, RANAEE, Vahid;** “Control Chart Pattern Recognition Using an Optimized Neural Network and Efficient Features”, *ISA Transactions*, Vol.49, 2010, pp.387-393.
- Eddine, M. D., & Shen, Y.** (2022). A deep learning based approach for predicting the demand of electric vehicle charge. *The Journal of Supercomputing*, 78(12), 14072-14095.
- ELMAS, Çetin;** *Yapay Sinir Ağları*, Ankara, Seçkin Yayıncılık, 1.Baskı, 2003.
- Fescioglu-Unver, N., Aktaş, M. Y., & Kasnakoğlu, C.** (2021). Feedback controlled resource management model for express service in electric vehicle charging stations. *Journal of Cleaner Production*, 311, 127629.
- Gandhi, A., Harchol-Balter, M., Raghunathan, R., & Kozuch, M. A.** (2012). Autoscale: Dynamic, robust capacity management for multi-tier data centers. *ACM Transactions on Computer Systems (TOCS)*, 30(4), 1-26.
- Gharbaoui, M., Valcarenghi, L., Bruno, R., Martini, B., Conti, M., & Castoldi, P.** (2012, March). An advanced smart management system for electric vehicle recharge. In 2012 IEEE International Electric Vehicle Conference (pp. 1-8). IEEE. **Global Electric Vehicle Outlook.** (alındığı tarih: 07.04.2023) <https://www.iea.org/reports/global-ev-outlook-2021>
- Guo, C., Yang, J., & Yang, L.** (2018). Planning of electric vehicle charging infrastructure for urban areas with tight land supply. *Energies*, 11(9), 2314.
- Guo, Q., Xin, S., Sun, H., Li, Z., & Zhang, B.** (2014). Rapid-charging navigation of electric vehicles based on real-time power systems and traffic data. *IEEE Transactions on smart grid*, 5(4), 1969-1979.
- Gusrialdi, A., Qu, Z., & Simaan, M. A.** (2017). Distributed scheduling and cooperative control for charging of electric vehicles at highway service stations. *IEEE Transactions on Intelligent Transportation Systems*, 18(10), 2713-2727.

- Gültekin, Y. B.** (2021). Traffic volume prediction using LSTM improved with rules obtained from anomalies (Master's thesis, Middle East Technical University).
- Hijry, H., & Olawoyin, R.** (2021). Predicting patient waiting time in the queue system using deep learning algorithms in the emergency room. *International Journal of Industrial Engineering*, 3(1).
- Hochreiter, S., & Schmidhuber, J.** (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hosseini, M., & MirHassani, S. A.** (2015). Selecting optimal location for electric recharging stations with queue. *KSCE Journal of Civil Engineering*, 19(7), 2271.
- Hosseini, S., & Sarder, M. D.** (2019). Development of a Bayesian network model for optimal site selection of electric vehicle charging station. *International Journal of Electrical Power & Energy Systems*, 105, 110-122.
- Huang, D., He, B., & Miao, C.** (2014). A survey of resource management in multi-tier web applications. *IEEE Communications Surveys & Tutorials*, 16(3), 1574-1590.
- HWANG, Gene, J., DING, Adam, A.;** "Prediction Intervals for Artificial Neural Networks", *Journal of the American Statistical Association*, Vol.92, No.438, 1997, pp.748-757.
- Jung, J., Chow, J. Y., Jayakrishnan, R., & Park, J. Y.** (2014). Stochastic dynamic itinerary interception refueling location problem with queue delay for electric taxi charging stations. *Transportation Research Part C: Emerging Technologies*, 40, 123-142.
- Kakillioglu, E. A., Aktaş, M. Y., & Fescioglu-Unver, N.** (2022). Self-controlling resource management model for electric vehicle fast charging stations with priority service. *Energy*, 239, 122276.
- Karaşan, A., Kaya, İ., & Erdoğan, M.** (2020). Location selection of electric vehicles charging stations by using a fuzzy MCDM method: a case study in Turkey. *Neural Computing and Applications*, 32, 4553-4574.
- Kerner, Y., Roet-Green, R., Senderovich, A., Shaposhnik, Y., & Yuan, Y.** (2021). Waiting-Time Prediction with Invisible Customers. Available at SSRN 3946696.
- Keskin, M., & Çatay, B.** (2018). A matheuristic method for the electric vehicle routing problem with time windows and fast chargers. *Computers & operations research*, 100, 172-188.
- Kim, Y., & Kim, S.** (2021). Forecasting charging demand of electric vehicles using time-series models. *Energies*, 14(5), 1487.
- Kumar, K. N., & Tseng, K. J.** (2016, November). Efficiency evaluation of coordinated charging methods used for charging electric vehicles. In 2016 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia) (pp. 270-275). IEEE.
- Kumar, K. N., Sivaneasan, B., & So, P. L.** (2015). Impact of priority criteria on electric vehicle charge scheduling. *IEEE Transactions on Transportation Electrification*, 1(3), 200-210.

- Kuo, Y. H., Chan, N. B., Leung, J. M., Meng, H., So, A. M. C., Tsoi, K. K., & Graham, C. A.** (2020). An integrated approach of machine learning and systems thinking for waiting time prediction in an emergency department. *International journal of medical informatics*, 139, 104143.
- Kyritsis, A. I., & Deriaz, M.** (2019, September). A machine learning approach to waiting time prediction in queueing scenarios. In *2019 Second International Conference on Artificial Intelligence for Industries (AI4I)* (pp. 17-21). IEEE.
- Lee, J., Issimova, Z., & Lim, H.** (2018, June). Reinforcement learning based charging station management for electric vehicles. In *Proceedings of the Ninth International Conference on Future Energy Systems* (pp. 450-452).
- Li, S., Hu, W., Cao, D., Dragičević, T., Huang, Q., Chen, Z., & Blaabjerg, F.** (2021). Electric vehicle charging management based on deep reinforcement learning. *Journal of Modern Power Systems and Clean Energy*, 10(3), 719-730.
- Li, X., Shi, M., Hu, J., He, S., Zou, D., & Jia, Y.** (2022, October). Effective Electric Vehicles Navigation Strategy Considering the Uncertainty of the Charging Load. In *2022 Asian Conference on Frontiers of Power and Energy (ACFPE)* (pp. 394-398). IEEE.
- Liang, X., Du, X., Wang, G., & Han, Z.** (2019). A deep reinforcement learning network for traffic light cycle control. *IEEE Transactions on Vehicular Technology*, 68(2), 1243-1253.
- Liu, C. H., Dai, Z., Zhao, Y., Crowcroft, J., Wu, D., & Leung, K. K.** (2019). Distributed and energy-efficient mobile crowdsensing with charging stations by deep reinforcement learning. *IEEE Transactions on Mobile Computing*, 20(1), 130-146.
- Liu, Y., Chen, W., & Huang, Z.** (2021). Reinforcement Learning-Based Multiple Constraint Electric Vehicle Charging Service Scheduling. *Mathematical Problems in Engineering*, 2021, 1-12.
- Liu, Y., Chen, W., & Huang, Z.** (2021). Reinforcement Learning-Based Multiple Constraint Electric Vehicle Charging Service Scheduling. *Mathematical Problems in Engineering*, 2021, 1-12.
- Lu F, Hua G.** A location-sizing model for electric vehicle charging station deployment based on queuing theory. In: *2015 international conference on logistics, informatics and service sciences*. IEEE: LISS); 2015. p. 1e5.
- Lu, C., Abdelzaber, T. F., Stankovic, J. A., & Son, S. H.** (2001, May). A feedback control approach for guaranteeing relative delays in web servers. In *Proceedings Seventh IEEE Real-Time Technology and Applications Symposium* (pp. 51-62). IEEE.
- Lu, C., Lu, Y., Abdelzaher, T. F., Stankovic, J. A., & Son, S. H.** (2006). Feedback control architecture and design methodology for service delay guarantees in web servers. *IEEE Transactions on Parallel and Distributed Systems*, 17(9), 1014-1027.
- Lu, F., & Hua, G.** (2015, July). A location-sizing model for electric vehicle charging station deployment based on queuing theory. In *2015*

International Conference on Logistics, Informatics and Service Sciences (LISS) (pp. 1-5). IEEE.

- Malandrino, F., Casetti, C., Chiasserini, C. F., & Reineri, M.** (2015). A game-theory analysis of charging stations selection by EV drivers. *Performance Evaluation*, 83, 16-31.
- Martonosi, S. E.** 2011. "Dynamic server allocation at parallel queues", *IIE Transactions*, 43(12), 863-877.
- MCCULLOCH, Warren, S., PITTS, Walter;** "A Logical Calculus of Ideas Imminent in Nervous Activity", *Buttein of Mathematics and. Biophysics*, Vol.5, 1943, pp.115-133. Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*, MacMillan College Publishing Co. New York.
- Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., & Riedmiller, M.** (2013). Playing atari with deep reinforcement learning. arXiv preprint arXiv:1312.5602.
- Mobility On Air Pollutants, Greenhouse Gas Emissions And Human Health, Atmospheric Environment**, 185(2018), 64-77
- Moghaddam, V., Yazdani, A., Wang, H., Parlevliet, D., & Shahnia, F.** (2020). An online reinforcement learning approach for dynamic pricing of electric vehicle charging stations. *IEEE Access*, 8, 130305-130313.
- Moradipari, A., & Alizadeh, M.** (2019). Pricing and routing mechanisms for differentiated services in an electric vehicle public charging station network. *IEEE Transactions on smart grid*, 11(2), 1489-1499.
- Mukherjee, J. C., & Gupta, A.** (2014). A review of charge scheduling of electric vehicles in smart grid. *IEEE Systems Journal*, 9(4), 1541-1553.
- Nair, L. M., & DM, M. S. R. P.** (2023). A novel modified tunicate swarm algorithm for optimal charge scheduling and pricing of electric vehicles with user priority-based charging station selection. *Concurrency and Computation: Practice and Experience*, 35(3), e7494.
- Niu, L., Zhang, P., & Wang, X.** (2018). Hierarchical power control strategy on small-scale electric vehicle fast charging station. *Journal of cleaner production*, 199, 1043-1049.
- Ogata K, Yang Y.** *Modern control engineering*, vol. 4. Prentice hall India; 2002.
- Olah, C.** (2015). *Understanding lstm networks*.
- Öztemel, E.** (2003). *Yapay sinir ağları*. PapatyaYayincilik, Istanbul.
- Palmer, J., Mitrani, I.** 2005. "Optimal and heuristic policies for dynamic server allocation", *Journal of Parallel and Distributed Computing*, 65(10), 1204-1211.
- Parekh, S., Gandhi, N., Hellerstein, J., Tilbury, D., Jayram, T., & Bigus, J.** (2001, May). Using control theory to achieve service level objectives in performance management. In *2001 IEEE/IFIP International Symposium on Integrated Network Management Proceedings*. Integrated Network

- Management VII. Integrated Management Strategies for the New Millennium (Cat. No. 01EX470) (pp. 841-854). IEEE.
- Peng, H., Jinkuan, W., & Yinghua, H.** (2012, July). Dynamic-priority-based real-time charging management for plug-in electric vehicles in smart grid. In Proceedings of the 31st Chinese Control Conference (pp. 2432-2436). IEEE.
- Qian, T., Shao, C., Li, X., Wang, X., Chen, Z., & Shahidehpour, M.** (2021). Multi-agent deep reinforcement learning method for EV charging station game. *IEEE Transactions on Power Systems*, 37(3), 1682-1694.
- Qian, T., Shao, C., Wang, X., & Shahidehpour, M.** (2019). Deep reinforcement learning for EV charging navigation by coordinating smart grid and intelligent transportation system. *IEEE transactions on smart grid*, 11(2), 1714-1723.
- Qin, H., & Zhang, W.** (2011, September). Charging scheduling with minimal waiting in a network of electric vehicles and charging stations. In Proceedings of the Eighth ACM international workshop on Vehicular inter-networking (pp. 51-60).
- R. S. Sutton and A. G. Barto**, Reinforcement learning: An introduction. MIT press Cambridge, March 1998, vol. 1, no. 1.
- Rahmani-Andebili, M., Shen, H., & Fotuhi-Firuzabad, M.** (2018). Planning and operation of parking lots considering system, traffic, and drivers behavioral model. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(9), 1879-1892.
- Said, D., & Mouftah, H. T.** (2019). A novel electric vehicles charging/discharging management protocol based on queuing model. *IEEE Transactions on Intelligent Vehicles*, 5(1), 100-111.
- Said, D., Cherkaoui, S., & Khoukhi, L.** (2015). Multi-priority queuing for electric vehicles charging at public supply stations with price variation. *Wireless Communications and Mobile Computing*, 15(6), 1049-1065.
- Schneider, M., Stenger, A., & Goeke, D.** (2014). The electric vehicle-routing problem with time windows and recharging stations. *Transportation science*, 48(4), 500-520.
- Stankovic, J. A., Lu, C., Son, S. H., & Tao, G.** (1999, June). The case for feedback control real-time scheduling. In Proceedings of 11th Euromicro Conference on Real-Time Systems. Euromicro RTS'99 (pp. 11-20). IEEE.
- Su, S., Li, H., & Gao, D. W.** (2017). Optimal planning of charging for plug-in electric vehicles focusing on users' benefits. *Energies*, 10(7), 952.
- Sun, Y., Teow, K. L., Heng, B. H., Ooi, C. K., & Tay, S. Y.** (2012). Real-time prediction of waiting time in the emergency department, using quantile regression. *Annals of emergency medicine*, 60(3), 299-308.
- Tan, J., & Wang, L.** (2015). Real-time charging navigation of electric vehicles to fast charging stations: A hierarchical game approach. *IEEE transactions on smart grid*, 8(2), 846-856.

- TEMİZEL, İlknur;** “Melas Atık Sularının Arıtımında Yukarı Akışlı Havasız Çamur Yataklı Reaktör (Yahçyr) Sisteminden Elde Edilen Biyogaz ve Metan Üretimlerinin Yapay Sinir Ağları İle Modellenmesi”, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Mühendisliği Programı, Çevre Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul, 2012.
- Tian, Z., Jung, T., Wang, Y., Zhang, F., Tu, L., Xu, C., ... & Li, X. Y.** (2016). Real-time charging station recommendation system for electric-vehicle taxis. *IEEE Transactions on Intelligent Transportation Systems*, 17(11), 3098-3109.
- Vardakas, J. S.** (2014, December). Electric vehicles charging management in communication controlled fast charging stations. In 2014 IEEE 19th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD) (pp. 115-119). IEEE.
- Wan, Z., Li, H., He, H., & Prokhorov, D.** (2018). Model-free real-time EV charging scheduling based on deep reinforcement learning. *IEEE Transactions on Smart Grid*, 10(5), 5246-5257.
- Wang, S., Bi, S., & Zhang, Y. A.** (2019). Reinforcement learning for real-time pricing and scheduling control in EV charging stations. *IEEE Transactions on Industrial Informatics*, 17(2), 849-859.
- Weeberb, J. R., Moataz, M., Christopher, D. H., Altaf, A., Mark, F.,** (2018). How Clean Are Electric Vehicles? Evidence-Based Review Of The Effects Of Electric.
- Wei W., Minghao A., Naishi C., Xianjun G., Tianjiao P.** (2016) "Multi-level Feeder Queue Optimization Charging Model of Electric Vehicle and its Implementation of M-R Algorithm", *International Journal of u- and e-Service, Science and Technology*, Vol.9, No.3, pp.199-208
- Xiao, D., An, S., Cai, H., Wang, J., & Cai, H.** (2020). An optimization model for electric vehicle charging infrastructure planning considering queuing behavior with finite queue length. *Journal of Energy Storage*, 29, 101317.
- Xiong, Y., Gan, J., An, B., Miao, C., & Bazzan, A. L.** (2017). Optimal electric vehicle fast charging station placement based on game theoretical framework. *IEEE Transactions on Intelligent Transportation Systems*, 19(8), 2493-2504.
- Xu, Y., Pan, F., & Tong, L.** (2016). Dynamic scheduling for charging electric vehicles: A priority rule. *IEEE Transactions on Automatic Control*, 61(12), 4094-4099.
- YALÇIN, Nesibe;** “Sezgisel Algoritma Öğrenmeli Yapay Sinir Ağları ile Epilepsi Hastalığının Teşhisi”, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Konya, 2012.
- Yang, Q., Sun, S., Deng, S., Zhao, Q., & Zhou, M.** (2018). Optimal sizing of PEV fast charging stations with Markovian demand characterization. *IEEE Transactions on Smart Grid*, 10(4), 4457-4466.

- Yang, S. N., Cheng, W. S., Hsu, Y. C., Gan, C. H., & Lin, Y. B.** (2013). Charge scheduling of electric vehicles in highways. *Mathematical and Computer Modelling*, 57(11-12), 2873-2882.
- Yu, Y., Si, X., Hu, C., & Zhang, J.** (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.
- Zhang, C., Liu, Y., Wu, F., Tang, B., & Fan, W.** (2020). Effective charging planning based on deep reinforcement learning for electric vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 22(1), 542-554.
- Zhang, G., Tan, S. T., & Wang, G. G.** (2017). Real-time smart charging of electric vehicles for demand charge reduction at non-residential sites. *IEEE Transactions on Smart Grid*, 9(5), 4027-4037.
- Zhang, T., Chen, W., Han, Z., & Cao, Z.** (2013). Charging scheduling of electric vehicles with local renewable energy under uncertain electric vehicle arrival and grid power price. *IEEE Transactions on Vehicular Technology*, 63(6), 2600-2612.
- Zhang, W., Liu, H., Wang, F., Xu, T., Xin, H., Dou, D., & Xiong, H.** (2021, April). Intelligent electric vehicle charging recommendation based on multi-agent reinforcement learning. In *Proceedings of the Web Conference 2021* (pp. 1856-1867).
- Zhang, X., Peng, L., Cao, Y., Liu, S., Zhou, H., & Huang, K.** (2020). Towards holistic charging management for urban electric taxi via a hybrid deployment of battery charging and swap stations. *Renewable Energy*, 155, 703-716.
- Zhang, Y., You, P., & Cai, L.** (2018). Optimal charging scheduling by pricing for EV charging station with dual charging modes. *IEEE Transactions on Intelligent Transportation Systems*, 20(9), 3386-3396.
- Zheng, Y., & Jian, L.** (2016, August). Smart charging algorithm of electric vehicles considering dynamic charging priority. In *2016 IEEE International Conference on Information and Automation (ICIA)* (pp. 555-560). IEEE.
- Zhu, J., Li, Y., Yang, J., Li, X., Zeng, S., & Chen, Y.** (2017). Planning of electric vehicle charging station based on queuing theory. *The Journal of Engineering*, 2017(13), 1867-1871.
- Zhu, J., Yang, Z., Chang, Y., Guo, Y., Zhu, K., & Zhang, J.** (2019, May). A novel LSTM based deep learning approach for multi-time scale electric vehicles charging load prediction. In *2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia)* (pp. 3531-3536). IEEE.
- Zorlu Energy Solutions**, (alındığı tarih: 07.04.2023). <https://zes.net/elektrikli-aracdunyasi.html>



EKLER

EK 1: Eğitim verisinde farklı istasyon doluluk oranının tahmin hatasına etkisi – Test verisi hedef görece bekleme oranı 1.5 olan 180 adet dizi verisi içermektedir.

EK 2: LSTM modeli için $\varphi=1.1, 1.3$ ve 1.5 koşulları altında TS=5 ve 15 olduğu örnek bir diziye ait EX ve NR test verilerinin dizi ortalamalarına karşılık RMSE değerleri.

EK 3: YSA modeli için $\varphi=1.1, 1.3$ ve 1.5 koşulları altında TS=5 ve 15 olduğu örnek bir diziye ait EX ve NR test verilerinin dizi ortalamalarına karşılık RMSE değerleri.


EK 4: $\varphi=1.1, 1.3, 1.5$ ve 1.7 , doluluk oranı 0.95 ve TS=5 ile 15 dakika koşullarıyla hazırlanmış bir EX ve NR test dizisi için gerçek ve tahmini değerlerin karşılaştırılması.

EK 1


Çizelge Ek1.: Eğitim verisinde farklı istasyon doluluk oranının tahmin hatasına etkisi

Eğitim Verisinde İstasyon Doluluk Oranı	Test verisinde İstasyon Doluluk Oranı	180 Dizi için Ortalama RMSE	180 Dizi için Maksimum RMSE
0,80-85-90-95 karma	0,95	2,03	5,61
0,95	0,95	2,08	5,55
0,80-85-90-95 karma	0,90	1,53	2,09
0,95	0,90	1,57	2,13
0,90	0,90	1,55	2,09
0,80-85-90-95 karma	0,85	1,27	1,65
0,95	0,85	1,31	1,73
0,85	0,85	1,28	1,99
0,80-85-90-95 karma	0,80	1,09	1,52
0,95	0,80	1,13	1,55
0,80	0,80	1,09	1,52


EK 2




Şekil Ek.1: TS=5 dakika, $\varphi=1.1$, EX test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.2: TS=5 dakika, $\varphi=1.3$, EX test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.3: TS=5 dakika, $\varphi=1.5$, EX test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.4: TS=5 dakika, $\varphi=1.1$, NR test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.5: TS=5 dakika, $\varphi=1.3$, NR test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.6: TS=5 dakika, $\varphi=1.5$, NR test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.7: TS=15 dakika, $\varphi=1.1$, EX test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.8: TS=15 dakika, $\varphi=1.3$, EX test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.9: TS=5 dakika, $\varphi=1.5$, EX test verisi ortalaması ve RMSE dağılımı.



Şekil Ek.10: TS=15 dakika, $\varphi=1.1$, NR test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.11: TS=15 dakika, $\varphi=1.3$, NR test verisi ortalaması ve RMSE dağılımı.



Şekil Ek.12: TS=15 dakika, $\varphi=1.5$, NR test verisi ortalaması ve RMSE dağılımı.


EK 3

YSA Görece Bekleme Oranı 1.1 iken EX dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=5)




Şekil Ek.13: TS=5 dakika, $\varphi=1.1$, EX test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.3 iken EX dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=5)



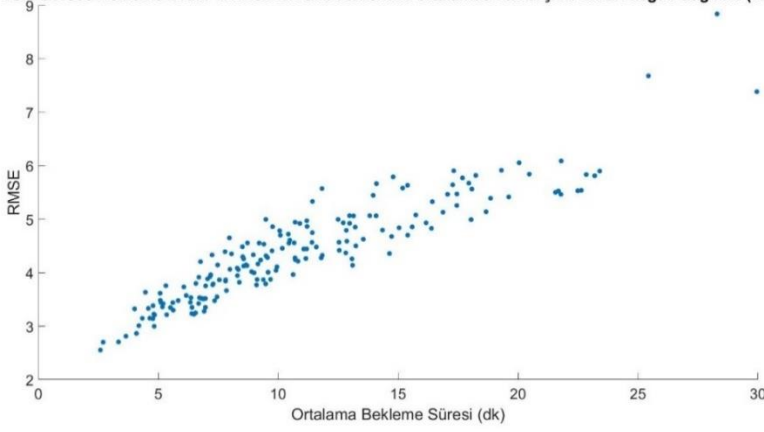
Şekil Ek.14: TS=5 dakika, $\varphi=1.3$, EX test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.5 iken EX dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=5)



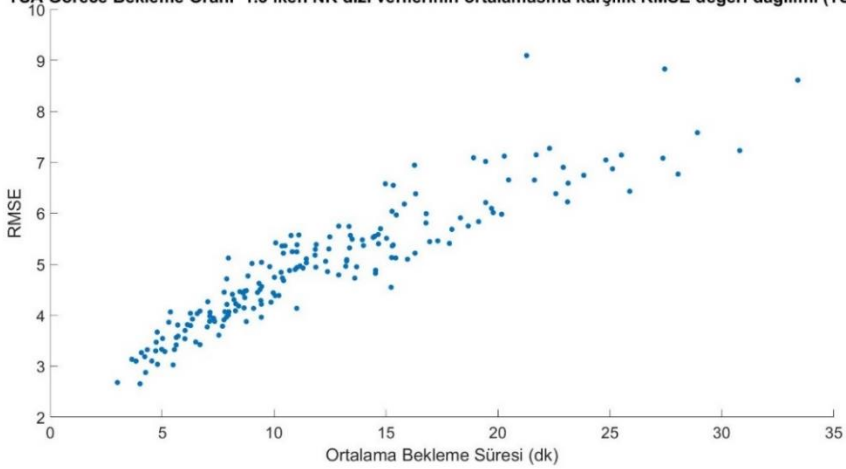
Şekil Ek.15: TS=5 dakika, $\varphi=1.5$, EX test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.1 iken NR dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=5)




Şekil Ek.16: TS=5 dakika, $\varphi=1.1$, NR test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.3 iken NR dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=5)




Şekil Ek.17: TS=5 dakika, $\varphi=1.3$, NR test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.5 iken NR dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=5)



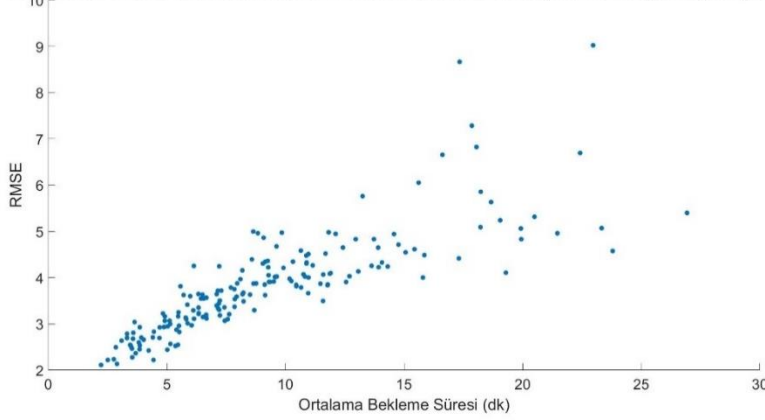
Şekil Ek.18: TS=5 dakika, $\varphi=1.5$, NR test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.1 iken EX dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=15)




Şekil Ek.19: TS=15 dakika, $\varphi=1.1$, EX test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.3 iken EX dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=15)



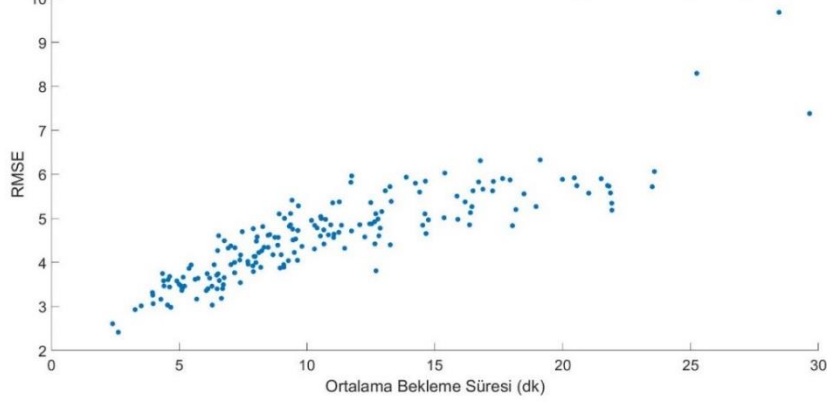
Şekil Ek.20: TS=15 dakika, $\varphi=1.3$, EX test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.5 iken EX dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=15)




Şekil Ek.21: TS=15 dakika, $\varphi=1.5$, EX test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.1 iken NR dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=15)




Şekil Ek.22: TS=15 dakika, $\varphi=1.1$, NR test verisi ortalaması ve RMSE dağılımı.

YSA Görece Bekleme Oranı 1.3 iken NR dizi verilerinin ortalamasına karşılık RMSE değeri dağılımı (TS=15)




Şekil Ek.23: TS=15 dakika, $\varphi=1.3$, NR test verisi ortalaması ve RMSE dağılımı.




Şekil Ek.24: TS=15 dakika, $\varphi=1.5$, NR test verisi ortalaması ve RMSE dağılımı.


EK 4




Şekil Ek.25: TS=5 dakika, $\varphi=1.1$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.26: TS=5 dakika, $\varphi=1.3$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.27: TS=5 dakika, $\varphi=1.5$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.28: TS=5 dakika, $\varphi=1.7$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.29: TS=5 dakika, $\varphi=1.1$, NR gerçekleşen değer ve tahmin değerleri.




Şekil Ek.30: TS=5 dakika, $\varphi=1.3$, NR gerçekleşen değer ve tahmin değerleri.




Şekil Ek.31: TS=5 dakika, $\phi=1.5$, NR gerçekleşen değer ve tahmin değerleri.




Şekil Ek.32: TS=5 dakika, $\phi=1.7$, NR gerçekleşen değer ve tahmin değerleri.




Şekil Ek.33: TS=15 dakika, $\varphi=1.1$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.34: TS=15 dakika, $\varphi=1.3$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.35: TS=15 dakika, $\varphi=1.5$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.36: TS=15 dakika, $\varphi=1.7$, EX gerçekleşen değer ve tahmin değerleri.




Şekil Ek.37: TS=15 dakika, $\varphi=1.1$, NR gerçekleşen değer ve tahmin değerleri.



Şekil Ek.38: TS=15 dakika, $\varphi=1.3$, NR gerçekleşen değer ve tahmin değerleri.



Şekil Ek.39: TS=15 dakika, $\varphi=1.5$, NR gerçekleşen değer ve tahmin değerleri.



Şekil Ek.40: TS=15 dakika, $\varphi=1.7$, NR gerçekleşen değer ve tahmin değerleri.