

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI

ELEKTRİKLİ ARAÇLAR İÇİN YAPAY ZEKA TABANLI
REJENERATİF ENERJİ DENETİMİ

DOKTORA TEZİ

ÖMER BOYACI

DENİZLİ, ARALIK - 2022

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



ELEKTRİKLİ ARAÇLAR İÇİN YAPAY ZEKA TABANLI
REJENERATİF ENERJİ DENETİMİ

DOKTORA TEZİ

ÖMER BOYACI

DENİZLİ, ARALIK - 2022

Bu tez çalışması Pamukkale Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından 2020FEBE044 nolu proje ile desteklenmiştir.

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.

ÖMER BOYACI

ÖZET

**ELEKTRİKLİ ARAÇLAR İÇİN YAPAY ZEKA TABANLI
REJENERATİF ENERJİ DENETİMİ
DOKTORA TEZİ
ÖMER BOYACI
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DOÇ. DR. SELAMİ KESLER)**

DENİZLİ, ARALIK - 2022

Ulaşım sektörü enerji tüketiminde önemli bir paya sahip olup bu sektörde genellikle fosil yakıtlı kaynaklar kullanılmaktadır. Petrol türevi olan bu kaynaklar karbon salınımları nedeniyle çevresel problemler oluşturmaktadır. Aynı zamanda araçlarda çoğunlukla içten yanmalı motorlar kullanılmaktadır ve bu motorların verimleri nispeten düşüktür.

Elektrikli araçlar, içten yanmalı araçlardan farklı olarak bünyelerinde motor, sürücü ve batarya gibi üç temel bileşen içerir ve araç menzili önemli ölçüde bataryanın enerji kapasitesine bağlıdır. Dolayısıyla, bu enerjinin verimli kullanılması sürüş menzilini artıracak gibi sürüş maliyetini de azaltacaktır. Elektrikli araçlarda, sürüş ve sürücü profiline göre, araç elektrik motorunun etkin kontrolü ile yavaşlama gerektiren yerlerde güç geri kazanımı yapılarak, ihtiyaç halinde kullanılmak üzere, bataryaya enerji depolanabilmektedir. Ayrıca, bu kazanım ile aracın sürtünmeli frenlemesi azaltılarak disk ve balata gibi aksamalar daha uzun süre kullanılmasına imkân sağlamaktadır. Frenleme anında aracın mevcut durumuna bağlı olarak mekanik ve rejeneratif fren miktarını, araç ve sürücü parametrelerinden bağımsız olarak kestirip sürüş mesafesini daha etkin hale getirebilmenin en iyi yollarından biri de insan gibi düşünen Yapay Zeka tabanlı bir rejeneratif enerji denetim sistemi oluşturmaktır.

Bu tez çalışmasında, öncelikle bir elektrikli araç sistemi için benzetim modeli oluşturulmuş ve deneysel çalışmalar yapabilmek için laboratuvar ortamında endüstriyel tip test platformu tasarlanıp gerçekleştirilmiştir. Farklı koşulları içeren durum çalışmaları, benzetim modeli ve test platformunda çalıştırılmış ve bu sayede öğrenme modeli için gerekli veri seti elde edilmiştir. Öğrenen rejeneratif enerji denetim sistemi modeli için, Makine Öğrenmesi algoritmalarından, Doğrusal Regresyon, K-En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritması olmak üzere dört farklı model oluşturulmuş ve modellerin tahmin performans değerleri karşılaştırılmıştır. En iyi tahmin doğruluğu sonuçlarını veren Rastgele Orman algoritmasıyla oluşturulan öğrenme modeli araç test sisteminde geliştirilmiş bir sürüş profili için kullanılarak benzetim modelinin deneysel doğrulaması yapılmış ve başarılı sonuçlar elde edilmiştir.

ANAHTAR KELİMELER: Elektrikli Araç, Rejeneratif Enerji, Yapay Zeka, Makine Öğrenmesi, Rastgele Orman, Test Sistemi

ABSTRACT

ARTIFICIAL INTELLIGENCE BASED REGENERATIVE ENERGY CONTROL FOR ELECTRIC VEHICLES

**PH.D THESIS
ÖMER BOYACI**

**PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE
ELECTRICAL AND ELECTRONICS ENGINEERING
(SUPERVISOR: ASSOC. PROF. DR. SELAMİ KESLER)**

DENİZLİ, DECEMBER 2022

The transportation sector has a significant share in energy consumption and fossil fuel resources are generally used in this sector. These petroleum-derived resources cause environmental problems due to carbon emissions. At the same time, mostly internal combustion engines are used in vehicles and the efficiency of these engines is relatively low.

Electric vehicles, unlike internal combustion vehicles, contain three basic components such as engine, driver and battery, and vehicle range is highly dependent on the energy capacity of the battery. Therefore, the efficient use of this energy will increase the driving range and reduce the driving cost. In electric vehicles, energy can be stored in the battery to be used in case of need, by recovering power in places that require deceleration with the effective control of the vehicle electric motor according to the driving and driver profile. In addition, with this gain, the frictional braking of the vehicle is reduced, allowing components such as discs and pads to be used for a longer period of time. One of the best ways to predict the amount of mechanical and regenerative braking depending on the current state of the vehicle at the moment of braking, independently of vehicle and driver parameters, and to make the driving distance more effective is to create an artificial intelligence-based regenerative energy control system that thinks like a human.

In this thesis, first of all, a simulation model for an electric vehicle system has been created and an industrial type test platform has been designed and realized in the laboratory environment in order to conduct experimental studies. Case studies involving different conditions are run on the simulation model and test platform, and thus the necessary data set for the learning model is obtained. For the learning regenerative energy control system model, four different models from Machine Learning algorithms, namely Linear Regression, K-Nearest Neighbor, Decision Tree and Random Forest algorithm are employed and the prediction performance values of the models are compared. The learning model created with the Random Forest algorithm, which gives the best prediction accuracy results, is used for a generalized driving profile in the vehicle test system, experimental verification of the simulation model is made and successful results are obtained.

KEYWORDS: Electric vehicle, Regenerative Energy, Artificial Intelligence, Machine Learning, Random Forest, Test System

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	viii
SEMBOL LİSTESİ	ix
KISALTMALAR LİSTESİ	xi
ÖNSÖZ	xiii
1. GİRİŞ	1
1.1 Genel Bilgiler	1
1.2 Literatür Özeti	2
1.3 Tezin Amacı	7
1.4 Materyal ve Yöntem	7
1.5 Tezin Katkısı	8
2. ELEKTRİKLİ ARAÇLAR	10
2.1 Elektrikli Araç Dinamik Denklemleri	12
2.2 Rejeneratif Frenleme	15
2.3 Rejeneratif Frenlemede Sürücü Davranışı	16
2.3.1 Paralel Rejeneratif Frenleme	20
2.3.2 Seri Rejeneratif Frenleme	20
2.3.3 Rejeneratif Mod Çalışma Modeli	21
2.4 Elektrikli Araç Benzetim Modelinin Oluşturulması	23
2.4.1 Araç Mekanik Modeli	23
2.4.2 Fren Kontrol Modeli	24
2.4.3 Motor Modeli	25
2.4.4 Hız Kontrol Modeli	28
2.4.5 Batarya Modeli	28
2.4.6 Sürüş Profili Modeli.....	30
2.4.6.1 Sürüş Profilleri	31
2.4.7 Öğrenme Modeli Bloğu	33
2.4.8 Parametre Görüntüleme ve Veri Kayıt	34
3. ÖĞRENME ALGORİTMALARI	35
3.1 Denetimsiz Öğrenme	36
3.2 Takviyeli Öğrenme	36
3.3 Denetimli Öğrenme	36
3.3.1 Doğrusal Regresyon Algoritması.....	37
3.3.2 KNN Algoritması.....	38
3.3.3 Karar Ağacı Algoritması.....	38
3.3.4 Rastgele Orman Algoritması	40
3.4 Makine Öğrenmesi İle Model Oluşturma.....	41
3.4.1 Problemin Belirlenmesi	42
3.4.2 Veri Seti Oluşturma	43
3.4.3 Verilerin Eğitim ve Test Verisi Olarak Ayrılması.....	44
3.4.4 Oluşturtulan Modelin Test Verisi Kullanarak Test Edilmesi	44
3.4.5 Oluşturtulan Modelin Gerçek Uygulamada Test Edilmesi.....	44

3.5	Algoritmaların Değerlendirilmesinde Kullanılan Performans Ölçüm Metrikleri.....	45
3.5.1	R ² Determinasyon Katsayısı	45
3.5.2	Ortalama Kare Hatası (MSE).....	46
3.5.3	Kök Ortalama Kare Hatası (RMSE)	46
3.5.4	Ortak Mutlak Hata (MAE).....	47
4.	ELEKTRİKLİ ARAÇLAR İÇİN TEST SİSTEMİ TASARIMI	48
4.1	Test Sisteminde Kullanılan Ekipmanlar	48
4.1.1	Analizörler	49
4.1.1.1	Güç Analizörü	49
4.1.1.2	AC Analizör	49
4.1.1.3	DC Analizör	50
4.1.2	Servo Motor ve Sürücü	52
4.1.3	Tork Sensörü.....	53
4.1.4	Motor Yükleme Sehpaı	53
4.1.5	Denetleyici	54
4.1.6	İnsan Makine Arayüzü (HMI)	56
4.1.7	Elektrikli Araç Batarya Ünitesi.....	60
4.1.8	BLDC Motor	61
4.1.9	Motor Sürücü	62
4.2	Deney Setinin Oluşturulması.....	64
5.	DURUM ÇALIŞMALARI VE DEĞERLENDİRMELER.....	65
5.1	Benzetim Modelinde Durum Çalışmaları.....	65
5.1.1	Benzetim Çalışması Durum-1	66
5.1.2	Benzetim Çalışması Durum-2.....	68
5.1.3	Benzetim Çalışması Durum 3	70
5.1.4	Benzetim Çalışması Durum-4.....	72
5.1.5	Benzetim Çalışması Durum-5.....	74
5.2	Test Sisteminde Yapılan Deneysel Çalışmalar.....	76
5.2.1	Durum-1 için Deneysel Çalışma.....	77
5.2.2	Durum-2 için Deneysel Çalışma.....	78
5.2.3	Durum-3 için Deneysel Çalışma.....	80
5.2.4	Durum-4 için Deneysel Çalışma.....	81
5.2.5	Durum-5 için Deneysel Çalışma.....	82
5.3	Deneysel Çalışmalarda Rejeneratif Enerji Sonuçları	84
5.4	Öğrenme Algoritma Sonuçları ve Değerlendirme.....	84
5.4.1	Doğrusal Regresyon Algoritması Bulguları	86
5.4.2	KNN Algoritması Bulguları.....	88
5.4.3	Karar Ağacı Algoritması Bulguları.....	90
5.4.4	Rastgele Orman Algoritması Bulguları	92
5.4.5	Algoritma Performanslarının Karşılaştırılması.....	94
5.5	Deneysel Sonuçlar ve Değerlendirme	95
5.5.1	RO Algoritmasının Deneysel Değerlendirilmesi	95
6.	SONUÇ VE ÖNERİLER	101
7.	KAYNAKLAR.....	103
8.	ÖZGEÇMİŞ	109

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: Tasarlanan EA test sisteminin modeli.....	8
Şekil 2.1: EA’larda kullanılan bileşenler ve alt bileşenleri (Tümbek, 2019). ..	10
Şekil 2.2: EA’larda kullanılan motor türleri.....	11
Şekil 2.3: EA’larda kullanılan tahrik yapıları.....	11
Şekil 2.4: Elektrikli aracın maruz kaldığı kuvvetler.....	12
Şekil 2.5: BLDC motorunun sürücü modeli.....	17
Şekil 2.6: BLDC motor sürücü rejeneratif çalışma anahtarlama modları.....	18
Şekil 2.7: Frenleme modelinin genel yapısı.....	21
Şekil 2.8: Fren dağılım sistemi kontrolü akış diyagramı.....	22
Şekil 2.9: Elektrikli aracın Matlab / Simulink’de oluşturulmuş benzetim modeli.....	23
Şekil 2.10: Elektrikli aracın mekanik benzetim modeli.....	24
Şekil 2.11: Elektrikli aracın fren kontrol modeli.....	25
Şekil 2.12: BLDC motor eşdeğer devresi.....	26
Şekil 2.13: BLDC motor benzetim modeli.....	27
Şekil 2.14: Benzetim çalışmasında kullanılan elektrik motorunun verim haritası.....	27
Şekil 2.15: Elektrikli aracın hız kontrol modeli.....	28
Şekil 2.16: Batarya hücre eşdeğer devresi.....	29
Şekil 2.17: Matlab/Simulink’de oluşturulan batarya benzetim modeli.....	30
Şekil 2.18: Benzetim modelinde sürüş profili seçme bloğu.....	31
Şekil 2.19: Kullanılan sürüş profilleri; a) NYCC, b) JAPAN 10, c) ECE, d) WLTP Class 1.....	32
Şekil 2.20: ECE sürüş döngüsünde frenleme torku ve araç hız grafiği.....	33
Şekil 2.22: Benzetim modelinde tahmin bloku.....	33
Şekil 2.21: a) Test sitemi parametrelerini görüntüleme bloğu, b) Veri kayıt bloku.....	34
Şekil 3.1: Makine Öğrenmesi türleri.....	35
Şekil 3.2: DR eğrisi.....	37
Şekil 3.3: KA algoritması bileşenlerinin gösterimi.....	39
Şekil 3.4: RO algoritmasının oluşumu.....	40
Şekil 3.5: RO algoritmasında oylama yöntemi ile tahminin oluşumu.....	41
Şekil 3.6: Öğrenme aşamaları (Kotsiantis, 2007).....	42
Şekil 3.7: Veri seti için oluşturulan karma hız profili.....	44
Şekil 4.1: Elektrikli araçlar için rejeneratif mod test platform modeli.....	48
Şekil 4.2: Test platformunda kullanılan güç analizörü.....	49
Şekil 4.3: Test platformunda kullanılan AC analizör (ENTES).....	50
Şekil 4.4: a) Test platformunda kullanılan DC analizör (CET), b) Şönt direnç.....	50
Şekil 4.5: Test platformunda kullanılan DC analizör batarya bağlantısı (CET).....	51
Şekil 4.6: a) Test platformunda kullanılan servo motor, b) servo motor sürücü.....	52
Şekil 4.7: Servo motor sürücü rejeneratif frenleme direnci.....	53
Şekil 4.8: Test platformunda kullanılan tork sensörü.....	53

Şekil 4.9: Test platformunda kullanılan motor yükleme ünitesi.....	54
Şekil 4.10: Test platformunda kullanılan denetleyici.	55
Şekil 4.11: Test platformunda kullanılan HMI.....	56
Şekil 4.12: Test platformunda kullanılan HMI giriş ekranı.....	57
Şekil 4.13: Test platformunda kullanılan HMI ayarlamaları giriş ekranı.....	57
Şekil 4.14: HMI araç parametre verilerinin giriş ekranı.....	58
Şekil 4.15: Test platformunda kullanılan HMI ana ekranı.	59
Şekil 4.16: HMI akım, gerilim, güç görüntüleme ekranı.....	59
Şekil 4.17: EA batarya ünitesi	60
Şekil 4.18: BLDC motor görünümü.	61
Şekil 4.19: BLDC motor sürücü görünümü.....	62
Şekil 4.20: Sürücü parametre ayarları; a) Sayfa 1 b) Sayfa 2 c) Sayfa 3 d) Sayfa 4 e) Sayfa 5.	63
Şekil 4.21: EA'lar için rejeneratif enerji denetimi test platformu görünümü... 64	64
Şekil 5.1: Referans hız ile araç hızının karşılaştırılması.	66
Şekil 5.2: Durum-1 motor, fren ve toplam torkun karşılaştırılması.	67
Şekil 5.3: Durum-1 enerji ve güç değerlerinin karşılaştırılması.....	68
Şekil 5.4: Durum-2 motor, fren ve toplam torkun karşılaştırılması.	69
Şekil 5.5: Durum-2 enerji ve güç değerlerinin karşılaştırılması.....	70
Şekil 5.6: Durum-3 motor, fren ve toplam torkun karşılaştırılması.	71
Şekil 5.7: Durum-3 enerji ve güç değerlerinin karşılaştırılması.....	72
Şekil 5.8: Durum-4 motor, fren ve toplam torkun karşılaştırılması.	73
Şekil 5.9: Durum-4 enerji ve güç değerlerinin karşılaştırılması.....	74
Şekil 5.10: Durum-5 motor, fren ve toplam torkun karşılaştırılması.	75
Şekil 5.11: Durum-5 motor, fren ve toplam torkun karşılaştırılması.	76
Şekil 5.12: Düz yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.	78
Şekil 5.13: Düz yol rejeneratif mod aktif sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.	79
Şekil 5.14: Rejeneratif frenleme ile yokuş yukarı yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.....	81
Şekil 5.15: Rejeneratif frenleme ile yokuş aşağı yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.....	82
Şekil 5.16: Rejeneratif frenleme ve 50 kg yük ile düz yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.....	83
Şekil 5.17: DR algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.	86
Şekil 5.18: DR algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.	87
Şekil 5.19: KNN algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.	88
Şekil 5.20: KNN algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.	89
Şekil 5.21: KA algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.	90
Şekil 5.22: KA algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.	91
Şekil 5.23: RO algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.	92
Şekil 5.24: RO algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.	93

Şekil 5.25: Algoritmaların karşılaştırılması, a) R^2 , b) MSE, c) RMSE, d) MAE değeri.....	94
Şekil 5.26: RO algoritması ile WLTP Class 1 sürüş profilinde gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.....	96
Şekil 5.27: RO algoritması ile WLTP Class 1 sürüş profilinde gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.....	97
Şekil 5.28: Test sisteminde WLPT Class 1 sürüş profili deneyinde referans hız ile ölçülen araç hızının karşılaştırılması.....	98
Şekil 5.29: Test sisteminde WLPT Class 1 sürüş profili deneyinde tahmin edilen motor torku ile ölçülen motor torkunun karşılaştırılması....	99
Şekil 5.30: WLPT Class 1 Sürüş profili deneyinde güç ile SoC değerinin karşılaştırılması.	99
Şekil 5.31: WLPT Class 1 sürüş profili deneyinde akım ile gerilim değerinin karşılaştırılması.	100

TABLO LİSTESİ

Sayfa

Tablo 2.1: Sürüş profillerinin teknik özellikleri.....	31
Tablo 3.1: Öğrenme algoritmalarında kullanılan veri seti.	43
Tablo 4.1: Batarya hücresinin karakteristik özellikleri.	60
Tablo 4.2: BLDC motor etiket değerleri.	61
Tablo 4.3: BLDC motor sürücü etiket değerleri.	62
Tablo 5.1: Benzetim çalışmalarında kullanılan araca ilişkin parametreler.	65
Tablo 5.2: Deneysel çalışmalardan alınan enerji değerleri.	84
Tablo 5.3: Öğrenme algoritmalarında kullanılan araca ilişkin giriş çıkış parametreleri.....	85
Tablo 5.4: DR algoritması ölçüm değerleri.....	87
Tablo 5.5: KNN algoritması ölçüm değerleri.....	89
Tablo 5.6: KA algoritması ölçüm değerleri.	91
Tablo 5.7: RO algoritması performans ölçüm değerleri.	93
Tablo 5.8: WLTP Class 1 sürüş profilinin Rastgele Orman algoritması ile performans ölçüm değerleri.	95

SEMBOL LİSTESİ

F_{te}	: Aracın yola aktardığı hareket kuvveti
F_{la}	: İvmelenme kuvveti
F_{ad}	: Aerodinamik kuvvet
F_{rr}	: Yuvarlanma sürtünmesi kuvveti
F_{Gx}	: Eğim direnci kuvveti
K_r	: Yuvarlanma direnci katsayısı
A	: Aracın ön yüzey alanı
V	: Araç hızı
r	: Tekerlek yarıçapı
α	: Aracın yüzeyle yaptığı açı
g	: Yer çekimi ivmesi
ρ	: Havanın yoğunluğu
T	: Tork
m	: Aracın kütlesi
a	: Aracın ivmesi
C_d	: Havanın sürtünme katsayısı
P	: Güç
L	: Faz Endüktansı
R	: Faz Direnci
I_a	: A fazı Endüvi Akımı
I_b	: B fazı Endüvi Akımı
I_c	: C fazı Endüvi Akımı
e_a	: A fazı zıt elektro motor kuvvet
e_b	: B fazı zıt elektro motor kuvvet
e_c	: C fazı zıt elektro motor kuvvet
H_a	: A fazı Hall etkili sensör
H_b	: B fazı Hall etkili sensör
H_c	: C fazı Hall etkili sensör
$S1 - S5$: Anahtarlama elamanları
EC	: Bataryadan alınan elektrik enerjisi
SOC_0	: Batarya doluluk oranı başlangıç değeri
ΔSOC	: Doluluk oranı değişimi adım aralığı
T_e	: Elektrik motoru torku
T_l	: Yük torku
J	: Atalet momenti
B	: Sürtünme katsayısı
K_t	: Motor tork sabiti
V_{emk}	: Zıt elektro motor kuvvet
R_b	: Bataryanın eşdeğer iç direnci
ω	: Açısal hız
D	: Görev döngüsü
V_{bat}	: Batarya voltajı
V_{oc}	: Bataryanın açık devre voltajı
Q	: Batarya amper-saat kapasitesi
$\beta_0 \dots \beta_n$: Doğrusal denklemin katsayıları
$x_1 \dots x_n$: Bağımsız değişkenler

e	: Regresyon sabiti
y	: Bağımlı değişken
b_n	: Uzaklık Fonksiyonu
k	: Komşu sayısı
N	: Veri sayısı
$p(x)$: Belirli bir özelliğe sahip örnek yüzdesi
$H(X)$: Entropi değeri
y_i	: Gerçek veri
y'_i	: Tahmin edilen veri

KISALTMALAR LİSTESİ

BLDC	: Fırçasız doğru akım motoru
ECE	: Avrupa şehir içi sürüş profili (Europe Elementary Urban Cycle)
US06	: Tamamlayıcı federal test prosedürü (Supplemental Federal Test Procedure)
LA92	: Birleşik dinamometre sürüş programı (Unified Dynamometer Driving Schedule)
NYCC	: New York şehir sürüş profili (New York City Cycle)
WLTP	: Dünya çapında uyumlaştırılmış hafif araçlar testi (Worldwide Harmonized Light Vehicles Test Procedure)
EA	: Elektrikli araç
İYM	: İçten yanmalı motor
IEA	: Uluslararası enerji ajansı
IM	: İndüksiyon motoru
SRM	: Anahtar relüktans motor
PMSM	: Sabit Mıknatıslı Senkron Motor
MIL	: Döngü içinde model testi (Model-in-the-Loop)
SIL	: Döngü içinde yazılım testi (Software-in-the-Loop)
VIL	: Döngü içinde araç testi (Vehicle-in-the-Loop)
HIL	: Döngü içinde donanım testi (Hardware-in-the-Loop)
PLC	: Programlanabilir Mantık Denetleyici (Programmable Logic Controller)
HMI	: İnsan makine arayüzü (Human Machine Interface)
RBCS	: Tek pedallı rejeneratif frenleme kontrol stratejisi
TCP/IP	: İnternet iletişim protokolü (Transmission Control Protocol/ Internet Protocol)
EMK	: Elektro motor kuvvet
PWM	: Darbe genişlik modülasyonu
YSA	: Yapay sinir ağları
DC	: Doğru akım
AC	: Alternatif akım
SoC	: Batarya doluluk oranı
PMSM	: Sabit mıknatıslı senkron motor
MTrq	: Motor rotorundan gelen tork verisi
Brk	: Frenleme bilgisi
Slp	: Eğim verisi
rpm	: Dakikadaki tur sayısı
VSpeed	: Aracın tekerlerinden alınan hız bilgisi
RefMTrq	: Rejeneratif fren torku
CTorq	: Araç motorunun üretmesi gereken tork
NiMH	: Nikel metal hidrat
Ni Cad	: Nikel kadmiyum
DR	: Doğrusal regresyon
KNN	: K-En yakın komşu (K-Nearest Neighbors)
KA	: Karar Ağacı
RO	: Rastgele Orman
SVM	: Destek vektör makineleri

- CART** : Sınıflandırma ve regresyon ağacı (Classification And Regression Tree)
- MAE** : Ortalama mutlak hata
- R²** : Determinasyon katsayısı
- OFT** : Ortalama farkların toplamı
- RMSE** : Kök ortalama kare hata
- HKT** : Hata karelerinin toplamı
- PID** : Oransal-integral-türevsel denetleyici
- MSE** : Ortalama kare hata
- CANBUS**: Elektronik iletişim veri yolu (Controller Area Network Bus)
- RS232** : Seri haberleşme protokolü

ÖNSÖZ

Öncelikle karşılaştığım tüm zorluklarda destekleyen, anlayışla ve sabırla karşılayan eşime, tez süresince çok fazla vakit geçiremediğim ve beni sabırla bekleyen üzmeyen oğullarıma çok teşekkür ederim. Her zaman beni destekleyen ve her koşulda yanımda olan anneme minnettarım.

Tez çalışmam ve okul hayatım boyunca bana yol gösteren, lisans öğrenimimden bu yana öğrencisi olmaktan onur ve gurur duyduğum, ayrıca tecrübe ve bilgilerinden faydalandığım danışmanım saygı değer hocam Doç. Dr. Selami KESLER'e saygı ve sevgi şükranlarımı sunarım. Her zaman her koşulda desteğini esirgemeyen değerli dostum çalışma arkadaşım Dr. Öğr. Üyesi Mustafa TÜMBEK'e, çok teşekkür ederim.

İnsani ve ilmi değerlerinden edindiğim tecrübelerden dolayı, bu tezin izleme jürisi üyelerinden Doç. Dr. Selim KÖROĞLU'na, Prof. Dr. Yusuf ÖNER'e ve Prof. Dr. Okan BİNGÖL'e en içten teşekkür ve saygılarımı sunarım. Tez çalışmamda yardımlarını esirgemeyen Dr. Öğr. Üyesi Akif DEMİRÇALI'ya desteklerinden dolayı minnetlerimi sunarım.

1. GİRİŞ

1.1 Genel Bilgiler

Elektrikli Araçlar (EA), 19. yüzyılın sonlarına doğru icat edilmiş, kullanım kolaylığı ve konforu sayesinde fosil yakıtlı araçlara göre daha fazla talep görmüştür. Ancak, 20. yüzyılın ortalarında içten yanmalı motorların (İYM) seri üretime geçmesi, düşük maliyetleri ve uzun sürüş mesafeleri nedeniyle EA'lara olan ilgi giderek azalmıştır. 20'nci yüzyılın ortalarında dünya ekonomik krizinin etkisi ve küresel ısınma sorunlarının ortaya çıkmasıyla alternatif enerji kaynakları arayışı zorunlu hale geldi. Hızla gelişen teknoloji sayesinde ülkeler petrole olan bağımlılıklarını azaltmak ve karbon emisyonlarını düşürmek için bir çözüm olarak EA'lara ilgi duymaktadır (Chan 2007).

Son on yıldır otomotiv firmaları da EA'lara olan ilgiye kayıtsız kalmamış ve EA'lardaki menzil problemini aşmak için hibrit araçları piyasaya sürmüşlerdir. EA'lara olan ilginin artması ve batarya teknolojisinin gelişmesiyle birlikte saf EA'lar üretilmeye başlanmıştır. Ancak EA'lara olan yoğun ilgi nedeniyle enerji talebi her geçen gün artmaktadır. Uluslararası Enerji Ajansı (IEA) 2020 Dünya Enerji Görünümü Raporu'na göre, ulaşım sektörünün enerji talebi 2018 yılında 51 TWh iken 2040 yılında 1551 TWh olması bekleniyor. Ulaşım sektörüne benzer şekilde diğer sektörlerde de elektrik enerjisine olan talebin artacağı düşünüldüğünde, talebin alternatif enerji kaynakları ile karşılanması sürdürülebilir değildir. Enerji arz-talep dengesinin sağlanması için Haziran 2020 IEA raporunda yapılan açıklamada, elektrik sektöründe daha verimli araçların tasarlanmasının önemi ortaya çıkmıştır (World Energy Outlook 2020). Bu çalışmada, gelecekte enerji talebinin önemli bir kısmını oluşturan EA'larda yapılacak en küçük iyileştirmelerin etkisinin büyük olduğu belirtilmiştir. EA'larda enerji tüketimini azaltmak için öncelikle daha verimli ve geliştirilmiş EA bileşenleri tasarlamak gerekiyor (Gundabattini ve diğ. 2021; Barhouni ve diğ. 2021). Buna ek olarak, optimize edilmiş sürüş algoritmaları daha az

enerji tüketimi gerçekleştirebilir. Böylece, sürüş verimliliğini artırarak insanlar sınırlı enerji kapasitesi ile daha uzun menzilli seyahat edebilirler.

EA'larda enerji tüketiminde rol oynayan önemli parametrelerden, sürüş ve sürücü profili göz önüne alınarak; insan gibi düşünen, öğrenen, öğrendiklerinden hareketle farklı araç, farklı sürücü ve farklı sürüş profilleri için enerji tüketimini en aza indiren ya da bu profillere göre sürüş menzilini artırmak üzere rejeneratif enerji kestirimi ve yönetimi yapabilen Yapay Zeka tabanlı sistemlere ihtiyaç ve güven artmaktadır.

1.2 Literatür Özeti

EA'lar araç gövdesi, batarya, sürücü, elektrik motoru ve aktarma mekanizmasından oluşmaktadır. Genel olarak bataryada depolanan elektrik enerjisi, elektrik motoru tarafından mekanik enerjiye dönüştürülür ve güç aktarma organları sayesinde aracın tekerleklerine aktararak tahrik gerçekleştirilir. Aracın hızı ve ivmelenmesi çekiş gücüne, araç kütlesine, yuvarlanma direncine, aerodinamik sürtünmeye, yokuş direncine ve aracın fiziksel özelliklerine bağlıdır.

EA'larda kullanılan bileşenler tasarımlarına ve topolojilerine göre farklılık göstermektedir. Literatürde bugüne kadar altı farklı şanzıman topolojisi sunulmuştur. Bu topolojiler arasında en çok beğenilen topoloji tek seviyeli dişli topolojisidir. Bu topolojiyi ele alan bir çalışmada, EA'lar için müşteri gereksinimleri ve motor karakteristikleri de sunulmuştur (Due ve Cheng 2008). EA'lara olan ilginin arttığı yıllarda yapılan bir başka çalışmada, EA'lar için önerilen DC, Endüksiyon, Relüktans ve Sabit Mıknatıslı motorlar karşılaştırılmıştır. Bu çalışmada da belirtildiği gibi, başlangıçta sürüş kolaylığı nedeniyle büyük ilgi gören DC motorlar, motor sürücülerinin ve etkin kontrol yöntemlerinin geliştirilmesi sayesinde yerini AC motorlara bırakmıştır (West 1994). Ayrıca DC motorlar, Fırçasız DC (BLDC) motorlar, Sabit Mıknatıslı Senkron Motor (PMSM), Line-Start PMSM, İndüksiyon Motor (IM) ve Anahtar Relüktans Motor (SRM) türlerinin avantajları araştırılmıştır. Mıknatıs içeren motorların yüksek verimli olduğu ve performanslarının EA'lar için daha uygun olduğu bildirilmektedir (Chau ve diğ. 2014; Zhu ve Howe 2007; Kim ve diğ. 2002).

Öte yandan, iletim topolojisine bağlı olarak iç veya dış rotor tipi motorlar kullanılmıştır. Fosil yakıtlı araç tasarımı gibi topolojilerde iç rotorlu elektrik motorları kullanılırken, tekerlek içi tasarımlarda dış rotorlu elektrik motorları tercih edilmektedir. EA'lar için dış rotorlu sabit mıknatıslı bir motorun tasarlandığı ve test edildiği bir çalışmada, bu motorun yüksek verimli olduğu ve EA'lar için daha uygun olduğu vurgulanmıştır (Chung ve diğ. 2016).

EA'lar üzerinde çalışılan bir diğer önemli bileşen de hareket için gerekli enerji kaynağı olan bataryadır. EA'lar, fosil yakıtlı araçların aksine, mekanik enerjiyi elektrik enerjisine dönüştürebilmekte ve tekrar kullanılmak üzere bataryada depolayabilmektedir. Enerji geri kazanımının gerçekleştiği mekanizma rejeneratif frenleme ve rejeneratif sıkıştırma olarak adlandırılır. Sıkıştırma veya frenleme modu çalışması sırasında elektrik motorunun jeneratör bölgesinde kontrol edilmesiyle gerçekleştirilir. Elektrik enerjisinin çift yönlü akışı, EA'larda enerji yönetimi açısından büyük önem taşımaktadır. Son zamanlarda yapılan çalışmalarda özellikle rejeneratif frenleme kullanan yüksek verimli enerji yönetim sistemleri gerçekleştirilmektedir (Tie ve Tan 2013; Khajepour ve Song 2019). Bu çalışmalarda şarj durumunun (SoC) maksimizasyonu araştırılmaktadır (Demirçalı ve Köroğlu 2020). SoC doğrudan ölçülmez, bu nedenle bazı ölçülebilir veya hissedilebilir değişkenler dikkate alınarak farklı birçok matematiksel yöntemle tahmin edilir. Bu yöntemler dört grupta sınıflandırılmaktadır. Bu yöntemlerden biri batarya voltajının ve empedansının doğrudan ölçümünü kullanır. Bir diğeri defter tutma tahmin yöntemidir ve deşarj akımını entegre ederek SoC'ı hesaplar. Diğeri ise sinir ağına dayalı uyarlanabilir bir sistemdir. Yaygın olarak kullanılan bu yöntemlerin hibrit halidir ve diğerlerine kıyasla (Chang. 2013)'da sunulduğu gibi daha doğru sonuçlar verir.

Aracın parametrik özellikleri göz önünde bulundurularak, araç dinamiğinin ve bileşenlerin etkilerinin daha iyi anlaşılması için bazı araştırmalarda tüm bu parametreler dikkate alınarak benzetim modelleri tasarlanmıştır (Gao 2007; Husain ve Islam 1999). Ayrıca, farklı modeller, kombinasyonlar, topolojiler ve bileşenler, makul doğruluk ve yüksek hesaplama hızı ile birleştirilerek benzetim çalışmaları yapılmıştır.

Benzetim çalışmaları ile elde edilen sonuçların doğrulanması için araç bileşenlerini test eden birçok yöntem bulunmaktadır. Bir otomotiv endüstrisinde araçların geliştirilmesi ve test edilmesi için kullanılan V modeli, test doğrulukları

düşükten yükseğe doğru; Model-in-the-Loop (MIL), Software-in-the-Loop (SIL), Hardware-in-the-Loop (HIL), Vehicle-in-the-Loop (VIL) olarak sıralanabilir. Genel olarak araçların geliştirilmesinde MIL-SIL-HIL test süreçlerinin tamamlanması kabul edilebilir bir durumdur (Nibert 2012). Literatürde, bu yöntemleri fosil yakıtlı araçlar üzerinde kullanan, araç sürücüsünün davranışını, yol eğimini ve yük faktörünü ve yol tipini dikkate alan bazı çalışmalar bulunmaktadır (Rosero ve diğ. 2021; Carrese ve diğ. 2013). Ayrıca, EA'ların geniş hız aralıklarında, değişken sıcaklıklarda, farklı yol koşullarında ve farklı sürüş özelliklerinde kullanılması nedeniyle EA'ların tüm bileşenleri ayrıntılı olarak analiz edilmiştir (Chul 2005; Zhu ve diğ. 2009; Ciceo ve diğ. 2016; Oh 2005; Sharma ve diğ. 2021; Song ve diğ. 2016; Mohammed ve Abed 2008). Gerçek bileşenler için araç dinamikleri hakkında yüksek doğrulukta daha fazla bilgi elde etmek için HIL yöntemi ile motor, batarya ve enerji yönetim sistemleri incelenmiştir(He ve diğ. 2013).

Rejeneratif frenleme özellikleri olan ve olmayan bir elektrikli aracın toplam enerji tüketimini karşılaştırmışlardır. 1994 model Toyota Kijang Süper modeli benzinli binek aracı elektrikli bir araca dönüştürülmüş ve karşılaştırma için testleri kentsel yollarda gerçek dünya ortamında gerçekleştirmişlerdir. (Araç test rotası olarak, Endonezya'nın Bandung kentindeki 12,4 km'lik yol belirlenmiştir.) Rejeneratif frenli ve frensiz araçlarda enerji tüketiminin ortalama değeri sırasıyla 145.26 Wh / km ve 154.79 Wh / km'dir. Ortalama enerji tüketimi arasındaki fark, 9,53 Wh / km olduğu görülmüş ve elektrik enerjisi tüketiminde yaklaşık %6,16 azalma olduğu test edilmiş; bu da kilometre veya araç verimliliğinde bir artış olduğunu göstermiştir (Huda ve diğ. 2020).

Qi ve ark. (2020), EA'larda helezon yaylara dayalı elektro-mekanik fren enerjisi geri kazanım sistemi tasarlayarak enerji tasarrufu sağlamışlardır. Helezon yaylar ile frenleme esnasında kazanılan kinetik enerjiyi kalkışlarda başlangıç torku olarak kullanılmış.. Bu sayede frenleme esnasında elektro-mekanik fren enerjisi geri kazanım sistemi oluşturulmuş ve enerji verimliliği sağlanmıştır (Qi ve diğ. 2020).

He ve ark. (2020), tarafından uyarlanabilir tek pedallı rejeneratif frenleme kontrol stratejisi (RBCS) ve çok amaçlı bir optimizasyon sinir ağı (YSA) kontrol modeli içeren akıllı bir fren sistemi önerilmiştir. Uyarlanabilir tek pedallı RBCS'nin benzetim analizi US06, UDDS, LA92 ve ECE sürüş döngüleri ile test edilerek veriler

alınmıştır. Benzetim sonuçları, rejeneratif frenleme enerjisinin uyarlanabilir tek pedallı RBCS'nin kontrolü ile etkili bir şekilde geri kazanılabileceğini göstermektedir. Benzetim sonuçları, yapay sinir ağları ile oluşturulmuş Simulink modelinin daha iyi frenleme yaptığını ve geleneksel paralel kontrol stratejisinden %3,4 daha fazla enerji geri kazandığını göstermektedir (He ve diğ. 2020).

Liu ve ark. (2020), tarafından günlük sürüş koşulları göz önünde bulundurularak tek pedallı bir benzetim modeli oluşturulmuştur. Tek pedallı kontrol stratejisinin etkinliğini doğrulamak için tipik sürüş profilleri ile sürülmüş ve benzetim modelinin geçerliliğini doğrulamak için bir dinamometre testi yapılmıştır. NEDC (Yeni Avrupa Sürüş Döngüsü) ve WLTP (Dünya Çapında Uyumlu Hafif Araçlar Test Döngüsü) kapsamındaki benzetim sonuçları, enerji geri kazanım oranlarının %26.12 ve %20.77 kadar yüksek olduğunu ve sürüş menzillerinin sırasıyla 63.29 ve 51.72 km uzadığını göstermektedir. Tek pedallı kontrol stratejisinin kullanılarak yapılan çalışmanın, enerji geri kazanım oranını etkili bir şekilde artırabildiğini ve fren yaparken güvenliği sağlama öncülünde sürüş mesafesini genişletebileceğini göstermiştir (Liu ve diğ. 2020).

Yang ve ark. (2020), tarafından bağımsız ön ve arka aks motor tahrik sistemi kullanılarak rejeneratif frenlemenin enerji geri kazanım sorunu üzerine bir çalışma yapılmıştır. NYCC (New York Şehir Döngüsü) koşulları altında önerilen stratejinin enerji geri kazanım oranı tipik frenleme stratejisine göre %1,18'lik bir artış göstermiştir (Yang ve diğ. 2020).

Li ve diğ. (2022), EA'lar için yokuş iniş sürecinde sabit ve değişken oranlı frenleme kuvvetleri kullanılarak, rejeneratif frenleme kontrol stratejileri üzerine çalışma yapmışlardır. Yol eğim açısı tahmini dikkate alınarak, araç kararlılık talebine dayalı olarak sabit oranlı ve değişken oranlı fren kuvvetleri optimizasyon dağıtım yöntemleri tasarlanmış ve tasarlanan fren kuvvetleri dağıtım yöntemleri ile daha fazla enerji geri kazanımı için rejeneratif frenleme kontrol stratejileri önerilmiştir. Frenleme dengesi ve enerji geri kazanımı arasındaki çelişki problemini minimize etme üzerine çalışılmıştır. Önerilen optimizasyon dağıtım yöntemleri, optimize edilmemiş yöntemlere göre daha iyi bir enerji geri kazanım etkisine sahiptir, optimal değişken oranlı yöntem geri kazanılan enerjiyi %3,67'ye kadar, optimal sabit oranlı yöntem ise geri kazanılan enerjiyi %3,38'e kadar artırdığı gözlemlenmiştir.

Shang ve diğ. (2022), konum ve araç çalışma parametreleri gibi çok kaynaklı bilgilere dayalı olarak EA'ların rejeneratif fren kontrolü incelenmiştir. İlk olarak, hız sınırı trafik işaretlerini belirlemek için hızlı normalleştirilmiş çapraz korelasyon algoritması uygulanır. Ardından araç hızı, algılanan trafik işaretleri ve yol eğimi tahmin bilgilerinin birleşimi altında akıllı bir şekilde kontrol edilir. Geleneksel seri kontrol stratejisi ve bulanık kontrol stratejisi ile karşılaştırıldığında, uyarlamalı kontrol stratejisi enerji geri kazanım oranını sırasıyla %11,9 ve %5,3 oranında artırdığı gözlemlenmiştir.

Subramaniyam ve diğ. (2021), rejeneratif frenlemenin tepkisini kullanan EA'larda teker kayma kontrolü üzerine çalışmışlardır. Entegre Kayma Modu Kontrolü stratejisini önermişler ve sürtünmeli frenlemeye kıyasla durma mesafesini %12,13 oranında azalttığını gözlemlemişlerdir.

Mediuni ve diğ. (2022), EA için enerji tüketimi tahmini ve analizi: hibrit bir yaklaşım yapmışlardır. Yapay veri seti oluşturularak, EA'lar için yakıt tahmin modeli oluşturmuşlardır. Model performans testinde 0,98 R² skoru ile yüksek başarımlı elde etmişlerdir.

EA'ların bileşenlerinin ayrı ayrı testlerini yaparak araç dinamiklerini anlamak zordur. Ne yazık ki tüm bileşenlerin gerçek ortamda test edilmesi güvensiz ve yüksek maliyetlidir. Bu nedenle, gerçek dünya sürüş koşullarında tüm parametrelerin etkilerini gözlemlemek için bir test düzeneği tasarlanmalıdır. Bu çalışma kapsamında maliyet, güvenlik, taşınabilirlik ve esneklik gibi ölçütler göz önünde bulundurularak hem akademik çalışmalarda kullanılması hem de mühendislik öğrencilerinin araç dinamiği konusunda öğrenme deneyimi elde etmesi için laboratuvarında kullanılmak üzere bir test düzeneği hazırlanmıştır. Test düzeneği akü, çekiş motoru, servo motor ve sürücüleri, kullanıcı ara yüzü, PLC(Programlanabilir Mantık Denetleyici), bilgisayar ve sensörlerden oluşmaktadır. Öncelikle enerji depolama ve kaynağı olarak hafif EA'larda sıklıkla kullanılan bakım gerektirmeyen, ucuz, güvenilir ve yüksek performanslı jel aküler seçilmiştir. Benzer şekilde, birçok EA'da kullanılan ve yüksek tork sağlayan dış rotor yapısına sahip BLDC motor tasarıma dahil edilmiştir. Hız ve tork kontrolünü PLC üzerinden yapabilen BLDC motor sürücüsü kullanılmıştır. Aynı mitle bağlı servo motor, elektrikli araca etki eden kuvvetleri temsil etmek için kullanılmıştır. Ayrıca, çekiş motorunda gelişen torku gözlemlemek için şaft üzerine

tork sensörü yerleştirilmiştir. PLC'ye bağlı İnsan-Makine Arayüzü (HMI) sayesinde kullanıcı araç parametrelerini, yol eğimini ve sürüş profillerini istediği gibi değiştirebilmektedir. Ayrıca test sırasında HMI ekranından durum değişkenlerini izlemek mümkündür. Bundan sonra, test tamamlandığında, test verileri harici bir diske veya bilgisayar sabit sürücüsüne kaydedilebilir. Ayrıca bu cihaz esnek bir yapıya sahip olup PLC ile bilgisayar bağlantısı yapılarak Phyton gibi mevcut yazılımlar kullanılarak programlanabilmektedir. Bu sayede kullanıcıların bilgi düzeyine bağlı olarak karmaşık algoritmaları sistem üzerinde test etmek mümkündür. Ayrıca test düzeneği, istenirse farklı motorların ve sürücülerinin test edilebilmesi için modüler olarak tasarlanmıştır.

1.3 Tezin Amacı


Bu tez çalışmasının temel amacı, dıştan rotorlu EA motorunun geri güç kazanımı sağlayacak akıllı rejeneratif enerji denetimi, düşük güçlü bir şehir içi EA için gerçekleştirmektir. Böylece enerji verimliliği artarak araç menzili daha da uzayacak veya daha küçük batarya kullanılarak aynı mesafe kat edilebilecektir. Bu sayede aynı batarya gücü ile daha uzun mesafe yol alabilecektir. Diğer taraftan; öğrenen rejeneratif modlu fren kontrol sayesinde fren sistemine destek sağlanacaktır. Böylece daha kısa mesafede, daha güvenli, kaydırma yapmayan bir frenleme elde edilecektir. Ayrıca, mekanik fren sisteminin ömrü de uzatılmış olacaktır.

Bu amaçla, EA'larda sürücü, araç, sürüş profili, eğim vb. parametrelerden etkilenmeyen tüm EA'lara adapte olabilecek bir Yapay Zeka tabanlı rejeneratif enerji denetim modeli oluşturulması hedeflenmiş olup tasarımı ve uygulaması gerçekleştirilen test platformu ile enerji denetim sistemi için yapay zeka algoritmalarının kestirim ve performansları, verimlilik esasına bağlı test edilerek zaman ve maliyet tasarrufu sağlanması da önemli bir katkı olarak değerlendirilmektedir.

1.4 Materyal ve Yöntem

EA sisteminin benzetiminin yapılabilmesi için öncelikle tüm araç bileşenlerinin modelleri Matlab/Simulink'de oluşturulmuştur. Bileşenlerin modelleri

örnek bir hafif elektrikli araca göre gerçeğe yakın ve test sisteminin sınırlarını aşmayacak şekilde oluşturulmuştur. Sonrasında Yapay Zeka tabanlı rejeneratif enerji için veri havuzu oluşturularak algoritmaların tahmin verimliliği üzerine detaylı çalışmalar yapılmıştır. Öğrenme tabanlı algoritmaların daha hızlı sonuçlar verebilmesi için hesap yükü düşük modeller seçilmiştir. Şekil 1.1’de gösterilen genel modele göre araç bileşenlerinden oluşan bir test sistemi imal edilmiştir.



Şekil 1.1: Tasarlanan EA test sisteminin modeli.

Bu test sistemi ile gerçek zamanlı olarak benzetim sonuçlarının doğruluğu karşılaştırmak için farklı sürüş profillerinde ve farklı parametrelerde de deneysel çalışmalar yapılmış ve sonuçları değerlendirilmiştir.

1.5 Tezin Katkısı

Tez çalışmasında Yapay Zeka tabanlı Rejeneratif enerji denetim stratejisi üzerinde durulmuştur. EA’lar için benzetim modeli ve gerçek araç bileşenlerinden oluşan bir test platformu oluşturulmuştur. Bu platform hem EA benzetimleri yapabilmekte ayrıca her türdeki elektrik motorunun yükleme testlerini gerçekleştirebilmektedir. Üretimi gerçekleştiren test platformuna araç parametreleri,


yol parametreleri, batarya parametreleri girildiği için ve platformda araçta kullanılan ekipmanlar birebir kullanıldığından bir aracın farklı koşullar altındaki çalışmasına ait veriler elde edilebilmektedir. Test sırasında anlık olarak gerilim, akım, tork, güç ve SoC değişimleri hassas şekilde ölçülebilmektedir ve test bitiminde veriler hem USB belleğe hem de bilgisayar belleğine otomatik olarak kayıt edilmektedir. Test sistemine ait tüm tasarım, deney ve çalışma akış diyagramı ayrıntıları ile gösterilmiştir.

Ayrıca Test sistemi TCP/IP protokolü kullanılarak bilgisayara uzaktan ve kablolu olarak bağlanabilmekte ve farklı programlama dillerinde kontrol algoritmalarını test edebilme imkânı tanımaktadır. Çalışmada Python programlama dile kullanılarak Makine Öğrenmesi algoritmaları test sistemi üzerinde çalıştırılmıştır.

Önerilen Makine Öğrenmesi algoritmalarından Rastgele Orman algoritması kullanılarak yapılan öğrenen fren dağılım sisteminin öğrenme performansını gösterebilmek için araçta diğer Makine Öğrenmesi algoritmaları ile karşılaştırma yapılmıştır. Oluşturulan model otonom araçlarda hızlanma ve yavaşlama kontrolü için rejeneratif enerji denetimi yapabilecek aracın sürtünmeli frenini azaltıp rejeneratif fren enerjisini bataryaya aktarabilecektir. Ayrıca sürücü bulunan araçlarda sürücünün fren kararına destek sağlayacak ve aracın faydalı fren kullanımına olacak sağlayacaktır.


2. ELEKTRİKLİ ARAÇLAR

Küresel ısınma ile atmosferimizdeki karbon miktarı arasındaki bağlantı göz önüne alındığında, atmosferimizi karbondan arındırma, giderek daha önemli bir hedef haline gelmektedir. Birçok ülke, ilerleyen zaman dilimi içinde karbon salınımını azaltmaya yönelik resmi taahhütlerde bulunmuştur; örneğin, Birleşmiş Milletler tarafından iklim değişikliğine ilişkin uluslararası bir anlaşma olan Paris Anlaşması bunlardan bir tanesidir. İngiltere’de endüstride karbon salınımı azaltmaya yönelik stratejiler hükümet planında yer almıştır. Uruguay 2030 gibi erken bir tarihte karbon nötrlüğü taahhüt ederken 2035’te Finlandiya tarihte karbon nötrlüğü taahhüt etmektedir (Maybury ve diğ. 2022). Bu nedenle, EA’ların benimsenmesine ilişkin araştırmalar son yıllarda büyük ölçüde artmıştır. Bu araştırmalarda matematiksel modelleme, EA’lara geçişi optimize etmede önemli bir rol oynamaktadır. Elektrikli aracın farklı durumlarda yaptığı davranışları gözlemleyebilmek için dinamik denklemler baz alınarak tüm araç bileşenlerinin modellenmesi gerekmektedir. EA bileşenleri ve bunların alt bileşenleri Şekil 2.1’de gösterilmiştir. Bu alt bileşen çeşitlemeleri kullanılarak literatürde farklı çalışmalar yapılmıştır.




Şekil 2.1: EA’larda kullanılan bileşenler ve alt bileşenleri (Tümbek, 2019).

EA'larda literatürde çeşitli motor tipleri kullanılmaktadır. Bu motor türleri Şekil 2.2'de gösterilmiştir. Bu tez çalışmasında dıştan rotorlu BLDC motor kullanılmıştır.



Şekil 2.2: EA'larda kullanılan motor türleri.

EA'lar için literatürde kullanılan farklı tahrik yapıları Şekil 2.3'de gösterilmiştir. Tahrik yapılarında dişli kutusu, diferansiyel, sabit dişli ve kavrama bulunmaktadır. Bu tez çalışmasında elektrik motoru olarak dıştan rotorlu BLDC motor tercih edildiğinden Şekil 2.3(f)'te gösterilen yapı kullanılmıştır. Bu yapı sayesinde motordan tekere arada aktarma organı olmadan güç verildiği için düşük güçlü EA'lar için en uygun ve verimli yapı olarak görülmektedir.




Şekil 2.3: EA'larda kullanılan tahrik yapıları.

2.1 Elektrikli Araç Dinamik Denklemleri

EA'larda, ön yüzey alanı, şekil, tekerlek yarıçapı, kütle, vb. parametreleri kullanılarak dinamik olarak modellenmektedir. Ayrıca elektriksel modeli oluşturulurken batarya, motor ve motor sürücüsü gibi bileşenler kullanılmaktadır.

Hareket halindeki bir araca bulunduğu konum ve yol koşullarına göre çeşitli kuvvetler etki etmektedir ve bu kuvvetler araç yapısına göre de farklılık göstermektedir. Bu kuvvetler Şekil 2.4'de gösterilmiştir.



Şekil 2.4: Elektrikli aracın maruz kaldığı kuvvetler.

Aracın tekerlekler ile yola aktardığı hareket kuvvetini ifade eden F_{te} Şekil 2.4'te gösterilmiştir ve Denklem (2.1)'de tanımlanmıştır. Araç motorundan tekerlere bu kuvvetin üzerinde bir değerde tork uygulanabilir ise araç hareket edebilmektedir. Araç ancak bu kuvveti yenebilirse hareketini sağlayabilmektedir.

$$F_{te} = F_{ad} + F_{la} + F_{rr} + F_{Gx} \quad (2.1)$$

Burada; F_{ad} aerodinamik kuvveti, F_{la} ivmelenme kuvvetini, F_{rr} yuvarlanma sürtünme kuvvetini ve F_{Gx} ise eğim direnci kuvvetini temsil etmektedir.

Aracın yüzeyini saran viskoz sürtünme kuvveti ile oluşan aerodinamik kuvveti (F_{ad}) ise Denklem (2.2) ile hesaplanabilmektedir. Bu sürtünme kuvveti, araç hızının karesine, ön yüzey alanı kabuk şekline ve havanın yoğunluğu ve bağlıdır.

$$F_{ad} = \frac{1}{2} \cdot A \cdot C_d \cdot \rho \cdot V^2 \quad (2.2)$$

Denklemde (2.2)'de yer alan C_d havanın sürtünme katsayısını, A (m^2) aracın ön yüzey alanını, ρ (kg/m^3) havanın yoğunluğunu ifade etmektedir.

İvmelenme kuvveti olan F_{la} (N), Newton'un ikinci hareket kanununa bağlı olarak Denklem (2.3)'te gösterildiği gibi tanımlanır.

$$F_{la} = m \cdot \frac{d}{dt} V = m \cdot a \quad (2.3)$$

Denklemde; V (m/s) aracın hızını, m (kg) ise kütesini göstermektedir. Aracın doğrusal ivmesi a (m/s^2) hızın zamana göre türevinden de bulunmaktadır.

Denklem (2.4)'te ifade edilen eğim direnci kuvveti (F_{Gx}) (N), yer çekimi ivmesi, aracın kütlesi ve pozitif ve negatif yol eğimine göre değeri değişmektedir.

$$F_{Gx} = m \cdot g \cdot \sin(\alpha) \quad (2.4)$$

Denklemde yolun eğim açısı α , yer çekimi kuvveti g ile ifade edilmektedir. Yer çekiminden kaynaklı araca etkileyen kuvvetin bir bileşeni ve aracın hareket yönünde olan eğim direnci kuvveti (F_G)'nin aracın bulunduğu yoldaki eğim açısına göre değeri değişmektedir. Eğim olmayan bir yolda ilerleyen bir araç için eğim direnci kuvvetinin değeri sıfır, negatif eğime sahip bir yolda ilerleyen araç için bu kuvvet değeri negatif, pozitif eğime sahip bir yolda ilerleyen araç için ise pozitif olmaktadır.

Denklem (2.4)'te ifade edilen yuvarlanma sürtünmesi kuvvetine (F_{rr}) aracın ağırlığı, yer çekimi ivmesi ve yuvarlanma katsayısı etki etmektedir.

$$F_{rr} = K_r \cdot m \cdot g \quad (2.5)$$

Denklem (2.4)'te yolun yapısına ve hava sıcaklığına göre değişim gösteren K_r yuvarlanma sürtünme katsayısını, g yerçekimi ivmesini, m aracın ağırlığını ifade etmektedir.

Araca etki eden tüm bu kuvvetlerin denklemleri açılarak ana denklem olan Denklem (2.6)'de yerine yazılırsa aşağıdaki denklem elde edilir.

$$F_{te} = m \cdot a + \frac{1}{2} \cdot C_d \cdot A \cdot \rho \cdot V^2 + K_r \cdot m \cdot g + m \cdot g \cdot \sin(\alpha) \quad (2.6)$$

Araca etki eden toplam net kuvvet denklem (2.6) gösterilen F_{te} kuvveti ile hesaplanmaktadır. Böylelikle, araca etki eden tüm kuvvetlerin toplamı olan F_{te} tüm parametrelere değerlerine bağlı aracın dinamik modelidir.

Bilindiği üzere kuvvet kolunun uzunluğunun kuvvet ile çarpımı neticesinde tork elde edilmektedir. Bu ifadeden yola çıkarak, elektrikli aracın hesaplanan kuvveti karşılayabilmesi için motorun üretmesi gereken tork değeri Denklem (2.7)'den hesaplanabilmektedir. Denklemde belirtilen r araç tekerleğinin yarıçapıdır.

$$T = F_{te} \cdot r \quad (2.7)$$

Araç için gerekli olan güç ise aracın hızı ile ilişkilidir. Denklem (2.8)'deki gibi hız ile aracın hareketini sağlayan kuvvetin çarpımından elde edilir.

$$P = F_{te} \cdot V \quad (2.8)$$

Araç yavaşlatılırken motor hızı aynı yönde pozitif kalırken aracı yavaşlatan tork ihtiyacı negatif olmaktadır. Bu nedenle Denklem (2.9) göz önüne alındığında enerjinin milden girip elektrik kapısından çıktığı yani negatif olduğu hesaplanır ki bu enerji bataryaya geri depo edilecek Rejeneratif enerji olarak tanımlanır. Burada W enerji, T araç tekerleğinden motor miline uygulanan tork, ω açısal hız olup birim zamandaki Rejeneratif gücün oluştuğu süre $[t_1 - t_2]$ zaman aralığında aktarılan Rejeneratif enerjinin miktarı W 'dır.

$$W = \int_{t_1}^{t_2} T \cdot \omega \cdot dt \quad (2.9)$$

2.2 Rejeneratif Frenleme

Elektrik enerjisi doğrudan şebeke kaynağından alınabilir veya kimyasal enerjiye dönüştürülerek bataryada saklanabilmektedir. EA'lar, sistemlerinde ihtiyaç duyulan enerjiyi sağlamak için elektrik enerjisi kullanan araçlardır. Bir elektrikli aracın çekiş gücü bir veya birkaç elektrik motorundan sağlanır. EA'larda, her tam dolum şarjdaki alınabilecek toplam yol mesafesi, batarya kapasitesine, sürücünün sürüş stiline ve araç bileşenlerinin verimliliğine bağlı olarak değişmektedir. Batarya kapasitesini arttırmak alınacak yol mesafesini artırır, fakat daha yüksek maliyet ve daha uzun şarj süresi gibi sorunları beraberinde getirir. Bu arada, sürücünün sürüş tarzını sınırlandırmak, aküden deşarj miktarını da etkileyebilir, ancak bu yöntemin sürücü özneliği faktörü nedeniyle uygulanması teknik olarak zordur. Özetlemek gerekirse, EA'larda alınacak yol mesafesini artırmanın en gerçekçi yolu, sürüş bileşenlerinin verimliliğini arttırmaktır.

Yapılan çalışmalara bakıldığında, sürüş bileşenlerinin enerji verimliliğini artırmanın çeşitli yollarını vardır. İki motor kullanılarak ve bunları planet dişli ve paralel şanzımanlarla birleştirilerek yapılan bir benzetim çalışmasında, tek bir motorla çalışan EA'a göre daha yüksek bir verimlilik göstermektedir (Wu ve diğ. 2018). Çevre koşulları veya akülerin şarj durumları (SoC) hakkında uygun bilgiler, sürücülerin sürüş stillerini daha fazla mil kat edecek şekilde en iyi şekilde ayarlamalarına yardımcı olabilir (Mruzek ve diğ. 2017). EA'larda bataryanın çalışma sıcaklığı bataryanın kapasitesi etkilemekte ve dolayısıyla alınacak olan toplam yol mesafesini etkilemektedir. Bu problemin çözümü için soğutucu kullanılarak, kabul edilebilir bir sıcaklık aralığının korunmasının verimliliği artırdığı gözlemlenmiştir. (Smith ve diğ. 2016). Sıcak ve soğuk hava koşulları klima sisteminin elektrik yükünü etkileyeceğinden, EA'nın klima sistemini düzenleme stratejisi de kilometreyi etkileyebilir (Zhang ve diğ. 2018).


EA'ların en önemli ve faydalı özelliklerinden bir tanesi fren enerjisini geri kazanma yeteneklerinin olmasıdır. EA sürüş bileşenlerinin verimliliğini artırmanın bir alternatifi, rejeneratif frenleme yöntemidir. Bu yöntemin temel prensibi, yavaşlama / frenleme esnasında mekanik ataletten kaynaklanan kinetik enerjiyi tahrik bileşenleri

tarafından tekrar kullanılabilen elektrik enerjisine dönüştürmektir (Zhang ve diğ. 2018).

Araç güvenliğini etkileyen en önemli faktörlerden birisi kuşkusuz araç frenleme performansı olduğu bilinmektedir. Fren sistemleri tasarlanırken iki önemli talebin karşılanması gözetilmektedir. Bunlardan birincisi öncelikle acil frenlemede aracı en kısa mesafede durdurmak ve ikincisi sürücünün aracın yönü üzerindeki kontrolü sağlamaktır. Birinci talebi gerçekleştirmek için fren sisteminin tüm tekerlere yeteri miktarda frenleme torku sağlaması gerekmektedir. İkinci talebi gerçekleştirmek için ise frenleme kuvvetinin tüm tekerlere eşit miktarda dağıtılması gerekmektedir. Bu frenleme torkunun karşılanması için gereken toplam tork değeri, elektrik motorunun üreteceği torktan büyüktür. EA ve Hibrit EA'larda, mekanik sürtünmeli fren sistemleri elektrik rejeneratif frenleme ile bir arada bulunmalıdır (Ehsani ve diğ. 2018). Fakat bu durumda hem mekanik hem de elektrikli fren sistemlerinin uygun tasarımı ve kontrolü kolay olmamaktadır. Günümüzde bu alanda çalışmalar halen devam etmektedir.

2.3 Rejeneratif Frenlemede Sürücü Davranışı

Modern EA'larda enerji verimliliği açısından motorda yapılan iyileştirmeler yeterli değildir. Frenleme esnasında oluşan kinetik enerji ısı enerjisine dönüşerek kaybolmaktadır. Rejeneratif modlu kontrol ile kinetik enerji elektrik enerjisine dönüştürülmesi enerji verimliliği açısından gereklidir. Frenleme gibi güç tüketen araç sistemlerinin de optimize edilmesi gerekmektedir. Ayrıca geri güç kazanımı yapılarak daha uzun sürüş ve güvenli frenleme sağlanabilmelidir (Crolla ve Cao 2012). Şekil 2.5'te bir çift yönlü BLDC motorun sürücü ve motor modelinin birleştirilmiş hali gösterilmiştir.




Şekil 2.5: BLDC motorunun sürücü modeli.

Rotor pozisyonuna bağlı hall sensörlerinden alınan pozisyon bilgisine göre çift yönlü sürücü kontrol edilmektedir. Burada L faz endüktansı, R faz direnci, I_a , I_b ve I_c endüvi akımları, E_a , E_b ve E_c Elektro Motor Kuvveti (EMK), C, kondansatör, S1, S2, S3, S4, S5, S6 ise anahtarlama elamanlarıdır. Şekil 2.6'de doğrudan bağlantı, üç anahtar, iki anahtar ve tek anahtarlı frenleme yöntemlerinin anahtarlama şekilleri gösterilmiştir. Burada H_a , H_b ve H_c ilgili hall etkili sensörlerin durum bilgilerini vermektedir.

Tek anahtar ile yapılan yöntemde S2, S4, S6 anahtarlarından sadece bir tanesi aktif olmaktadır. İki anahtar yönteminde, aynı anda 1 adet üst kolda (S1, S3, S5) 1 adet alt kolda (S2, S4, S6) yer alan anahtar aynı anda PWM(Darbe genişlik modülasyonu) ile anahtarlansaktadır. Üç anahtar yönteminde, alt kolda bulunan üç anahtar (S2, S4, S6) da aynı anda PWM modunda anahtarlansaktadır. Doğrudan bağlantı yönteminde ise iki anahtarlama yöntemine benzer şekilde PWM darbeleri yerine tüm anahtarlara sürekli sinyal uygulanır (Godfrey ve Sankaranarayanan 2018).

Sabit hızda ve değişken hızda rejeneratif frenleme yapılırken frenleme hızı yüksek ve sabit olduğunda maksimum enerji kazanımı elde edilmesi için tek ve 3 anahtarlı anahtarlama yöntemleri tercih edilmektedir. Fakat değişken hızda frenlemede hız düşük ve acil durma gerekiyorsa iki anahtarlı frenleme yöntemi en yüksek torku sağlamaktadır (Chen ve diğ. 2011).



Şekil 2.6: BLDC motor sürücü rejeneratif çalışma anahtarlama modları.

EA'larda durma süresi aşağıdaki denklemler ile hesaplanmaktadır.

$$J \frac{d\omega}{dt} + B\omega + T_l = T_e \quad (2.10)$$

Denklem (2.10) motor dinamiğini ifade etmektedir. Burada J atalet momentini, B sürtünme katsayısını, ω açısal hızı, T_l yük torkunu ve T_e motor torkunu ifade etmektedir.

$$J \frac{d\omega}{dt} = T_e \quad (2.11)$$

Yük torku ve sürtünme katsayısı ihmal edilirse motor torku ile Denklem (2.11) elde edilir.

$$T_e = -K_t i_a \quad (2.12)$$

$$J \frac{d\omega}{dt} = -K_t i_a \quad (2.13)$$

Motor torku frenleme esnasında negatif olacağı için önce Denklem (2.12) elde edilir sonra da Denklem (2.11)'da yerine yazılırsa Denklem (2.13) elde edilmektedir. Burada K_t motor tork sabiti ve i_a endüvi akımıdır.

$$i_a = \frac{D(2V_{emk})}{R_b + 2R} \quad (2.14)$$

Tek anahtar yönteminde endüvi akımı i_a Denklem (2.14) ile ifade edilir. Burada, D görev döngüsü, $2V_{emk}$ zıt elektro motor kuvvet, R_b bataryanın eşdeğer iç direnci ve R faz başına düşen armatür direncini ifade etmektedir.

$$\frac{d\omega}{dt} = \frac{K_t D(2V_{emk})}{J(R_b + 2R)} \quad (2.15)$$

$$\frac{d\omega}{dt} = \frac{K_t(2V_{emk} + DV_{bat})}{J(R_b + 2R)} \quad (2.16)$$

$$\frac{d\omega}{dt} = \frac{K_t D(2V_{emk})}{J(R_b + \frac{7}{4}R)} \quad (2.17)$$

Denklem (2.13) ve (2.14) tek denklem haline getirilir ise Denklem (2.15) yani tek anahtarlamalı frenleme tekniğinde durma süresinin hesaplanması için gerekli

denklem elde edilmiş olur. Denklem (2.16)'de iki anahtarlamalı frenleme tekniği, (2.17)'de üç anahtarlamalı frenleme tekniğinde durma süresi hesabı gösterilmektedir.

2.3.1 Paralel Rejeneratif Frenleme


Rejeneratif frenleme sistemi genel olarak ikiye ayrılır ve bunlardan birisi paralel rejeneratif frenleme stratejisidir. Bu frenleme stratejisinde rejeneratif frenleme ve mekanik frenleme aynı anda belirli oranlarda devreye alınmaktadır. Fakat iki frenleme sisteminin aynı anda kontrolü zor olmaktadır ve mekanik frenlemenin performansı olumsuz bir şekilde etkilenmekte ve güvenilirlik performansını düşürmektedir (Zhang ve diğ. 2011).

2.3.2 Seri Rejeneratif Frenleme

Bir diğer rejeneratif fren yöntemi de seri rejeneratif fren stratejisidir. Bu stratejide öncelik olarak motor üzerinden rejeneratif frenleme kullanılmakta ve gerekli durumlarda kalan frenleme torku mekanik fren üzerinden sağlanmaktadır. Seri rejeneratif frenleme, fren torkunun ön-arka tekerlekler ile mekanik-rejeneratif fren sistemleri arasında nasıl dağıtılacağını denetleyen yöntemdir (Tanaka ve diğ. 2014). Xu ve diğ., hibrit rejeneratif frenleme sistemi ile donatılmış dört tekerlek motorlu EA'lar için yeni bir fren torku dağıtım stratejisi sunmaktadırlar. Önerilen kontrolde hidrolik fren torkunu ve motor fren torkunu belirleyerek rejenerasyon verimliliğini en üst düzeye çıkarmayı hedeflemişlerdir. Frenleme gereksinimi izlenip ön ve arka tekerlerin fren torkundan geri güç kazanımı ve güvenli frenleme sağlanmıştır (Xu ve diğ. 2019).


2.3.3 Rejeneratif Mod Çalışma Modeli

EA'larda fren anında meydana gelen ısı enerjisini elektrik enerjisine dönüştürme olayına rejeneratif frenleme denilmektedir. Elektrik motorları bilindiği üzere aynı zamanda jeneratör olarak çalışabilmektedir. Elektrik motorlarının bu özelliği kullanılarak elektrikli araca frenleme anında motor freni yaptırılarak ısıya dönüşecek olan enerji motor sürücü üzerinden bataryaya aktararak enerji kazanımı sağlanmaktadır. Bu olay sayesinde sürtünmeli fren azaltılmış olup mekanik parçaların daha uzun süre dayanmasını sağlamaktadır. Şekil 2.7'de gösterilen blok diyagramda öncelikle araç parametreleri ve yol verileri alınarak aracın talep ettiği tork miktarı araç kontrol sisteminde hesaplanmaktadır.



Şekil 2.7: Frenleme modelinin genel yapısı

Sonrasında bu bilgi fren kontrol bloğuna gelerek rejeneratif ve mekanik fren oranları belirlenerek aracın durdurulması sağlanmaktadır. Şekil 2.8'de gösterilen akış şeması takip edilerek rejeneratif frenleme operasyonu tamamlanmaktadır.




Şekil 2.8: Fren dağılım sistemi kontrolü akış diyagramı.

Akış diyagramında öncelikle araç parametreleri girilir sonrasında sürüş profili başlatılır. İlk etap da aracın ihtiyaç duyacağı motor torku hesaplanır ve sonrasında frenleme torkuna ihtiyaç olup olmadığı sorgulanır. Eğer bir frenleme talebi mevcut ise rejeneratif mod açık mı diye kontrol edilir. Rejeneratif modun aktif olması halinde ve SoC değerinin % 90'nın altında olması durumunda rejenerasyon katsayısı yani fren dağılım katsayısı hesaplanır ve bu katsayıya göre mekanik ve rejeneratif frenleme operasyonu tamamlanır.

2.4 Elektrikli Araç Benzetim Modelinin Oluşturulması

EA dinamik denklemlerinden yola çıkılarak Matlab/Simulink programında mekanik ve elektronik modellerin bir arada bulunduğu Şekil 2.9’da gösterilen benzetim modeli oluşturulmuştur. Benzetim modeli öğrenme tabanlı algoritmaları uygulayarak farklı araç parametreleri ve sürüş profilleri altında öğrenen rejeneratif mod çalışmalarını yapmaya elverişli hale getirilmiştir. Benzetim modeli test sistemi ile yapılan deneyler sonrası veriler kayıt altına alınarak karşılaştırmalar yapılmaktadır.




Şekil 2.9: Elektrikli aracın Matlab / Simulink’de oluşturulmuş benzetim modeli

Elektrik motoru, batarya, motor sürücüsü bir elektrikli aracın elektriksel bileşenlerini oluşturmaktadır. Benzetim sisteminde bu bileşenlerin modellerinin doğruluğu ve hassasiyeti önem arz etmektedir. Ayrıca araç gövdesi, tekerler, diferansiyel gibi aracın mekanik aksamaları da benzetim modelinde olması deneylerin daha doğru sonuçlar elde etmemizi sağlamaktadır.

2.4.1 Araç Mekanik Modeli

Araç mekanik modeli içerisinde rotor mil çıkışı, mekanik bölümünde ise 4 adet teker, araç gövdesi, dişli kutusu ve diferansiyel bulunmaktadır. Benzetim çalışması içinde araç mekanik modelini oluşturduğumuz için deneysel çalışmalar yapacağımız elektrikli aracın özelliklerini benzetim ortamına girebileceğimizden dolayı daha gerçekçi benzetim sonuçları alınabilecektir. Ayrıca EA’da güç harcayan tüm ekipmanları daha detaylı olarak irdeleme imkânımız olacaktır.


Şekil 2.10’da gösterilen mekanik benzetim modeline, hareketin sağlanması için “MTrq” ile motor rotorundan gelen tork verisi, “Brk” üzerinden frenleme bilgisi ve “Slp” ile de eğim verisi gelmektedir. Ayrıca modelden çıkan “VSpeed” ile aracın tekerlerinden alınan hız bilgisi kapalı döngü kontrol yapılabilmesi için hız kontrol modeline gitmektedir.



Şekil 2.10: Elektrikli aracın mekanik benzetim modeli

2.4.2 Fren Kontrol Modeli

Fren kontrol modeli EA sisteminde frenleme miktarını, frenlemenin mekanik veya rejeneratif olmasını ve frenleme dağılım oranının belirlendiği modeldir (Şekil 2.11). Fren kontrol modelinde araç motoru kontrol torku olan “CTrq” etiketli veriden negatif tork değerleri süzülerek frenleme için gerekli olan tork sinyali olan “BrkT” etiketli frenleme torku sinyali oluşturulmuştur.



Şekil 2.11: Elektrikli aracın fren kontrol modeli.


Sonrasında toplam frenleme torku mekanik ve rejeneratif olarak ayrıştırılarak mekanik fren (Brk) olarak araç mekanik modeline, motor sınırları çerçevesinde rejeneratif fren (RefMTrq) olarak motor modeline gönderilmektedir. Bu sayede hem rejeneratif hem de mekanik fren yaptırılmaktadır.

2.4.3 Motor Modeli

Elektrik motoru, elektrik ve mekanik enerjinin dönüşümünü sağlayan elektromekanik bir sistem olduğundan, elektrik ve mekanik sistemler arasındaki bir bağlantı aracılığıyla aracı hareket ettiren çekme kuvvetini sağlamaktan sorumludur. Elektrik motoru, elektrik enerjisini mekanik enerjiye çevirerek mekanik şanzıman parçaları vasıtasıyla tekerleklerin dönme hareketini oluşturmaktadır. Ayrıca, frenleme durumundayken, elektrik motoru, elektronik güç dönüştürücüler aracılığıyla tekerleklerden aküye enerji geri kazanımı sağlamak için bir jeneratör görevi görmektedir.

Literatürde EA’larda kullanılan birçok konvansiyonel DC ve AC elektrikli makine, tekerleklere gerekli gücü sağlamak için tasarlanmıştır. Fırçalı DC motorlar, IM(Induction Motor)’ler, PMSM’ler, BLDC motorlar ve SRM’ler, EA’larda yaygın olarak kullanılan geleneksel elektrikli makinelere örnektir. Bu elektrikli makinelerden biri olan BLDC motor, özellikle hafif EA’lar için kullanılan yüksek tork ve yüksek güç yoğunluğuna sahip bir motordur. Bu tez çalışmasında, EA’larda yaygın olarak kullanılan BLDC motor, EA’ların kurulumunda hareket torkunu sağlamak için kullanılmıştır.

BLDC motorun statoru, 120 derece aralıklı bobinlerden oluşur. Rotordaki kalıcı mıknatıslar, 180 derecelik manyetik aralıklarla birbiri ardına yerleştirilir. Böylece motor döndürüldüğünde, rotor sargılarında 120 derecelik bir faz farkıyla yamuk dalga formu şeklinde voltaj indüklenir. Motoru düzgün bir şekilde döndürmek için 120 derecelik iletim periyoduna sahip dengeli bir üç fazlı dikdörtgen akım gereklidir. BLDC motorunun elektriksel eşdeğer devresi Şekil 2.12’de gösterilmektedir. Bu modelde rotor ve stator sargısı sadece uzaysal sinüzoidal gerilimleri ve akımları uyarır. Ayrıca manyetik malzemeler izotropiktir ve doymunluk yoktur.



Şekil 2.12: BLDC motor eşdeğer devresi.

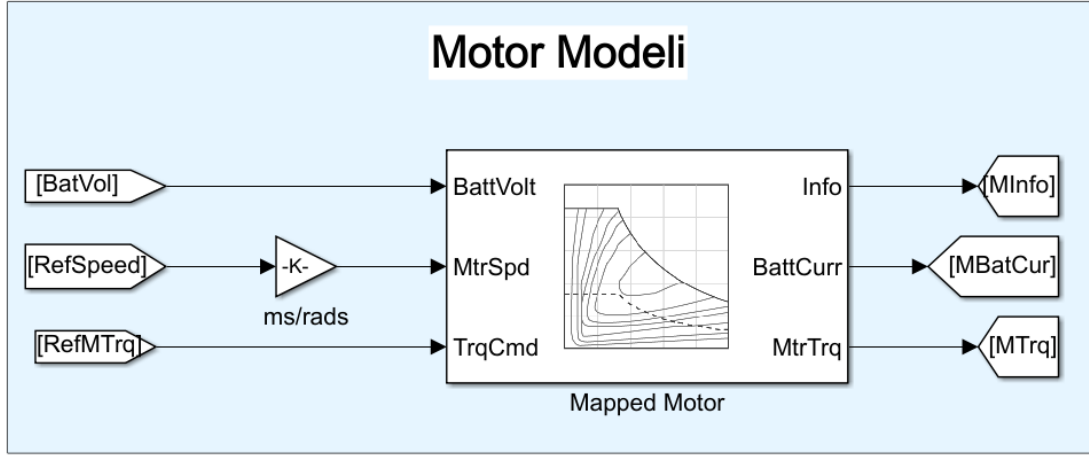
BLDC motor voltaj denklemleri aşağıdaki gibidir:

$$u_A = Ri_A + (L - M) \frac{d}{dt} i_A + e_A \quad (2.18)$$

$$u_B = Ri_B + (L - M) \frac{d}{dt} i_B + e_B \quad (2.19)$$


$$u_C = Ri_C + (L - M) \frac{d}{dt} i_C + e_C \quad (2.20)$$

Denklem (2.18), (2.19), (2.20), motor voltaj denklemleri verilmiştir. Burada R sargı direnci, L sargı endüktansı ve M karşılıklı endüktansıdır. Benzetim modelinde Şekil 2.13'te gösterilen motor modeli kullanılmıştır.



Şekil 2.13: BLDC motor benzetim modeli.

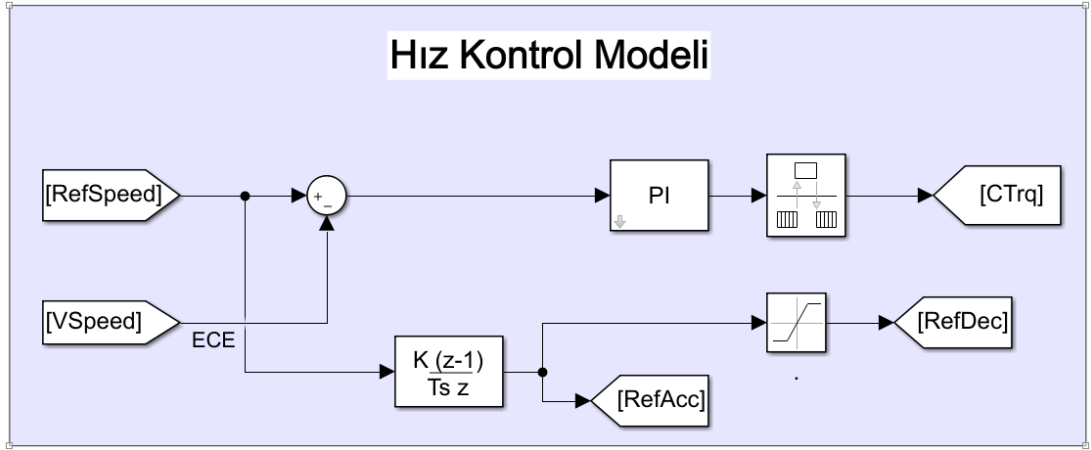
Motor modeline batarya modelinden batarya voltajı, referans hız modelinden, referans hız ve fren kontrol modelinden rejeneratif frenleme tork bilgileri gelmektedir. Motor modelinde hız ve frenleme tork verileri kullanılarak Şekil 2.14'te gösterilen motor verim haritası verilerine göre araç mekanik modeline gitmek üzere motor torku ve frenleme sırasında bataryaya gidecek olan akım üretilmektedir. Bu tork ile araç hareket etmekte veya durmaktadır.



Şekil 2.14: Benzetim çalışmasında kullanılan elektrik motorunun verim haritası.

2.4.4 Hız Kontrol Modeli


Aracın hızlanmasını ve yavaşlaması bilgi sinyallerini üreten araç hız kontrol modeli Şekil 2.15'te gösterilmiştir. Burada araç tekelerinden “VSpeed” etiketi ile gelen aracın mevcut hız bilgisi “Hız kontrol” bloğuna girilerek kapalı döngü PI kontrol ile aracın referans hıza ulaşması sağlanmıştır. İstenilen hız ulaşmak için aracın motorunun üretmesi gereken tork olan “CTorq” etiketli veri bu kapalı döngü kontrol tarafından belirlenmektedir.



Şekil 2.15: Elektrikli aracın hız kontrol modeli.

2.4.5 Batarya Modeli

Bataryalar, EA'ların ihtiyaç duyduğu elektrik enerjisinin kimyasal enerji olarak depolandığı elektrokimyasal cihazlardır. Günümüzde EA'larda farklı kimyasal özelliklere sahip birçok batarya türü kullanılmaktadır. En çok kullanılan bataryalar lityum, sulu kurşun-asit, nikel kadmiyum (Ni Cad), sızdırmaz jel kurşun-asit, veya nikel metal hidrat (NiMH) bazlıdır. Dolayısıyla literatürde bataryaların özelliklerine bağlı olarak birden fazla model bulunmaktadır. Benzetim ve deneylerde kullanılacak batarya modeli, çalışmaların doğruluğu açısından önemlidir. Bu nedenle bataryanın şarj ve sağlık durumunun tahmini için uygun modellerin kullanılması gerekmektedir. Ancak bataryaların doğrusal olmayan şarj ve deşarj davranışı, hesaplamaların karmaşıklığını artırmaktadır.



Şekil 2.16: Batarya hücre eşdeğer devresi.

Bu çalışmada, bataryanın elektrik eşdeğer devresi Şekil 2.16’da gösterildiği gibi kullanılmıştır. Bu devre modelinde paralel iç direnç ihmal edildiğinden bataryanın açık devre voltajı sabit kalır.

$$V_{bat} = V_{oc} - i_b * R_i \quad (2.21)$$

Denklem (2.21)’de, değerler V_{oc} , ve i_b , R_i sırasıyla batarya açık devre voltajı, batarya akımı ve batarya iç direncidir. Bu değerlere bağlı olarak batarya voltajı V_{bat} hesaplanır. Ayrıca akülerin kapasitesi, deşarj sırasında tam dolu durumda terminal voltajının kesme voltajı değerine düştüğünde tüketilen amper-saat (Ah) sayısı olarak tanımlanır ve etiketlerinde gösterilir. Değer farklı deşarj hızlarında değiştiğinden, akü üreticileri genellikle amper-saat değerlerini akım değerleriyle birlikte etiketlerinde belirtirler. Bataryanın bir diğer önemli parametresi olan SoC , kalan kapasitenin tam kapasiteye oranı olarak tanımlanır. Tam olarak şarj edilmiş bir bataryanın SoC 'u %100 olarak kabul edilir ve tamamen boşalmış bir bataryanın SoC %0’dır (Kesler ve diğ., 2022). SoC ’da ki değişiklik dt zaman aralığında deşarj veya şarj sırasında ve amper-saat kapasitesi (Q) aşağıdaki gibi ifade edilir (Denklem 2.22).


$$\Delta SoC = \frac{i dt}{Q(i)} \quad (2.22)$$

i akım değeri deşarjda anında pozitif ve şarj anında negatif değer almaktadır. Denklem (2.23)’te SoC_0 bataryanın SoC ’unun başlangıç değeridir.

$$SoC = SoC_0 - \int \frac{i dt}{Q(i)} \quad (2.23)$$

$V(i, SoC)$, batarya akımının ve SoC 'nın bir fonksiyonu olan batarya terminal voltajıdır. Bataryadan alınan elektrik enerjisi Denklem (2.24) ile ifade edilir.

$$EC = \int_0^{\tau} V(i, SoC) i(t) dt \quad (2.24)$$

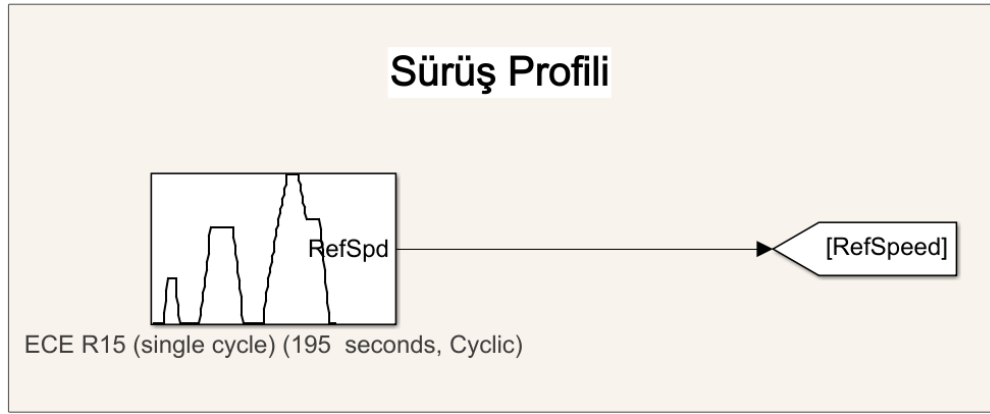


Şekil 2.17: Matlab/Simulink’de oluşturulan batarya benzetim modeli.

Şekil 2.17’de gösterilen batarya benzetimi test platformunda kullanılan batarya verileri ve yukarıdaki denklemler kullanılarak oluşturulmuştur. Batarya modelinden anlık çıkış olarak bataryanın gücü, voltajı, akımı, SoC değeri gibi veriler alınmaktadır.

2.4.6 Sürüş Profili Modeli

Bu benzetim bloğu ile literatürde kullanılan sürüş profilleri sisteme verilmekte bu hız verisi ile deneyler yapılmaktadır. Şekil 2.18’de gösterilen sürüş profili seçme bloğunda deneyi yapılacak sürüş profili seçilmektedir. EA seçilen sürüş profilindeki hız değerlerine göre sürülmektedir.



Şekil 2.18: Benzetim modelinde sürüş profili seçme bloğu.

2.4.6.1 Sürüş Profilleri

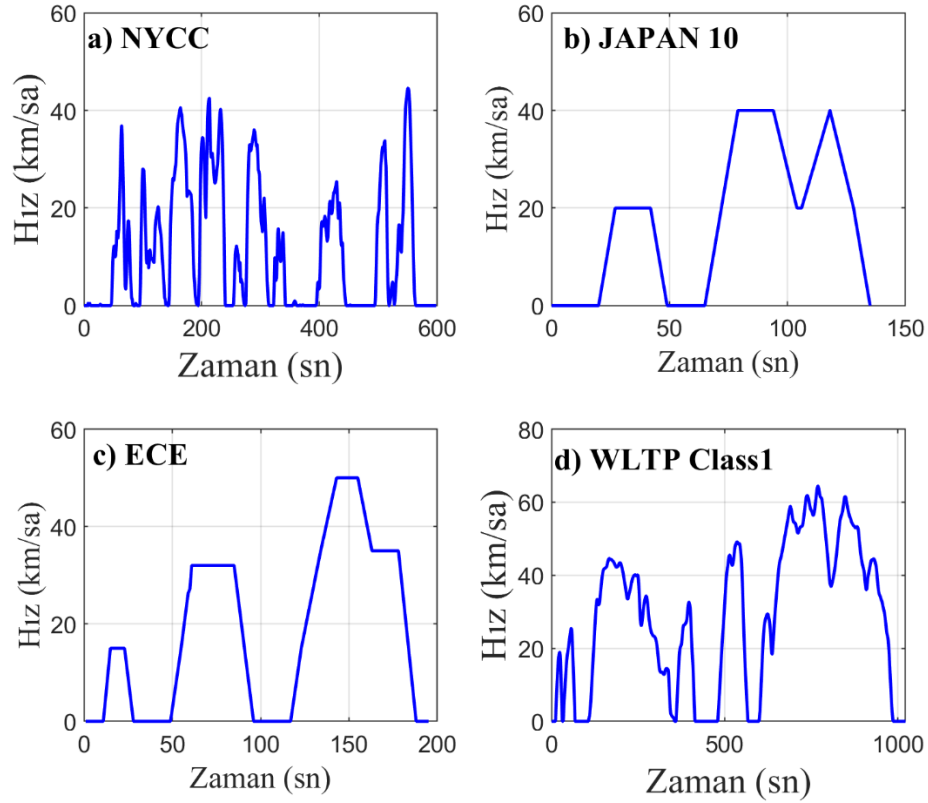
Sürüş profilleri, birçok ulusal ve uluslararası kuruluşlar tarafından oluşturulmuş, her ülkedeki yol durumunu, trafiği ve sürücü karakteristiklerini örneklemiş, zamana bağlı olarak değişen hız verisi kümeleridir. Bu sürüş profilleri kullanılarak araç bileşenleri ile oluşturulmuş benzetim çalışmalarında yazılmış olan modeller, algoritmaların performansları test edilebilme imkanı oluşmaktadır.

Tablo 2.1’de EA çalışmalarında yaygın kullanılan, sürüş profiline sahip ülkenin trafik koşullarını yansıtan, sürüş profillerinin ve karakteristik özellikleri görülmektedir (United States Environmental Protection Agency 2020).

Tablo 2.1: Sürüş profillerinin teknik özellikleri.

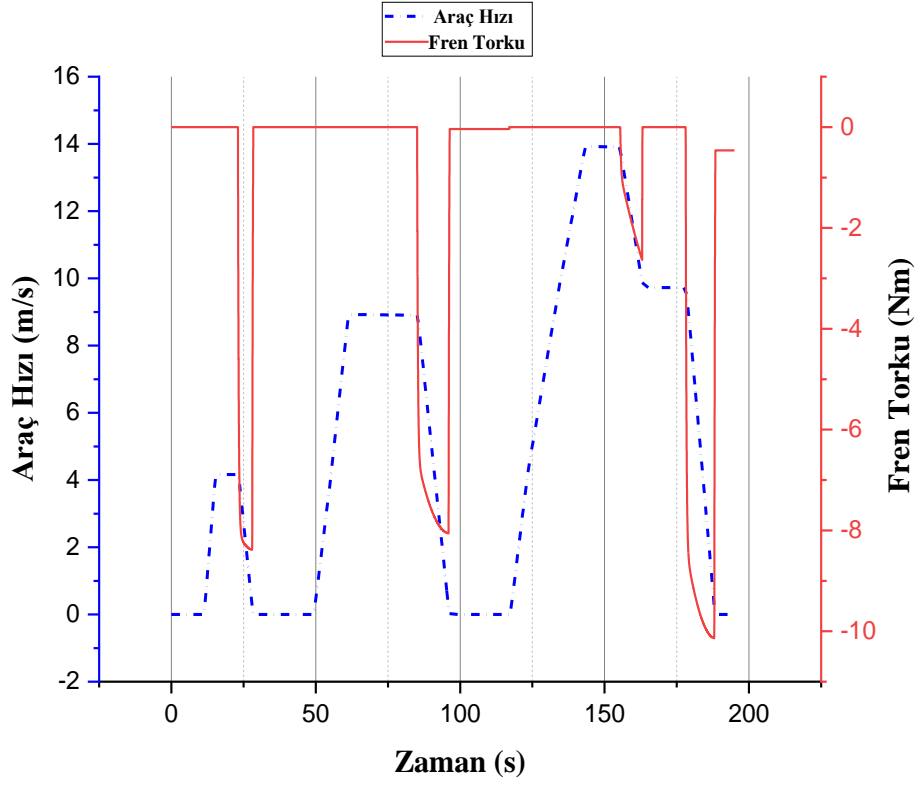
	NYCC	WLTP Ci-1	Japan-10	ECE
Duraklama Sayısı	18	9	2	3
Duraklama Süresi (sn)	210	203	39	64
Mesafe (km)	1,9	11,42	17,44	0,99
Ortalama Hız (km/sa)	11,41	28,5	17,57	18,26
Süre (sn)	598	1022	137	195
Maksimum Hız (km/sa)	44,58	44	40	50
Maksimum Yavaşlama (m/sn²)	-2,64	-1	-0,81	-0,83
Maksimum Hızlanma (m/sn²)	2,68	0,76	0,81	1,06
Ortalama Hızlanma (m/sn²)	0,62	0,69	0,67	0,64
Ortalama Yavaşlama (m/sn²)	-0,61	-0,78	-0,65	-0,75

Sürüş profilleri ülkelerdeki ve araç trafiğinin özelliklerini göstermektedir. Örneğin ECE(Avrupa sürüş profili (Europe Elementary Urban Cycle) ve JAPAN-10 sürüş profilinde sakin bir hızlanma ve yavaşlama özelliği gösterirken NYCC'de (New York City Cycle) agresif bir sürüş profili özelliği görülür.



Şekil 2.19: Kullanılan sürüş profilleri; a) NYCC, b) JAPAN 10, c) ECE, d) WLTP Class 1.


Bu tez çalışmasında modellenen şehir içi elektrikli aracın benzetim çalışmaları için Şekil 2.19'da gösterilen sürüş profilleri kullanılmıştır. Şekil 2.20'de ECE sürüş döngüsünde araç tekerinden alınan hız bilgisi ile araç parametreleri ve referans hız bilgisi ile oluşan frenleme tork talebinin karşılaştırılmalı grafiği verilmiştir. Hızlanma anında frenleme tork talebi sıfır iken yavaşlama anlarında yavaşlama miktarına göre frenleme tork talebinin negatif değer olarak değiştiği grafikte görülmektedir.



Şekil 2.20: ECE sürüş döngüsünde frenleme torku ve araç hız grafiği.

2.4.7 Öğrenme Modeli Bloğu

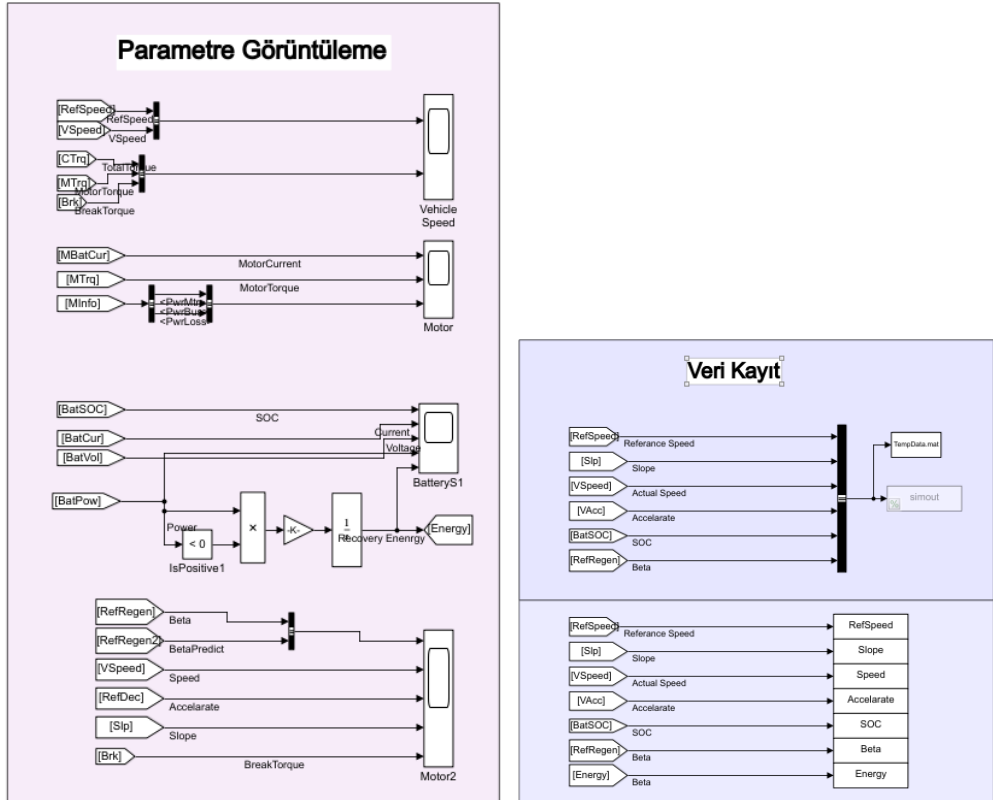
Benzetim modelinde tezin ana konusu olan öğrenen bir fren kontrol modeli deneyleri için Şekil 2.21’de gösterilen öğrenen model bloğu oluşturulmuştur. Bu blokta giriş verileri tahmin modelinde değerlendirilerek anlık olarak rejeneratif fren miktarının ne kadar olacağı ayarlanmaktadır.



Şekil 2.21: Benzetim modelinde tahmin bloku.

2.4.8 Parametre Görüntüleme ve Veri Kayıt

Benzetim modelinde deneyler yapılırken anlık olarak motorun akım, gerilim, güç değerlerini, aracın hız tork ve frenleme değerlerini gözlemlemek ve sonrasında verilerin kayıt altına alınmasını sağlamak için Şekil 2.22’de gösterilen parametre görüntüleme ve veri kayıt blokları oluşturulmuştur.



a)

b)


Şekil 2.22: a) Test sistemi parametrelerini görüntüleme bloğu, b) Veri kayıt bloku.

3. ÖĞRENME ALGORİTMALARI

Yapay Zeka denildiğinde, insanlar gibi kendi başına problemleri çözebilen karar verme yetisi olan bilgisayar sistemleri akla gelmektedir. Günümüzde bilim dünyasında her alanda bu algoritmalar karşımıza çıkmaktadır. Makine Öğrenmesi Yapay Zeka'nın bir alt dalıdır.

Makine öğrenimi, temel ilgi alanı bilgisayarların öğrenmesini sağlayan algoritmaların tasarımı ve analizi olan ve hızla büyüyen bir çalışma alanıdır. Örneğin nesnelerin otomatik algılanması sağlanarak sürücü destekli veya sürücüsüz araçların kontrolünde, konuşma tanıma ile sesli komut teknolojisinde, tıp biliminde veya tahmine dayalı analitik hesap teknolojisinde kullanılmaktadır.

Makine öğrenme algoritmaları denetimli, denetimsiz ve takviyeli öğrenme olarak üç alt dala ayrılmaktadır (Şekil 3.1).



Şekil 3.1: Makine Öğrenmesi türleri.

3.1 Denetimsiz Öğrenme

Denetimsiz öğrenme algoritmalarında etiketsiz bir veri seti kullanılmaktadır. Yani bu öğrenme modelinde veriler arası ilişki öğrenilir ve kümeleme işlemi yapılmaktadır.

3.2 Takviyeli Öğrenme

Takviyeli bir diğer adı pekiştirmeli öğrenme türünde ödül ve ceza yöntemi kullanılmaktadır. Ajanlar çevre ile etkileşime girerek karşılaşılan durum karşısında ödül ve ceza alarak en doğru yolu veya cevabı bulmaya çalışırlar.


3.3 Denetimli Öğrenme

Yapay Zeka'nın uygulaması olan Makine Öğrenmesi'nin alt kategorilerinden biride denetimli öğrenme algoritmalarıdır. Denetimli öğrenme algoritmalarında etiketli bir veri kümesi kullanılır. Bu öğrenme modelinde hem giriş hem de çıkış verileri bulunmaktadır ve sistem örneklerden öğrenir. Denetimli öğrenme, eğitim veri seti kullanarak modellere istenen çıktıyı verecek şekilde öğretmeyi amaç edinir.

Bu yöntem sınıflandırma ve tahmin olmak üzere iki tür problemlerde kullanılmaktadır. Test verilerinde belirli farklılıkları bularak bu verileri kategorilere ayırmak için sınıflandırma algoritmaları tercih edilmektedir. Başlıca sınıflandırma algoritmaları, Destek Vektör Makineleri (SVM), Doğrusal Sınıflandırıcılar, K-En Yakın Komşu (K-Nearest Neighbors / KNN) ve Rastgele Orman (RO) ve Karar Ağaçlarıdır (KA). Regresyon algoritmaları, bağımsız ve bağımlı değişkenler arasındaki ilişkiyi anlamak için kullanılmaktadır. Başlıca regresyon algoritmaları, Doğrusal regresyon (DR), KA, KNN algoritması, RO algoritmasıdır.

3.3.1 Doğrusal Regresyon Algoritması

DR, bir veya birden fazla bağımsız değişken ile bir veya birden fazla bağımlı değişken arasındaki bağıntıyı oluşturmak için kullanılmaktadır. Eldeki veriler ışığında oluşturduğu fonksiyona göre geleceği tahmin etmeye çalışan algoritma türüdür. Bağımlı ve bağımsız değişken sayısı birden fazla ise çoklu doğrusal regresyon olarak tanımlanmaktadır.



Şekil 3.2: DR eğrisi.

Her bir DR türü için, en küçük kareler yöntemiyle hesaplanan en uygun çizgiyi çizmeye çalışır (Şekil 3.2). Ancak, diğer regresyon modellerinden farklı olarak, bu çizgi bir grafikte çizildiğinde düzdür.

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3 + \dots + \beta_nx_n + e \quad (3.1)$$

Denklem (3.1)'de çok girişli DR modelinde y çıkışının hesaplanması gösterilmiştir. Burada $x_1 \dots x_n$, giriş değişkenleri yani bağımsız değişkenler, $\beta_0 \dots \beta_n$, doğrusal denklemin katsayılarını, e , regresyon sabitini, y ise çıkış değişkeni yani bağımlı değişkeni ifade etmektedir. En doğru y çıkışını bulmak için ve hatayı azaltmak için en uygun $\beta_0 \dots \beta_n$, katsayılarını bulmamız gerekmektedir.

3.3.2 KNN Algoritması

KNN algoritması öncelikle sınıflandırma algoritması olarak geliştirilmiş olsa da günümüzde regresyon problemlerinde sıklıkla kullanılan algoritmalarındandır. KNN algoritmaları yaygın olarak kullanılan Öklid mesafe ölçme fonksiyonu kullanarak, her girdi parametresine en yakın k adet komşuyu seçer ve bunların ortalamasını almaktadır.

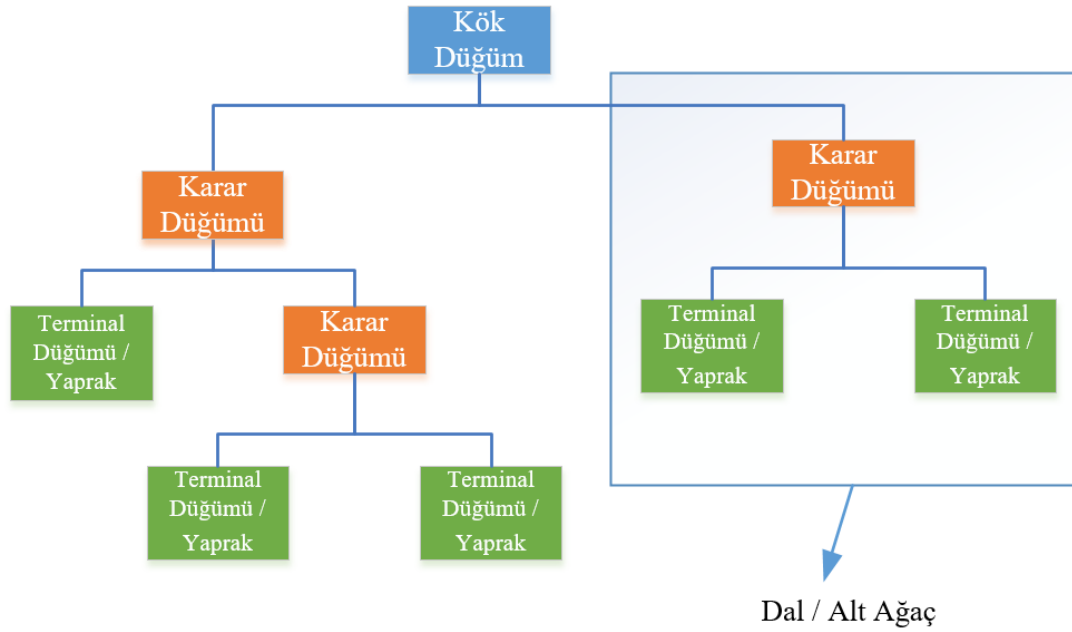
$$y = \frac{1}{k} \sum_{n=1}^N b_n \quad (3.2)$$

Denklem (3.2)'de k komşuların sayısını, b_n uzaklık fonksiyonun, y ise tahmin değerini ifade etmektedir (Şen, 2022). Tahmin doğruluğunu artırmak için k değeri iyi belirlemek gerekmektedir.

3.3.3 Karar Ağacı Algoritması

KA algoritması, modellemek istediğimiz bir durumu veya değişkeni tahmin etmek için kuralları belirlemeye yardımcı olan ağaç tabanlı algoritmaların temelini oluşturur. KA algoritmaları sonuç amaçlı kullanıcı dostu ve çıktılarının sezgisel olması en önemli avantajlarıdır. Doğrusal olmayan verilerden öğrenebilen, sayısal ve kategorik veriler ile çalışabilmektedir. Ayrıca dönüşümlü olarak sınıflandırma veya regresyon için kullanılabilir. Bu nedenle genellikle Sınıflandırma ve Regresyon Ağacı (CART) olarak adlandırılmaktadır.

Şekil 3.3'te gösterilen Kök düğüm, tüm veri setini veya bir bölümünü temsil etmektedir ve iki veya daha fazla dala ayrılabilir. Bir alt düğüm daha fazla alt düğüme bölünüyorsa bu düğüme karar düğümü denilmektedir. KA'ndaki son düğüme yaprak/terminal düğümü, bir karar düğümünden alt düğümleri çıkarma işlemine budama, bütün bir ağacın alt bölümüne alt ağaç veya dal diye ifade edilmektedir.



Şekil 3.3: KA algoritması bileşenlerinin gösterimi.

KA'da bölme işleminin en önemli amacı alt düğümler arasındaki ayırt ediciliği en üst seviye çıkarmaktır. Her nitelik için ayırt ediciliği belirlemek için bilgi kazancı (Information Gain) değeri, Entropi ile ölçülmektedir. Bilgi kazancı en yüksek olan özellik ağacın en üstüne yerleştirilir.

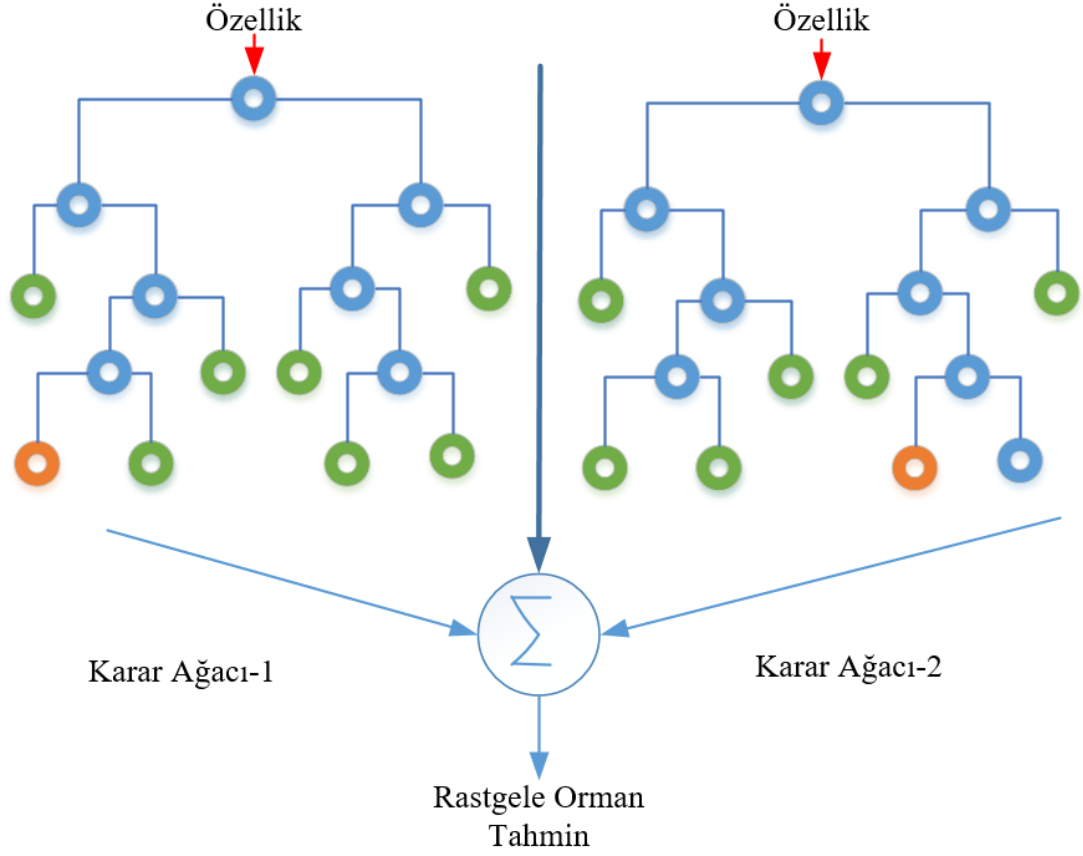
$$H(x) = \sum p(x) \log_2 p(x) \quad (3.3)$$

$$Gain(S, x) = H(S) - \sum P(x) H(x) \quad (3.4)$$

Denklem (3.3)'te $H(x)$, x özelliğinin entropi değerini, $p(x)$ ise belirli bir özelliğe sahip örnek yüzdesini ifade etmektedir. Örneğin 10 adet veri olsun bu verilerden 4 tanesi için karar anı fren yapmak olsun o zaman $p(x)$ değerimiz $4/10$ olmaktadır. Denklem (3.4)'te S veri setimizin tamamını, x ise bir setin bir bölümünü ifade etmektedir. KA algoritmasında en iyi bölümlenmeleri yapmak için entropi değerimizi düşürmemiz gerekmektedir. Bölme işlemini ne kadar doğru yaparsak yapraklar üzerinden tahmin doğrulumuzda bir o kadar artmaktadır. Bu değere göre her dal başka düğüme gidebilmekte veya tahmin değerine sahip bir yaprak olarak kalabilmektedir. Bölme işlemi tamamlandığında yapraklar oluşur ve bu yapraklar çıktı değerini göstermektedir (Massaron ve Boschetti 2016).

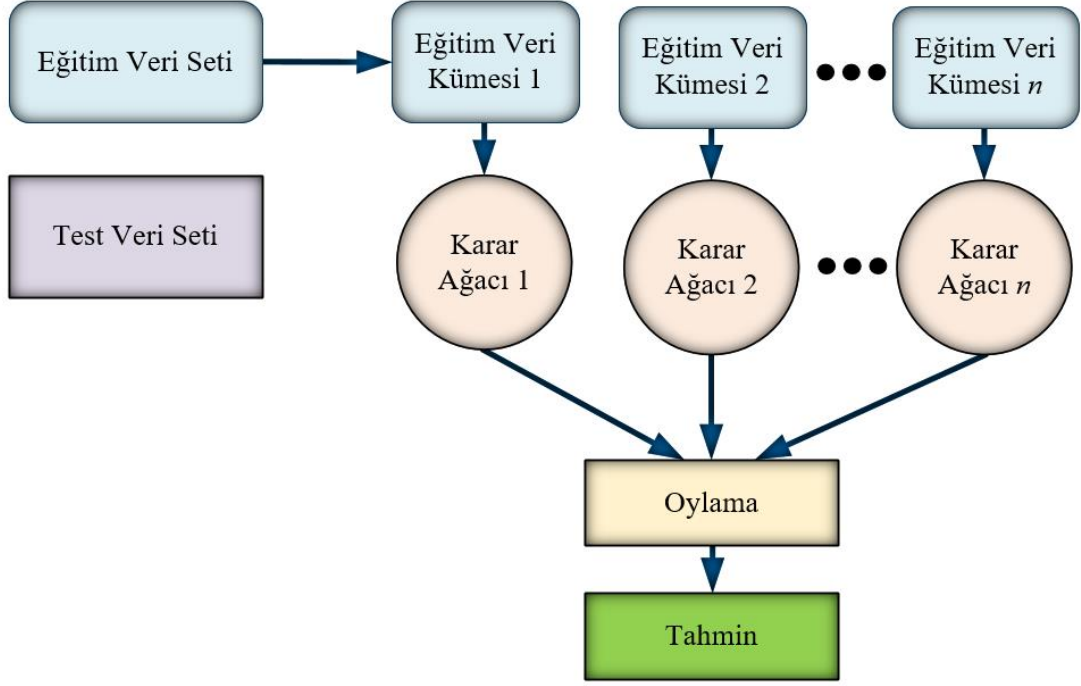
3.3.4 Rastgele Orman Algoritması

RO algoritması karar ağaçlarının birleşiminden oluşan çok yapılı bir Makine öğrenmesinin alt dalı olan denetimli öğrenme algoritmasıdır (Şekil 3.4). RO algoritması KA algoritmalarını geliştirilmiş halidir. KA algoritmasında bir özelliğe bakılarak bölünme gerçekleşirken RO algoritmasında tüm özelliklere bakılarak bölünme dallanma gerçekleşir.



Şekil 3.4: RO algoritmasının oluşumu.

RF algoritmasının çalışmasında öncelikle veri setinden rastgele örnekler seçilmektedir. Sonrasında seçilen veri örneklerine göre tahmin üretecek karar ağaçları oluşturulmaktadır.

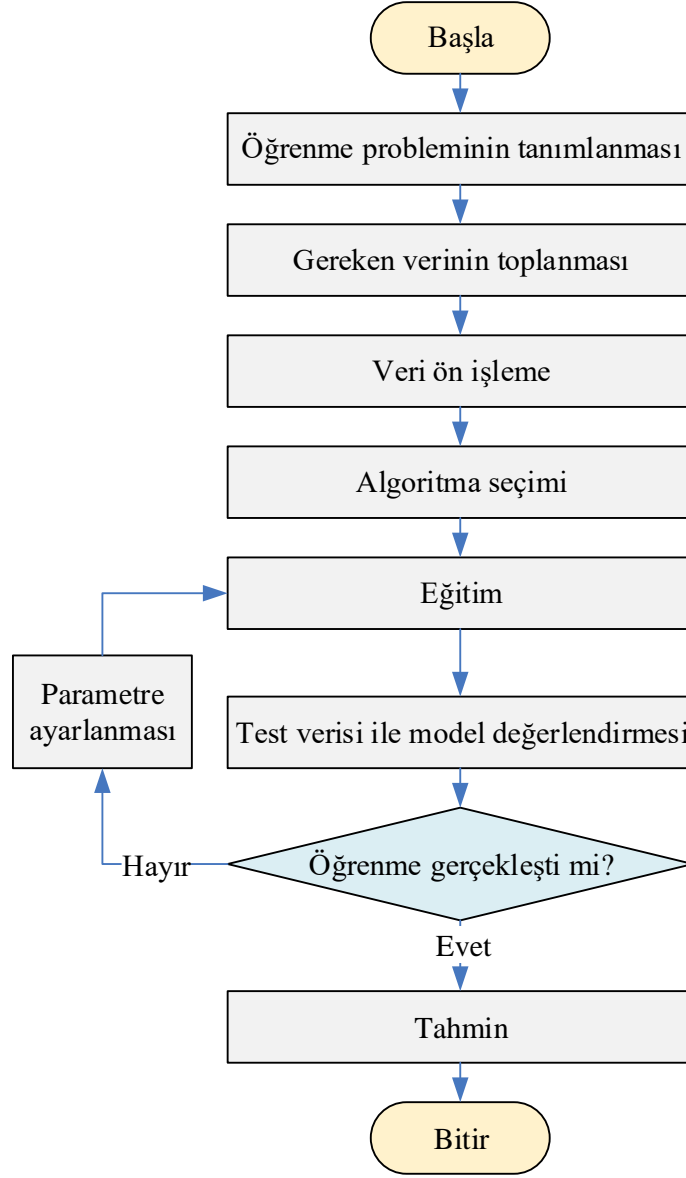


Şekil 3.5: RO algoritmasında oylama yöntemi ile tahminin oluşumu.

Şekil 3.5'te gösterildiđi gibi Karar ađaçlarından üretilen tahminler içinden oylama yöntemi ile en çok oy alan tahmin değeri çıkış olarak verilmektedir (Acet 2022).

3.4 Makine Öğrenmesi İle Model Oluşturma

Makine Öğrenmesi algoritmalarında model oluşturmak için Şekil 3.6'de gösterilen model oluşturma akış diyagramı takip edilmektedir.



Şekil 3.6: Öğrenme aşamaları (Kotsiantis, 2007).

Model oluşturmadaki aşamalar aşağıda sırasıyla anlatılmıştır.

3.4.1 Problemin Belirlenmesi

Makine Öğrenmesi algoritmalarının sağlıklı bir şekilde çalışabilmesi için problemin iyi belirlenmesi gerekmektedir. Tasarlanacak modelin amacının tam olarak ne olduğu iyi bir şekilde tanımlanıp ortaya konulmalıdır.

Rejeneratif frenleme sistemi araç sürücüsü yapısı, araç parametreleri, yol parametreleri, şehir trafiği gibi birçok etmene bağlıdır.

Bu karmaşık yapıyı geleneksel programlama yöntemleri ile programlamak mümkün olmamaktadır. Bu nedenle öğrenen bir rejeneratif fren modelinin gerekliliği ortaya çıkmıştır.

Bu tez çalışmasında öğrenen bir rejeneratif frenleme modeli amaç edinilmiştir. Bu amaç doğrultusunda Yapay Zeka'nın alt dallarından biri olan Makine Öğrenmesi algoritmaları kullanılarak sürücünden, araç parametrelerinden ve yol şartlarından bağımsız öğrenen bir fren kontrol modeli geliştirilmiştir.

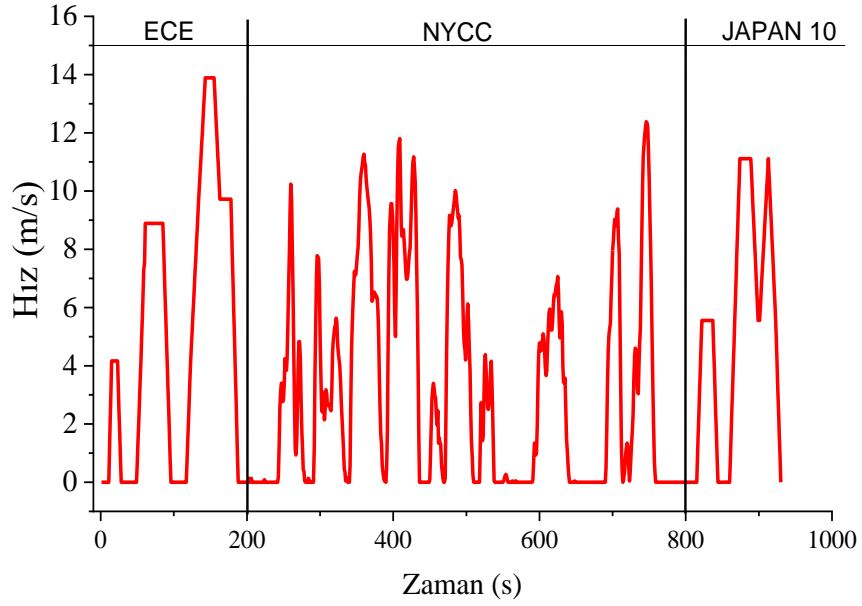
3.4.2 Veri Seti Oluşturma

Model oluşturulurken eğitilen veri setinin önemi büyüktür. Oluşturulan veri seti ne kadar modeli özetler ise modelin tahmin doğruluğu ve performansı bir o kadar artmaktadır.

Tablo 3.1: Öğrenme algoritmalarında kullanılan veri seti.

Giriş/Çıkış	Veri aralığı
Hız	0 m/s – 13,88 m/s
İvme	-2,637 m/s ² - 2,682 (m/s ²)
Eğim	%-3, %0, %3
Araç ağırlığı	150 kg - 200 kg
Yol durumu	(Asfalt, Mucur, Toprak)
Motor Torku	-5 Nm – 30 Nm
Mekanik fren torku	-30 Nm – 0 Nm

Bu tez çalışmasında tüm dünya yol, hız, eğim, sürücü profili örnek alınarak test sistemi çalışma sınırlarında genel olarak tüm hafif EA'ları örnekleyebilecek bir veri seti oluşturulmuştur. Oluşturulan veri setinin sınırları Tablo 3.1'de gösterilmiştir. Hafif EA'lar için Avrupa Şehir içi normal sürüş profili olan ECE, New York agresif şehir içi sürüş profili olan NYCC, Japonya şehir içi orta düzey agresif şehir içi sürüş profili olan JAPAN 10 profili hız verisi olarak seçilmiştir ve Şekil 3.7'de gösterilmiştir. Bu karma hız profili tüm dünya koşullarını yaklaşık olarak sağlamaktadır.



Şekil 3.7: Veri seti için oluşturulan karma hız profili.

3.4.3 Verilerin Eğitim ve Test Verisi Olarak Ayrılması

Benzetim modeli üzerinden elde edilen veri setimiz %70 eğitim verisi, %30 test verisi olarak ikiye ayrılmıştır. Eğitim veri setimiz ile modelimizi eğiterek sonrasında test veri setimiz ile doğrulama işlemi gerçekleştirilmektedir.

3.4.4 Oluşturtulan Modelin Test Verisi Kullanarak Test Edilmesi

DR, KNN, KA, RO algoritmalarının her biri kullanılarak dört farklı model oluşturulmuştur. Eğitim verileri ile eğitim işlemi tamamlandıktan sonra farklı algoritmalar ile oluşturulan modellerimiz test verileri ile tahmin doğruluğu testine sokulmuştur.

3.4.5 Oluşturtulan Modelin Gerçek Uygulamada Test Edilmesi

Algoritmalar arasında performans karşılaştırılması yapılarak en iyi sonuçları veren algoritma seçilerek eğitim ve test verisi haricinde hiç kullanılmamış bir veri seti ile gerçek bir uygulamada modelimiz test edilmiştir.

Model oluşturulduktan sonra test sistemi yazılımına model eklenerek deneysel çalışmalar yapılmıştır. WLTP Class 1 sürüş profili veri setinde bulunmadığından ve dünya geneli genelleştirilmiş hafif araçlar test prosedürü özelliğine sahip olduğu için deneylerde bu veri seti tercih edilmiştir. Yapılan deneysel çalışmaların sonuçları Bölüm 5’te verilmiştir.

3.5 Algoritmaların Değerlendirilmesinde Kullanılan Performans Ölçüm Metrikleri

Makine Öğrenmesi algoritmaları belirli durumlardan elde edilen veri kümesi değişkenleri arası ilişkiyi bulunarak bilinmeyenler için sonuç tahmin etmek için kullanılmaktadır. Algoritmaların doğruluğunu ve performanslarını karşılaştırılıp en iyi modeli üretmek için bazı ölçüm metriklerine ihtiyaç duyulmaktadır. Regresyon analizinde modelin performansını değerlendirmek için Ortalama Kare Hata(MSE), Ortalama mutlak hata(MAE), Kök Ortalama Kare Hata(RMSE) ve R-Kare(R^2) veya Belirleme Katsayısı metrikleri kullanılır.

3.5.1 R^2 Determinasyon Katsayısı

Öğrenme algoritmalarında Determinasyon Katsayısı (R^2), verilerin regresyon hattına ne kadar yaklaştığının ölçüsü olarak tanımlanmaktadır. R^2 değeri 0 ile 1 arasında değer almaktadır. 1 en yüksek tahmin doğruluğunu 0 ise en düşük tahmin doğruluğuna karşılık gelmektedir.

$$OFT = \sum_i^N (y_i - y_{ort})^2 \quad (3.5)$$

Ortalama farkların toplamı (OFT) hesabı Denklem (3.5)’te gösterilmiştir. Burada y_i gerçek veriyi, y_{ort} tahmin edilenlerin ortalamasını, N de veri sayısını ifade etmektedir.

$$HKT = \sum_i^N (y_i - y'_i)^2 \quad (3.6)$$

Hata karelerinin toplamı (HKT) hesaplaması Denklem (3.6)'da ifade edilmiştir. Burada y'_i tahmin edilen veriyi ifade etmektedir.

$$R^2 = 1 - \frac{HKT}{OFT} \quad (3.7)$$

Determinasyon katsayısı R^2 hesaplaması Denklem (3.7)'de gösterilmiştir.

3.5.2 Ortalama Kare Hatası (MSE)

MSE tahmin sonuçlarının gerçek veriden ne kadar uzakta olduğunu ölçüsüdür. Veri setindeki orijinal ve tahmin edilen değerler arasındaki farkın karesinin ortalamasını temsil eder. Kalıntıların varyansını ölçer. Hata miktarları yakın ve benzer ise MSE kullanılabilir. Fakat hata miktarı büyüdükçe ve ortalamanın üzerinde hatalar elde edilmişse MSE'ye göre değerlendirmek uygun olmayabilir. Böyle durumlarda Hatanın Mutlak ortalaması olan MAE kullanılabilir.

$$MSE = \frac{1}{N} \sum_i^N (y_i - y'_i)^2 \quad (3.8)$$

Denklem (3.8)'de MSE hesaplaması verilmiştir.

3.5.3 Kök Ortalama Kare Hatası (RMSE)

RMSE, regresyon hattının gerçek verilerden ne kadar uzak mesafede olduğunu ölçümüdür yani tahmin hatalarının standart sapmasıdır. RMSE değeri sıfır ile sonsuz değer arasında değişebilir. Modelin hiç hata yapmaması durumunda RMSE sıfır değerini almaktadır. RMSE değeri Denklem (3.9)'da gösterildiği gibi hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{N} \sum_i^N (y_i - y'_i)^2} \quad (3.9)$$

3.5.4 Ortak Mutlak Hata (MAE)

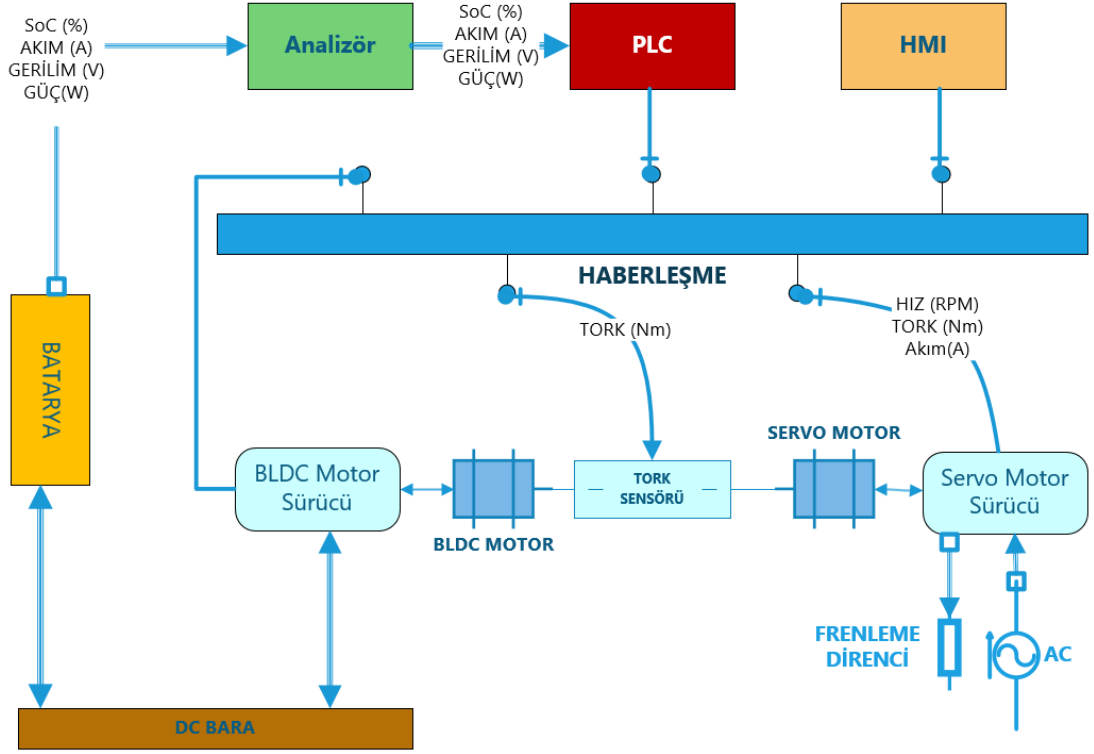
MAE, gerçek veriler ile tahmin edilen değerler arasındaki mutlak hatayı ölçmektedir. MAE her gerçek değer ile veri setine uyan en iyi regresyon çizgisine olan ortalama dikey mesafeyi vermektedir. Hesaplaması kolay olduğu için ve sezgisel olduğundan pratikte çok tercih edilen hata metriklerindedir.

$$MAE = \frac{1}{N} \sum_i^N |y_i - y'_i| \quad (3.10)$$

MAE hesaplaması Denklem (3.10)'da gösterilmiştir. MAE değeri sıfır ile sonsuz değer alabilmektedir. MAE ölçüm metriğinin RMSE'den farklı RMSE hata metriğinin nispeten büyük hatalara yüksek ağırlık vermesidir. Büyük hatalar istenilmediği durumlarda RMSE değeri dikkate alınması gerekmektedir.

4. ELEKTRİKLİ ARAÇLAR İÇİN TEST SİSTEMİ TASARIMI

EA bileşenleri dikkate alınarak, bir elektrikli aracın gerçek yol koşullarında birebir EA bileşenleri kullanarak enerji verimliliğini test etmek Şekil 4.1’de blok şeması gösterilen test platformu tasarlanmıştır.



Şekil 4.1: Elektrikli araçlar için rejeneratif mod test platform modeli.

4.1 Test Sisteminde Kullanılan Ekipmanlar

Test çalışmalarında verilerin hızlı akması ve zamanında doğru verilerin elde edilmesi oldukça önemlidir. Bu nedenle test sistemi için endüstride ve akademik çalışmalarda sıklıkla kullanılan doğruluğu kanıtlanmış ihtiyaçları karşılayan sistem araçları tercih edilmiştir. Bu sistem araçlarının ve özellikleri alt bölümlerde anlatılmıştır.

4.1.1 Analizörler

Test platformunda enerji verimliliğinin test edilmesi için batarya ve motorun akım, gerilim, güç değerleri alınması gerekmektedir. Bu doğrultuda test platformunun deneysel çalışmaları esnasında enerji transferinin, akım gerilim değişimlerinin gözlemlenmesi ve kaydedilmesi amacıyla çeşitli analizörler kullanılmıştır. Kullanılan analizörler aşağıda detaylıca anlatılmıştır.

4.1.1.1 Güç Analizörü

Şekil 4.2’de gösterilen HIOKI marka PW3390 modeli güç analizörü kullanılmıştır. Güç analizöründen alınan DC bara gerilimi, akımı ve güç akışı verileri denetleyiciye anlık olarak alınmaktadır.



Şekil 4.2: Test platformunda kullanılan güç analizörü.

4.1.1.2 AC Analizör

Test platformunda motor sargıları üzerindeki oluşan akım ve gerilim ve frekansın ölçümlenebilmesi amacıyla ENTES MPR-47SE model AC analizör kullanılmıştır (Şekil 4.3).

AC analizörün genel özellikleri aşağıda sıralanmıştır;

- 4 adet gerilim, 3 adet akım ölçme girişi,
- 16 MB dâhili hafıza,
- Olay kayıtları depolama ve yönetimi,

- 2 adet dijital giriş, 2 adet dijital, 2 adet röle ve analog çıkışı,
- 3 faz Nötrlü, 3 faz nötrsüz ölçüm yapabilme,
- Akım, gerilim, enerji, güç güç faktörü ve $\cos \phi$ ölçümü yapılmaktadır.



Şekil 4.3: Test platformunda kullanılan AC analizör (ENTES).

Akım sensörleri vasıtası ile sargılar üzerinden geçen AC akım değerleri analizöre gelmektedir. Ayrıca sargı uçlarına yapılan ölçüm bağlantısı ile de sargı uçlarında oluşan AC gerilim değerleri AC analizöre alınmaktadır. AC analizörden ölçümlenen veriler RS 485 port çıkışı aracılığı MODBUS(Seri İletişim Protokolü) protokolü ile PLC'ye gelmektedir ve ayrıca bu veriler HMI ekranında gösterilmektedir.

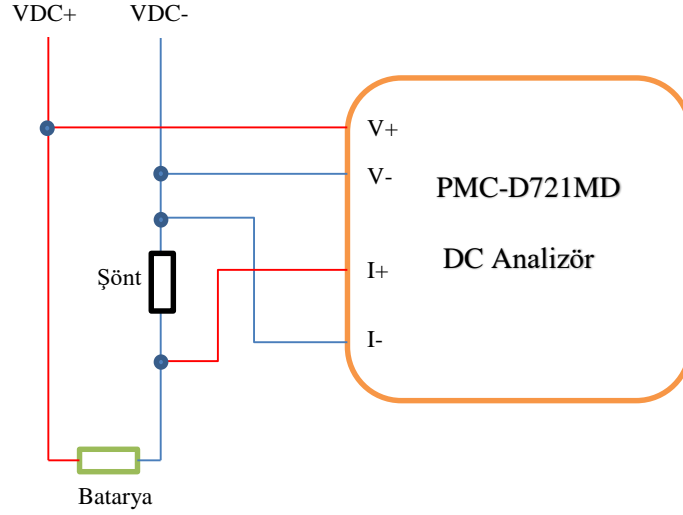
4.1.1.3 DC Analizör

Test platformunda batarya gerilimini, akımını ve gücünü gözlemlemek amacıyla CET PMC-D721MD model DC analizör kullanılmıştır (Şekil 4.4 (a)).



Şekil 4.4: a) Test platformunda kullanılan DC analizör (CET), b) Şönt direnç.

Bu DC analizör akım okumak için Şekil 4.5'te bağlantısı gösterilen şönt direnci kullanmaktadır. Gerilim okuma girişleri direk batarya çıkışına paralel bir şekilde bağlanmıştır.



Şekil 4.5: Test platformunda kullanılan DC analizör batarya bağlantısı (CET).


AC analizörün genel özellikleri aşağıda sıralanmıştır;

- Voltaj ölçümü
- Çift yönlü enerji ölçümü
- Gerçek zaman saati
- RS485 Modbus RTU haberleşme bağlantısı
- 1-100 mV şönt ile DC akım ölçümü
- Güç ölçümü
- Son 32 olayın kaydını hafızaya alabilme özelliklerine sahiptir.

Ayrıca bu analizör HIOKI PW3390 model güç analizörü kullanılarak kalibre edilmiş ve bu sayede maliyeti yüksek olan güç analizörünü sonraki uygulamalarda kullanımına gerek kalmamıştır. Bu sayede test platformunun maliyeti düşürülmüştür. DC analizörden ölçümlenen akım, gerilim, güç ve enerji verileri RS 485 port çıkışı aracılığı ve MODBUS protokolü ile PLC'ye gelmektedir ve ayrıca bu veriler HMI ekranında gösterilmektedir.

4.1.2 Servo Motor ve Sürücü

Test platformunda aracın dinamik denklemlerinden elde edilen maruz kalacağı torku elektrik motoruna yüklemek üzere servo-sistem kullanılmıştır. Kullanılan servo motor ve sürücü sistemi Delta ASDA A2 serisi ve 2,1 kW güce sahiptir (Şekil 4.6).



a)



b)

Şekil 4.6: a) Test platformunda kullanılan servo motor, b) servo motor sürücü.

Servo motora yüklenecek olan bilgisayar üzerinden gelen tork verisi PLC CANBUS haberleşmesi ile servo motora hızlı bir şekilde iletilmektedir. Servo motor sürücü içerisindeki PID kontrol algoritması ile istenilen tork değerine hızlı bir şekilde erişilip sistem senkronizasyonu sağlanmaktadır. Servo motor sürücü akımı ile tork kestirimi yapılmıştır ve bir sonraki bölümde anlatılan tork sensörü ile kalibre edilmiştir. Servo motorun arka bölümünde ve motor yükleme sehpasında orta bölümde bulunan enkoderler ile hız verileri alınmış ve dış kaynaklı devir ölçer cihazları ile doğruluğu kontrol edilmiştir. Hız değeri yine servo sürücü üzerinden CANBUS protokolü ile PLC'ye oradan da TCP/IP protokolü ile bilgisayara hızlı bir şekilde iletilmektedir.

Servo motor sürücü sistemini korumak amacıyla Şekil 4.7'de gösterilen servo rejeneratif frenleme direnci kullanılmıştır.



Şekil 4.7: Servo motor sürücü rejeneratif frenleme direnci.

4.1.3 Tork Sensörü

Test sisteminde mildeki torkun ölçülmesi için Şekil 4.8’de gösterilen Lorenz DR-2122 model tork sensörü kullanılmıştır.




Şekil 4.8: Test platformunda kullanılan tork sensörü.

Tork sensörü aynı zamanda HIOKI PW3390 model güç analizörüne bağlantı yapılarak sürüş anındaki enerji analizi yapılmasına olanak sağlamaktadır. Sonrasında Servo motor sürücü üzerinden akım verisi kullanılarak tork kestirimi yapılmış ve enerji analizörü ile kalibresi sağlanmıştır. Bu sayede maliyeti yüksek olan tork sensörü kullanılmasına gerek kalmamıştır. Oluşturulan test sisteminin maliyeti düşürülmüştür.

4.1.4 Motor Yükleme Sehpaı

Sürüş profillerini ve araç parametrelerini değiştirerek EA motoruna farklı yükleri yüklemek için motor yükleme sehpaı tasarlanmıştır. Ayrıca bu sehpa farklı

büyükölüklerde, dıştan ve içten rotorlu tüm motorların testinde kullanılabilecek şekilde ayarlanabilir olarak tasarımı gerçekleştirilmiştir. Şekil 4.9’da gösterilen motor yüklenme ünitesi kullanılarak servo motor ve EA motoru olan BLDC motorun rotor millerini birleştirilmiştir.



Şekil 4.9: Test platformunda kullanılan motor yüklenme ünitesi.

4.1.5 Denetleyici

Deney düzeneğinde, denetleyici olarak endüstride en çok tercih edilen denetleyicilerden Şekil 4.10’da gösterilen DELTA AS218tx model PLC tercih edilmiştir. Bu PLC nin tercih edilme sebebi işleminin mevcut PLC’lere göre daha hızlı olmasıdır. Çünkü sistemde tork ve hız kontrolü aynı mile bağlı iki motor tarafından yapıldığından senkronizasyon açısından sistemde hızın önemi büyüktür. Denetleyicinin test platformundaki görevi sistemdeki tüm verileri toplamak ve göndermek, test bileşenleri arası haberleşme protokollerini yönetmektir. PLC cihazı sistemin ana kontrolörü olarak görev yapmaktadır.



Şekil 4.10: Test platformunda kullanılan denetleyici.

Test sisteminde kullanılan Delta marka AS 218TX modeli PLC'nin özellikleri aşağıda sıralanmıştır;

- Dijital olarak 8 adet girişe, 6 adet çıkışa sahiptir.
- Analog olarak 2 adet girişe 2 adet çıkış bulunmaktadır.
- Dahili CANBUS, Ethernet/IP, RS 485, RS 232 haberleşme portları bulunmaktadır.
- 25 nano saniye mantıksal operasyon hızına sahiptir.
- 64K step program, 60K Word değişken kapasitesine sahiptir.
- Dahili gerçek zaman saati ve RTC işleme komutlarına sahiptir.

Sistemdeki tüm veriler PLC'de toplanmakta veya PLC üzerinden dağılmaktadır. Bilgisayardaki yazılmış olan Python programı üzerinden gelen referans hız değeri analog voltaj değeri olan 0-10V arası değere dönüştürülmekte ve BLDC motor sürücünün analog girişine verilerek istenilen hız değerine ulaşılmaktadır. Aynı şekilde referans tork değeri de CANBUS haberleşme kanalı kullanılarak hızlı bir şekilde Servo motor sürücüyeye gönderilmektedir. Ayrıca enkoder ve tork sensörü ile gerçek hız ve tork değerleri alınmaktadır. Denetleyici içerisinde oluşturulan PID algoritması ile referans hızın gerçek hız değerine, referans torkun gerçek tork değerine ulaşması sağlanmıştır.

4.1.6 İnsan Makine Arayüzü (HMI)

Oluşturulan test platformunda sistemin çalıştırılması/durdurulması ve verilerin gözlemlenip kaydedilmesi için Şekil 4.11’de gösterilen Delta marka DOP110IS 65536 renk serisi 10.1” ekran boyutuna sahip HMI kullanılmıştır.



Şekil 4.11: Test platformunda kullanılan HMI.

- Kullanılan HMI’nin özellikleri;
- 10.1” TFT 65536 renk LCD
- RS232 / RS422 / RS485 COM portları
- Ethernet bağlantısı
- Web server ile uzaktan kontrol özelliği bulunmaktadır.

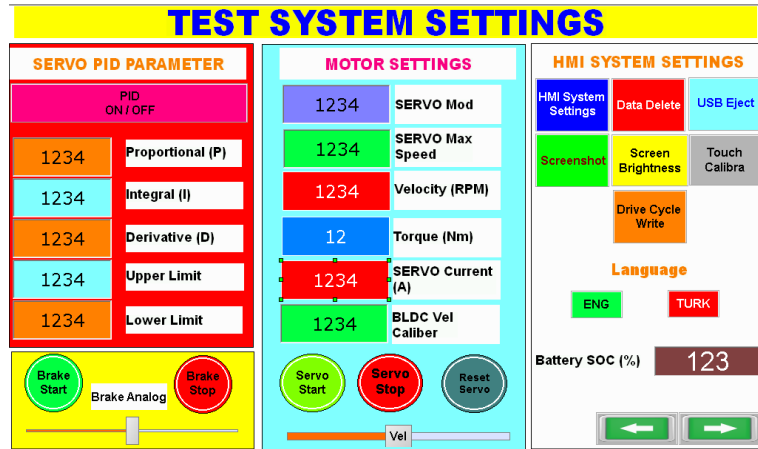
Haberleşmenin hızlı olması ve verilerin anlık olarak doğru bir şekilde gözlemlenebilmesi için PLC ile Ethernet portu üzerinden TCP/IP protokolü kullanılarak veri haberleşmesi sağlanmıştır. HMI üzerinde veri girişi ve verilerin izlenmesi amacı ile çeşitli sayfalar oluşturulmuştur. Bu sayfalar aşağıda anlatılmıştır.

Şekil 4.12’de gösterilen HMI sayfası sisteme giriş yapma sayfasıdır. Bu sayfa üzerindeki yeşil renkli buton tıklanarak sisteme giriş yapılmaktadır. Ayrıca test platformuna bağlı EA bataryasının SoC değeri gösterilmektedir.



Şekil 4.12: Test platformunda kullanılan HMI giriş ekranı.


Test platformunda gerekli ayarlamaların yapıldığı HMI sayfa tasarımı Şekil 4.13'te gösterilmiştir. Bu sayfada servo çalışma modu, frenleme sistemi PID katsayı parametreleri ayarı, servo motorun manuel kontrolü, sürüş profili yazımı, dil seçenekleri ve diğer HMI sistem ayarları yapılmaktadır. Bu sayfadan ayrıca manuel olarak motor yükleme testleri, BLDC motor hız testleri ve frenleme testleri gerçekleştirilmektedir.



Şekil 4.13: Test platformunda kullanılan HMI ayarlamaları giriş ekranı.


Araç parametre değerlerinin girildiği HMI sayfası Şekil 4.14'te gösterilmiştir. Bu sayfada ise araç dinamik denklemlerinin hesaplanmasında gerekli olan ağırlık, tekerlek yarıçapı, ön yüzey alanı vb. parametrelerin girişi, sürüş döngüsü seçimi, rejeneratif modun aktif/pasif seçimi ve batarya seçimi yapılmaktadır. Testi yapılacak elektrikli aracın özellikleri bu sayfadan girildikten sonra test işlemi bu özelliklere göre test işlemi başlatılmaktadır. Bu sayfa ile istenilirse rejeneratif mod özelliği kapatılarak sadece sürtümlü fren kullanılarak araç sürüş testleri gerçekleştirilmektedir.

Ayrıca bu sayfa sayesinde sürüş profili seçimi ve aracın parametrik değerlerini değiştirilerek enerji kullanıma etkileri gözlemlenmiştir.

VEHICLE PARAMETER SETTINGS		
Weight (kg)	1234	Driving Cycle
Wheel Radius (r,m)	1.234	European Driving Cycle
Vehicle front surface area (m ²)	1.234	Regenerative Breaking
Rolling Resistance Coefficient (Mrr)	1.234	Regenerative Braking On
Air Density (p)(kg/m ³)	1.234	Battery Type
Aerodynamic drag coefficient (Cd)	1.234	Gel
Battery Voltage (Vb)	1234	
Slope (%)	123	
SAVE DATA		

Şekil 4.14: HMI araç parametre verilerinin giriş ekranı.


Şekil 4.15'te test platformunu çalıştırmak ve deneyi başlatmak için kullanılan ana HMI ekranı gösterilmektedir. Bu HMI sayfası ile Şekil 4.14'te girilen araç parametresi, sürüş profili ve rejeneratif moda göre test sistemi çalışmaya başlatılmaktadır. Bu sayfadan BLDC motor hızı girilerek ve servo tarafından yüklenecek olan tork değeri girilerek manuel çalışmalar deneyler yapılmaktadır. Ayrıca servo aşırı yüklenme sebebiyle kendini korumaya aldığıında "Reset Servo" butonu ile servo motor hata silme ve sıfırlama işlemi gerçekleştirilmektedir. "Oto Start" butonuna basıldığında test sistemi bilgisayara hazırım bilgisini gönderir ve sonrasında bilgisayarda Python programı ile yazılmış olan yazılım çalışmaya başlar. Öncelikle Şekil 4.14'te girilen araç parametresi, sürüş profili ve rejeneratif mod bilgileri alınıp işlenir. Sonrasında PLC'ye tork ve hız değerleri gönderilir ve PLC'de bu bilgileri ilgili haberleşme protokolleri ve analog çıkışları ile ilgili sürücüler iletir ve sistem adım adım tüm sürüş profili tamamlanıncaya kadar bu işlemlere devam eder. Bu sayfa da test anında anlık olarak BLDC motor hızı, mildeki tork değeri, Batarya voltajı, akımı, gücü ve SoC değeri gösterilmektedir. Ayrıca anlık hız, batarya akımı ve tork değerinin grafiği çizdirilmektedir.



Şekil 4.15: Test platformunda kullanılan HMI ana ekranı.

Test sisteminin çalışma anında bataryanın ve motorun elektriksel değerlerinin değişimini gözlemlemek için Şekil 4.16’da gösterilen “Analizör” sayfası tasarlanmıştır.


HMI ile gözlemlenebilen bütün veriler istenilen çözünürlükte HMI arkasına takılan bir harici diske kayıt altına alınmaktadır. Aynı zamanda çalıştırılan Yapay Zeka tabanlı algoritmaların çalıştırıldığı Python programı ile bilgisayar sisteminde veriler deney çalışması bitiminde Excel formatında otomatik olarak kaydedilmektedir.



Şekil 4.16: HMI akım, gerilim, güç görüntüleme ekranı.

4.1.7 Elektrikli Araç Batarya Ünitesi

Test platformunda Şekil 4.17’de gösterilen 6 adet 12 V’luk jel batarya hücrelerinden oluşmuş bir elektrikli araç batarya grubu kullanılmıştır. Test platformundaki ölçüm değerlerinin doğruluğunu sağlamak amacıyla gerçek bir EA bataryası tercih edilmiştir.



Şekil 4.17: EA batarya ünitesi

Batarya korumalı şarj ünitesi ile önce tamamen doldurulup test platformundan *SoC* değeri ayarlanmaktadır. Sonrasında *SoC* hesabı ile de anlık olarak bataryanın *SoC* değeri izlenebilmektedir.

Tablo 4.1’de test platformunda kullanılan bataryada her bir jel batarya hücresinin kapasite ve gerilim değerleri verilmiştir (VOLTAPLEX 2012). Bu hücrelerden 6 tanesi seri bağlanarak batarya modülü oluşturulmuştur.

Tablo 4.1: Batarya hücresinin karakteristik özellikleri.

Parametre	Değerler
Minimum hücre gerilimi	12,6 V
Maksimum hücre gerilimi	14,2 V
Nominal kapasite	60 Ah
Nominal gerilim	13,2 V


4.1.8 BLDC Motor

EA motoru olarak gerçek bir EA'dan sökülmüş dıştan rotorlu %90 verime sahip pik gücü 3 kW, nominal gücü ise 2 kW BLDC motor kullanılmıştır. BLDC motor nominal 96 V çalışma gerilimine ve 750 rpm (Dakikadaki tur sayısı) dönüş hızı özelliğine sahiptir ve etiket değerleri Tablo 4.2'de verilmiştir.

Tablo 4.2: BLDC motor etiket değerleri.

Parametre	Değerler
Koruma sınıfı	IP65
Nominal motor hızı	750 rpm
Motor tipi	Dış rotorlu BLDC
Pik gücü	3 kW
Nominal güç	2 kW
Nominal gerilim	96 V
Verim	90%

Test platformunda kullanılan BLDC motorun motor sehпасına takılı haldeki görüntüsü Şekil 4.18'de gösterilmiştir. Test platformunda BLDC motor servo motor ile aynı mil üzerinde birleştirilmek üzere motor sehпасı imal edilmiştir. Motor yükleme sehпасı, yükleme torkuna dayanabilecek mukavemette tasarlanmış ve imal edilmiştir. BLDC motor ve Servo motor ortada tork sensörü olacak bir şekilde birleştirilmiştir. Bu sayede servo motor ile EA motoru olan BLDC motor aracın yol koşullarını sağlayacak şekilde yükleme gerçekleştirmektedir.



Şekil 4.18: BLDC motor görünümü.

4.1.9 Motor Sürücü

Test platformundaki elektrik motorlarını sürmek için Kelly-KBL96151 seri-model, analog girişe sahip ve rejeneratif mod destekli BLDC motor sürücüsü kullanılmıştır. Sürücü etiket değerleri Tablo 4.3'te verilmiştir. Kullanılan BLDC motor sürücü Şekil 4.19'da gösterilmiştir.



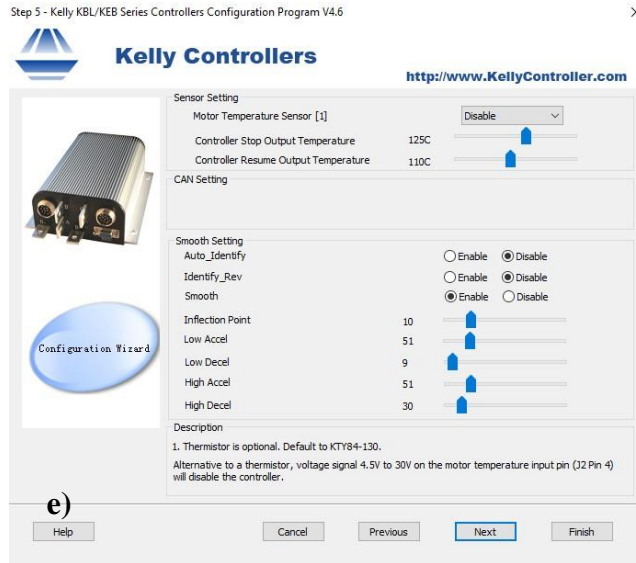
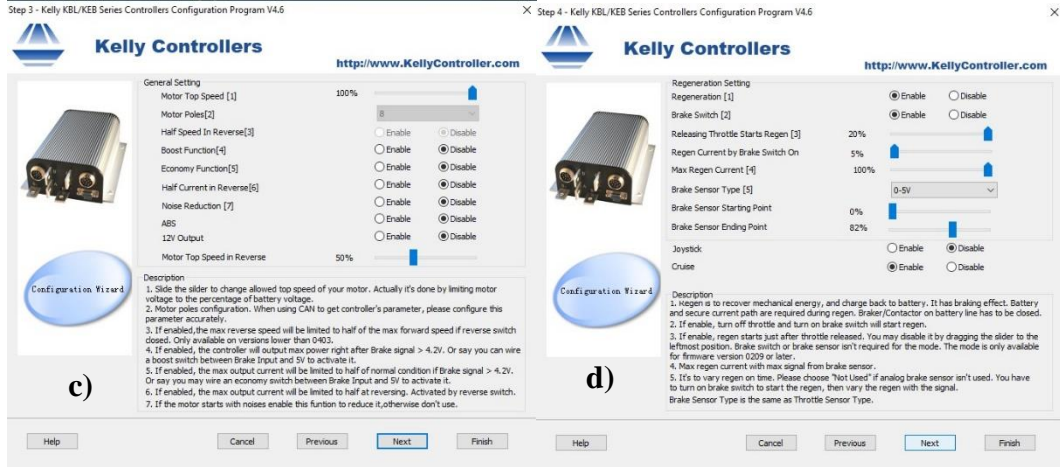
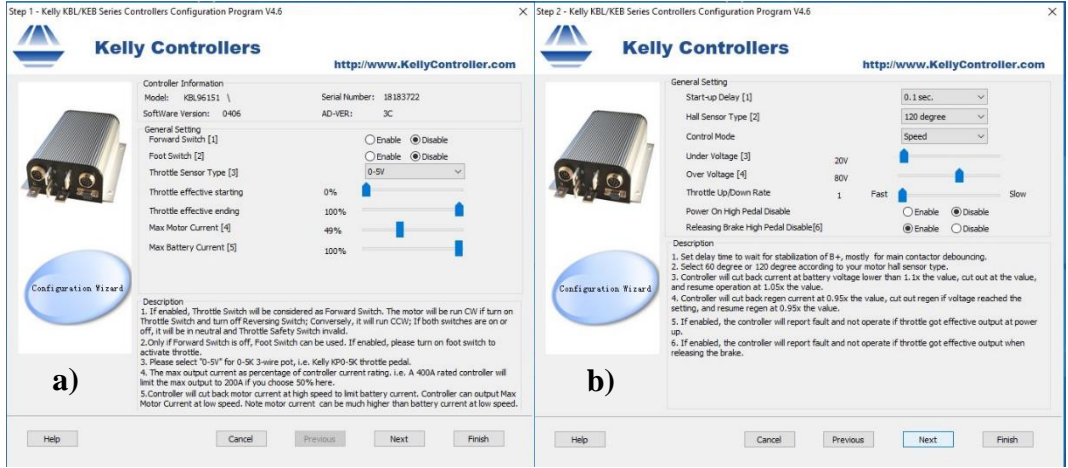
Şekil 4.19: BLDC motor sürücü görünümü.

Tablo 4.3: BLDC motor sürücü etiket değerleri.

Parametre	Değer
Hız	40000 rpm'e kadar
Maksimum akım (10 sn)	150 A
Maksimum akım (1 dk)	120 A
Sürekli durum akım	60 A
Giriş gerilimi	18-120 V
Sürekli durum akım	60 A
Çalışma frekansı	16,6 kHz
Rejeneratif Mod	Var

BLDC Motor sürücü parametre ayarlamaları RS232 seri haberleşme protokolü ile bilgisayara bağlanarak Kelly firmasının üretmiş olduğu yazılım ile yapılmaktadır. Şekil 4.20(a)'de motor sürücüye gaz pedalı bilgisi yani hız bilgisi için sensör tipi ayarı yapılmaktadır. Burada PLC analog çıkışı üzerinden hız bilgisi 0-5 V olarak gönderileceği için bu ayar seçilmiştir. Ayrıca bu sayfada motor ve bataryanın akım sınırlama ayarlamaları, motor başlangıç torku ayarlamaları da yapılmıştır. Şekil 4.20(b) 'de ise kontrol modu olarak hız modu ve Hall efekt sensör yerleşimi


ayarlamaları yapılmıştır. Şekil 4.20(c)'de ise motorun maksimum hız ayarı ve geri kazanımlarda kullanılacak ekonomi ve yükseltme ayarlamaları yapılmıştır. Şekil 4.20(d) 'de rejeneratif mod ve fren sensörü ayarlamaları yapılmıştır. Frenleme bilgisi yine PLC analog çıkışından geleceği için 0-5 V ayarı seçilmiştir.



Şekil 4.20: Sürücü parametre ayarları; a) Sayfa 1 b) Sayfa 2 c) Sayfa 3 d) Sayfa 4 e) Sayfa 5.

4.2 Deney Setinin Oluşturulması

Test siteminde kontrolör olarak endüstride sıkça kullanılan PLC (Programlanabilir Mantık Denetleyici) kullanılmıştır. Test platformunun kontrolü, ölçüm verilerin görüntülenmesi ve kayıt altına alınması için HMI kullanılmıştır. Batarya enerji transferi verilerinin kaydedilmesi için güç analizörü (HIOKI PW3390 modeli) test düzeneğine eklenmiştir. EA motorunun (BLDC motor) enerjisi jel batarya hücrelerinden 6 adet 12 V 60Ah seri bağlı batarya grubu tarafından sağlanmıştır. Servo motorun rejeneratif çalışma durumlarında kendi sistemine zarar vermemesi için frenleme yük direnci bağlanmıştır. EA motoru olan BLDC motor, servo motor ile aynı mil üzerinde bağlantı noktalarının ortasına tork sensörü bulunmak üzere bağlantısı gerçekleştirilmiştir. Bu tez çalışmasında oluşturulan test platformu Şekil 4.21’de gösterilmiştir.



Şekil 4.21: EA'lar için rejeneratif enerji denetimi test platformu görünümü.

5. DURUM ÇALIŞMALARI VE DEĞERLENDİRMELER

5.1 Benzetim Modelinde Durum Çalışmaları

Oluşturulan benzetim modeli ile Avrupa Şehir İçi Sürüş profillerinden olan ECE sürüş profili kullanılarak beş farklı durum çalışması yapılmıştır. Durum-1’de rejeneratif frenleme modu kapalı halde iken aracın ve bileşenlerinin davranışları incelenmiştir. Durum-2’de Rejeneratif mod aktif iken aracın rejeneratif frenleme anında enerji geri kazanımı incelenmiştir. Durum-3’te bir aracın yokuş yukarı giderken, Durum-4’te ise yokuş aşağı giderken araca etki eden kuvvetlerin etkisi üzerinde durulmuştur. Son olarak da Durum-5’te aracın ağırlığı artırılmış ve araç ağırlığının enerji üzerindeki etkisi incelenmiştir.


Benzetim çalışmalarında, şehir içi kullanıma yönelik düşük güçlü bir araca ait parametreler Tablo 5.1’de gösterilmiştir. Bu tez çalışmasında deneylerin yapıldığı benzetim modeli ve test platformunda Tablo 5.1’de gösterilen parametreler kullanılmıştır.

Tablo 5.1: Benzetim çalışmalarında kullanılan araca ilişkin parametreler.

Parametreler	Değerler
Havanın sürtünme katsayısı (C_d)	0,3
Tekerlerdeki sürtünme katsayısı (Kr)	0,012
Aracın ön yüzey alanı (A)	1,64 m ²
Ağırlık (m)	200 kg
Havanın kütle yoğunluğu (ρ)	1,2 kg/m ³
Tırmanma açısı (θ)	-3, 0, 3 Derece
Yerçekimi ivmesi (g)	9,81 m/s ²


5.1.1 Benzetim Çalışması Durum-1

Bu durum çalışmasında rejeneratif mod kapatılarak tüm frenleme sürtünmeli fren üzerinden sağlanmıştır. Bu nedenle herhangi bir frenleme anında enerji kazanımı söz konusu değildir. ECE sürüş profilinden referans hız değerleri uygulandığında benzetim modeli içerisindeki araç mekanik modelinde tekerlerden ölçülen hız değeri yani aracın referans hız değerlerinin karşılaştırılması Şekil 5.1’de gösterilmiştir.




Şekil 5.1: Referans hız ile araç hızının karşılaştırılması.

Referans olarak verilen hız değeri ile araçtan ölçülen hız değeri birbirini karşılamaktadır. Şekil 5.2’de toplam torkun, motor ve fren torku ile karşılaştırılması gösterilmiştir. Burada görüldüğü üzere rejeneratif mod kapalı olduğu için motor torku negatif tork oluşturamamış ve tüm frenleme sürtünmeli fren üzerinden gerçekleştirilmiştir.



Şekil 5.2: Durum-1 motor, fren ve toplam torkun karşılaştırılması.


Diğer taraftan araç hızlanma halinde iken talep edilen pozitif torku motor üretmiş ve aracı hızlandırmıştır. Şekil 5.3'te güç talebi ve enerji tüketimini görmekteyiz.




Şekil 5.3: Durum-1 enerji ve güç değerlerinin karşılaştırılması.

5.1.2 Benzetim Çalışması Durum-2

Bu çalışmada Durum-1'den farklı olarak rejeneratif mod aktif edilmiş ve frenleme anında mekanik fren ile motor freni devreye girmiştir. Şekil 5.4'te toplam torkun mekanik fren torku ve motor torkuna dağılımı görülmektedir. Frenleme anında BLDC motor rejeneratif frenleme yaparak negatif tork üretmiş ve bataryaya enerji akışı sağlamıştır. Ayrıca negatif güç talep bölgelerinde enerji kazanımı olduğu için enerji talebinin düştüğü görülmektedir (Şekil 5.5).



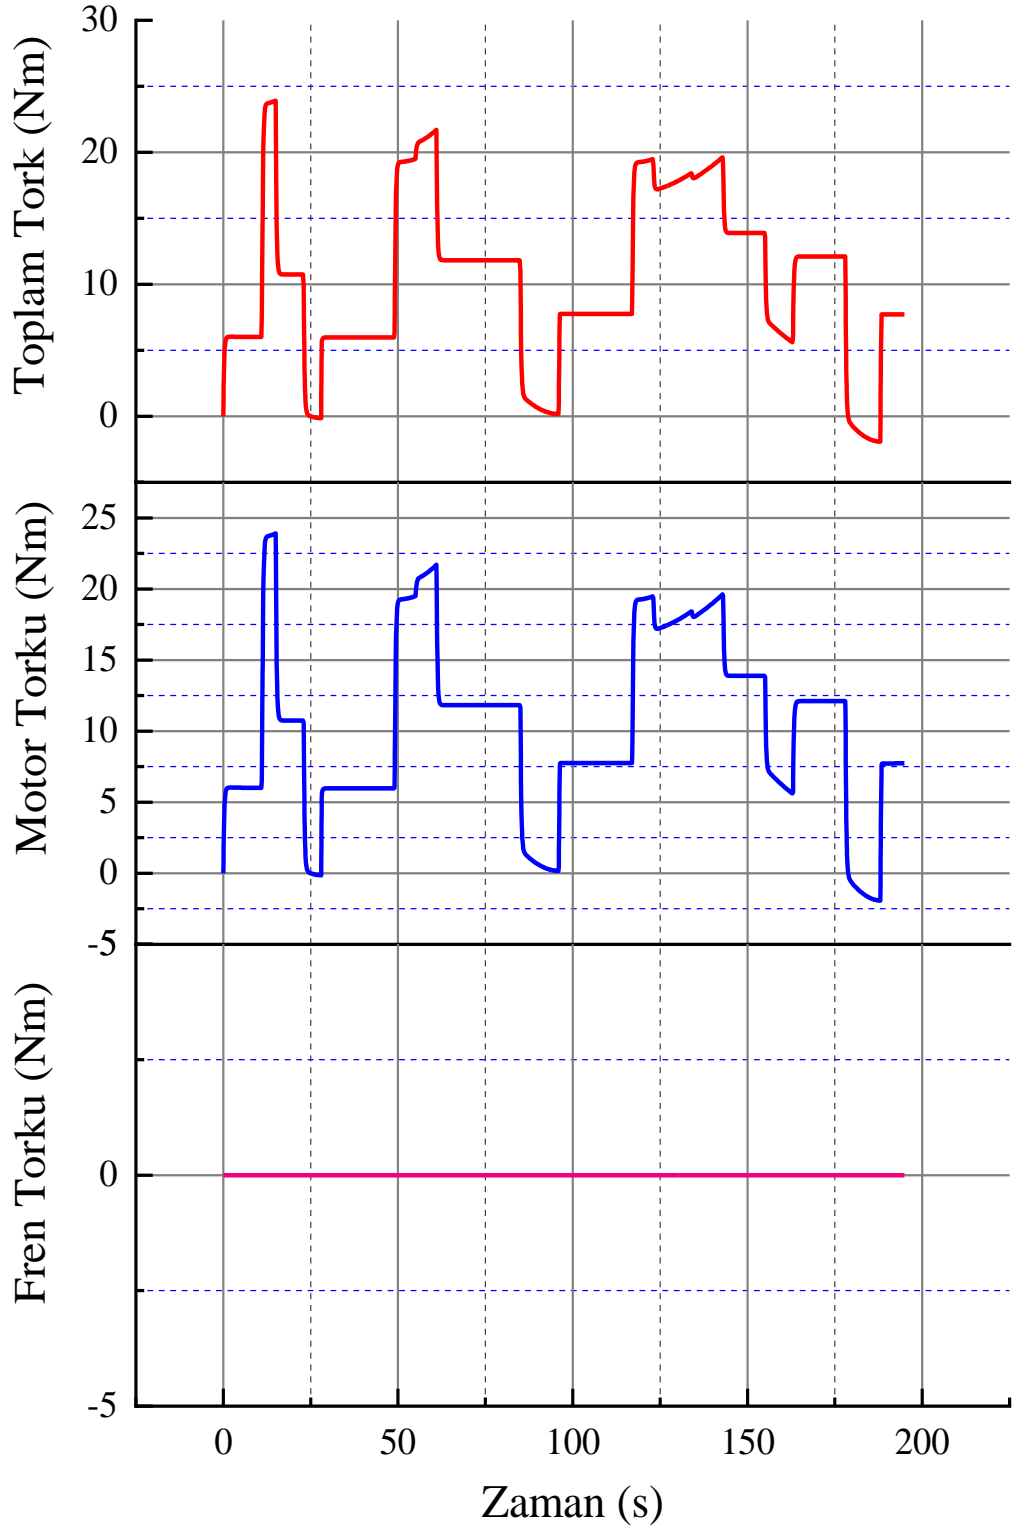
Şekil 5.4: Durum-2 motor, fren ve toplam torkun karşılaştırılması.




Şekil 5.5: Durum-2 enerji ve güç değerlerinin karşılaştırılması.

5.1.3 Benzetim Çalışması Durum 3

Durum-3 ve Durum-4 çalışmalarında yolun eğiminin EA üzerindeki etkisi gözlemlenmiştir. Durum-3 çalışmasında pozitif sabit bir eğim uygulanmış ve tork talep grafiği Şekil 5.6'da gösterilmiştir. Yokuş yukarı pozitif bir eğimle giden aracın düz bir araca göre daha fazla enerji tükettiği görülmüştür (Şekil 5.7). Ayrıca yokuş yukarı gidilirken yapılan frenleme motor freni yeterli gelmiştir ve mekanik fren yapılmadan frenleme işlemi tamamlanmıştır.




Şekil 5.6: Durum-3 motor, fren ve toplam torkun karşılaştırılması.




Şekil 5.7: Durum-3 enerji ve güç değerlerinin karşılaştırılması.

5.1.4 Benzetim Çalışması Durum-4

Bu çalışmada negatif eğim yani yokuş aşağı giden bir araç modellenmiştir. Yokuş aşağı giden araç Durum-3'e göre daha az enerji tüketmiştir. Frenleme yapmak yüksek fren torkuna ihtiyaç duyulduğundan ve rejeneratif yetersiz kalacağı için mekanik frenlemede kullanılmıştır (Şekil 5.8). Şekil 5.9'da enerji ve güç değerlerinin deney sırasında değişimi gösterilmiştir.




Şekil 5.8: Durum-4 motor, fren ve toplam torkun karşılaştırılması.




Şekil 5.9: Durum-4 enerji ve güç değerlerinin karşılaştırılması.

5.1.5 Benzetim Çalışması Durum-5

Bu durum çalışmasında araç ağırlığının toplam talep torkuna ve frenleme torkuna etkisi incelenmiştir. Araç ağırlığı 50 kg daha artırılarak rejeneratif frenleme ve mekanik frenleme tork değişimleri Şekil 5.10'de gösterilmiştir. Araç ağırlığı arttığı için enerji talebi yükselmiş ve daha fazla enerji tüketildiği gözlemlenmiştir (Şekil 5.11).



Şekil 5.10: Durum-5 motor, fren ve toplam torkun karşılaştırılması.



Şekil 5.11: Durum-5 motor, fren ve toplam torkun karşılaştırılması.

Benzetim sistemi tasarımı ve deney uygulamaları tamamlandıktan sonra test sistemi tasarımı gerçekleştirilmiştir. Bir sonraki bölümde EA'lar için tasarlanmış EA test sistemi tanıtılmıştır.

5.2 Test Sisteminde Yapılan Deneysel Çalışmalar


Benzetim modelinde yapılmış olan durum çalışmalarının gerçek bileşenleri barındıran test sisteminde doğrulaması yapılmak üzere test sistemi üzerinde beş deney yapılmıştır. Bu deneysel çalışmaların sonuçları aşağıda sırasıyla verilmiştir.

5.2.1 Durum-1 için Deneysel Çalışma


Durum çalışması 1’de, ECE sürüş profili kullanılarak, elektrikli aracın hız değişimlerinde ve rejeneratif frenleme olmadan düz yolda sabit hızda hareket halindeyken enerji değişimlerinin ve tork talebinin karşılaştırılması amaçlanmıştır.

Test grafikleri Şekil 5.12’de verilmiştir ve bu deneyden elde edilen gözlemlenen sonuçlar aşağıdaki gibi değerlendirilmiştir:

- Toplam enerji tüketimi 26076 Joule (J)’dür.
- Tork talebi ve enerji talebi doğru orantılıdır.
- Tork talebi en büyükten en küçüğe doğru hızlanma, sabit hız ve yavaşlama bölgelerinde sıralanmıştır. Yavaşlama bölgelerinde motor torku sıfırdır.
- Sabit hız bölgelerinde, hız ne kadar yüksekse tork talebi de o kadar büyük olur.
- Hızlanma ve sabit hızda hareket sırasında enerji tüketimi gerçekleşmesine rağmen yavaşlama bölgesinde enerji tüketilmez.
- Referans torkun negatif olduğu bölgelerde sadece mekanik frenleme uygulanır.



(a)



(b)


Şekil 5.12: Düz yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.

5.2.2 Durum-2 için Deneysel Çalışma


İkinci durum çalışmasında ise ilk durum çalışmasından farklı olarak rejeneratif frenleme yapılarak enerji geri kazanımının etkisinin gözlemlenmesi amaçlanmıştır. Deneysel sonuçları içeren tork, güç ve enerji grafikleri Şekil 5.13'te gösterilmiştir. Bu deneysel çalışmadan elde edilen sonuçları aşağıdaki gibi değerlendirilmiştir:

- Toplam enerji tüketimi 20319 J'dür. Ancak rejeneratif frenleme sayesinde 2883 J enerji geri kazanılmıştır.
- Tork talebi en büyükten en küçüğe doğru hızlanma, sabit hız ve yavaşlama bölgelerinde sıralanmıştır. Yavaşlama bölgelerinde motor torku negatiftir.
- Hızlanma ve sabit hızda hareket sırasında enerji tüketilirken, yavaşlama bölgelerinde enerji geri kazanılmaktadır.
- Mümkün olan maksimum enerji geri kazanımı gerçekleştirilirken, referans hızı takip etmek için mekanik frenleme de uygulanır.
- Enerji geri kazanımının gerçekleştiği yavaşlama bölgelerinde enerji tüketim grafiğinde düşüş gözlemlenmektedir.

- Enerji geri kazanımının gerçekleştiği bölgelerde güç negatiftir. Diğer bir deyişle, enerji elektrik motorundan bataryaya doğru akmaktadır.



(a)




(b)

Şekil 5.13: Düz yol rejeneratif mod aktif sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.


5.2.3 Durum-3 için Deneysel Çalışma

Durum çalışması 3, eğimli yol koşullarında EA üzerine etki eden kuvvetlerin etkisini gözlemlemeyi amaçlamaktadır. Bu parametreyi daha anlaşılır kılmak için yokuş yukarı ve yokuş aşağı olmak üzere iki farklı deney tasarlanmıştır. Bu çalışmada sabit pozitif eğime sahip yol test edilmiştir. Test grafikleri Şekil 5.14'te verilmiş olup bu deneyden gözlemlenen sonuçlar aşağıdaki gibi değerlendirilmiştir:

- Enerji geri kazanımı gerçekleşmesine rağmen toplam enerji tüketimi 31758 J'dür. Ancak enerji geri kazanımı deneysel çalışma-2'ye kıyasla azalmakla birlikte 2580 J olarak elde edilmiştir.
- Yokuş yukarı bir yolda, araç düz bir yola göre daha fazla torka ihtiyaç duymaktadır. Tersine, yavaşlama için daha az mekanik frenleme gerekmektedir.



(a)




(b)

Şekil 5.14: Regeneratif frenleme ile yokuş yukarı yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.


5.2.4 Durum-4 için Deneysel Çalışma

Bu çalışmada, deneysel çalışma-3'ün aksine, deney çalışması-4 olarak yokuş aşağı yol sürüşü gerçekleştirilmiştir. Test grafikleri Şekil 5.15'te verilmiştir ve bu deneyden elde edilen gözlemlenen sonuçlar aşağıdaki gibi değerlendirilmiştir:

- Yokuş aşağı yolda aracın harcadığı toplam enerjide çok büyük bir düşüş vardır ve toplam enerji 8758 J'dür. Ayrıca 3532 J'lük enerji geri dönüşüm olarak gerçekleşmekte ve en çok mekanik frene ihtiyaç duyulmaktadır.
- Yokuş aşağı yolda araç, düz yola göre daha az torca ihtiyaç duymaktadır.
- Fakat yavaşlamak için daha fazla mekanik frenleme gerekmektedir.
- Yüksek enerji geri dönüşümü de elde edilmiştir. Ancak mekanik frenlemede kaybedilen enerji daha fazla olduğu gözlemlenmiştir.



(a)



(b)


Şekil 5.15: Regeneratif frenleme ile yokuş aşağı yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.

5.2.5 Durum-5 için Deneysel Çalışma


EA'larda enerji ihtiyacının miktarını belirleyen bir diğer parametre de aracın ağırlığıdır. Bu deneyde aracın diğer özelliklerinin değişmediği varsayılmış ve aracın

kütlesine 50 kg yük eklenmiştir. Test grafikleri Şekil 5.16'da verilmiştir ve bu deneyden elde edilen gözlem sonuçları aşağıdaki gibi değerlendirilmiştir:

- Toplam enerji tüketimi 22966 J'dür. Geri kazanılan enerji miktarı ise 2496 J'dür.
- Deney-2 ile karşılaştırıldığında hem hızlanma hem de yavaşlama sırasında talep edilen tork için bir artış görülmektedir.



(a)



(b)

Şekil 5.16: Rejeneratif frenleme ve 50 kg yük ile düz yol sürüş testi a) Tork grafiği b) Güç ve enerji grafiği.

5.3 Deneysel Çalışmalarda Rejeneratif Enerji Sonuçları

Bu çalışmada değişen araç ağırlığı, yol eğimi, rejeneratif frenleme koşulları altında beş deneysel çalışma gerçekleştirilmiştir ve alınan enerji ve güç değerleri Tablo 5.2’de gösterilmiştir.

Tablo 5.2: Deneysel çalışmalardan alınan enerji değerleri.

	Rejeneratif Durum	Eğim (%)	Yük (kg)	Toplam Enerji (J)	Rejeneratif Enerji (J)	Maksimum Güç (W)
Deney-1	Pasif	Düz %0	0	26076	0	590
Deney-2	Aktif	Düz %0	0	20319	2883	570
Deney-3	Aktif	Yokuş yukarı %3	0	31758	2580	730
Deney-4	Aktif	Yokuş aşağı %-3	0	8758	3532	416
Deney-5	Aktif	Düz %0	50+	22966	2496	670

İlk deneyde araç, yüksüz durum ve rejeneratif frenleme olmadan düz bir yolda test edilmiştir. Bu deneyde toplam bataryadan çekilen enerji 26076 J, talep edilen maksimum güç 590 W olmuştur. İkinci deneyde, ilk deneyden farklı olarak rejeneratif frenleme ile enerji geri kazanımı sağlanmıştır. Böylece rejeneratif frenleme sayesinde yaklaşık %22 kazanç sağlanmıştır. Deneysel çalışma-3’te, deneysel çalışması-2’den farklı olarak, yol eğimi değiştirilmiştir. Yol eğimi %3 artırıldığında toplam harcanan enerji %56 artarken, enerji geri kazanım miktarı %10 azalmıştır. Deneysel çalışma-4’de yol eğimi %3 azaltıldığında toplam enerji %56 azalmış ve geri kazanılan enerji %22 artmıştır. Son deneysel çalışmada ise yükün etkilerini gözlemlemek için Deneysel çalışma-2’nin koşullarına 50 kg’lık bir yük eklenmesi yapılmıştır. Araç ağırlığına yapılan %25 yük artışı sonucunda, toplam enerjide %13’lük bir artış olmuştur. Sonuç olarak, deneysel sonuçlar EA’nın dinamik denklemlerini desteklemektedir.

5.4 Öğrenme Algoritma Sonuçları ve Değerlendirme

Öğrenen bir model oluşturmak için öncelikle giriş ve çıkış değişkenleri oluşturulmuştur. Giriş bileşenleri olarak, hız, ivme, yol eğimi, araç ağırlığı ve yolun durumu belirlenmiştir. Burada yolun durumu ifadesi yolun asfalt, mucur veya toprak

yol olması deęişkenidir ve matematiksel modelde yuvarlanma sürtünme katsayısı olarak ifade edilmektedir. Çıkış bileşeni olarak da motor torku ve mekanik fren torku belirlenmiştir.

Tablo 5.3: Öğrenme algoritmalarında kullanılan araca ilişkin giriş çıkış parametreleri.

Giriş/Çıkış		Parametreler
X1	Giriş	Hız (m/s)
X2	Giriş	İvme (m/s ²)
X3	Giriş	Eğim (%)
X4	Giriş	Araç ağırlığı (kg)
X5	Giriş	Yol durumu (Asfalt, Mucur, Toprak)
Y1	Çıkış	Motor Torku (Nm)
Y2	Çıkış	Mekanik fren torku (Nm)


Çıkış bileşenlerinden olan motor torku, hem hızlanma için gerekli pozitif tork değerini hem de motor üzerinden Rejeneratif fren ile yavaşlama için gerekli negatif tork değerine karşılık gelmektedir. Diğer çıkış bileşeni mekanik fren torku ise yavaşlama anında Rejeneratif fren torkunun yetersiz kaldığı durumlarda mekanik freni ayarlayacak olan fren tork değeridir. Giriş ve çıkış verilerimizin etiketleri Tablo 5.3'te verilmiştir.

Giriş ve çıkış verilerimiz belirlendikten ve ön veri temizliği yapıldıktan sonra verilerimizi belirli bir oranda eğitim ve test verisi olarak ikiye ayırıyoruz. Bu çalışmada 11622 veriden %70 eğitim verisi olarak, %30 'u ise test verisi olarak ikiye ayrılmıştır.

Öğrenme tabanlı algoritma olarak Yapay Zeka'nın alt dalı olan Makine Öğrenmesi algoritmaları kullanılmıştır. Makine Öğrenmesi algoritmalarından da denetimli öğrenme kategorisinde bulunan DR, KNN, KA, RO olmak üzere dört farklı algoritma üzerinde çalışılmış ve aşağıda bu algoritmalarından elde edilen sonuçlar değerlendirilmiştir.


5.4.1 Doğrusal Regresyon Algoritması Bulguları

Denetimli öğrenme algoritmalarından olan DR algoritması genelde bağımlı ve bağımsız veri arasında doğrusal bir ilişki olduğunda sağlıklı sonuçlar elde edilebilen regresyon algoritmasıdır. Şekil 5.17’de görüldüğü üzere gerçek Y1 çıkışı ile tahmin edilen Y1 çıkışı arasında doğru tahmin yapılamadığından dolayı farklar bulunmaktadır ve bu da istenmeyen bir durumdur.



Şekil 5.17: DR algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.

Şekil 5.18’de Y2 çıkış verisi için gerçek ve tahmin değerleri arasında farklar gösterilmiştir. Burada grafik incelendiğinde istenmeyen aşırı çıkış değerleri üretilmiş ve bu durum aracın denge sınırlarını aşabileceğinden dolayı tehlikeli sonuçlar oluşturması muhtemeldir.



Şekil 5.18: DR algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.


Tablo 5.4'te DR algoritmasının istatistiksel değerlendirme metriklerinin değerleri verilmiştir.

Tablo 5.4: DR algoritması ölçüm değerleri.


Ölçüm	Değer
R ² Skor	0,67
MSE	16,54
RMSE	4,07
MAE	3,08

5.4.2 KNN Algoritması Bulguları

KNN algoritması en yakın komşuluk ilkesine dayanan Makine Öğrenmesi algoritmalarından denetimli algoritmalarından birisidir. KNN veri setindeki her giriş parametresine olan mesafeyi hesaplar bunların içinden k adet komşuyu seçer ve bu sonuçların ortalamasını alarak sonuç değerini tahmin eder. Bu tez çalışmasında en iyi sonuçlar k değeri 2 belirlenerek alınmıştır. KNN algoritması ile oluşturulan modelin çıktıları Şekil 5.19'de Y1 çıkış verisi için ve Şekil 5.20'de ise Y2 çıkış verisi için gerçek veri ve tahmin edilen verilerin karşılaştırılması gösterilmiştir.



Şekil 5.19: KNN algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.



Şekil 5.20: KNN algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.


KNN ile oluşturulan modelin performans metrikleri Tablo 5.5'te verilmiştir. Burada R^2 0,86 , MSE 7,15 , RMSE 2,67 , MAE 1,37 olarak hesaplanmıştır.

Tablo 5.5: KNN algoritması ölçüm değerleri.


Ölçüm	Değer
R^2 Skor	0,86
MSE	7,15
RMSE	2,67
MAE	1,37

5.4.3 Karar Ağacı Algoritması Bulguları

KA algoritmaları denetimli algoritma kategorisinde olan ve verilerin doğrusal bir yayılım göstermediği durumlarda sıklıkla tercih edilen Makine Öğrenmesi algoritmalarından birisidir. KA algoritması ile oluşturulan modelin çıktıları Şekil 5.21’de Y1 çıkış verisi için ve Şekil 5.22’de ise Y2 çıkış verisi için gerçek veri ve tahmin edilen verilerin karşılaştırılması gösterilmiştir.



Şekil 5.21: KA algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.



Şekil 5.22: KA algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.


KA algoritması ile oluşturulan modelin performans metrikleri Tablo 5.6'da verilmiştir. Burada R^2 0,96 , MSE 1,94 , RMSE 1,39 , MAE 0,46 olarak hesaplanmıştır.

Tablo 5.6: KA algoritması ölçüm değerleri.


Ölçüm	Değer
R^2 Skor	0,96
MSE	1,94
RMSE	1,39
MAE	0,46

5.4.4 Rastgele Orman Algoritması Bulguları

RO algoritması denetimli öğrenme algoritmalarından olup, karar ağaçları birleştirilerek oluşturulan Makine Öğrenmesi algoritmasıdır. Bu algoritmada birden çok karar ağacının sonu alınıp sonrasında bunlar oylanarak tahmin sonu edilmektedir. RO algoritması ile oluşturulan modelin çıktıları Şekil 5.23'te Y1 çıkış verisi için ve Şekil 5.24'te ise Y2 çıkış verisi için gerçek veri ve tahmin edilen verilerin karşılaştırılması gösterilmiştir.



Şekil 5.23: RO algoritması ile gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.



Şekil 5.24: RO algoritması ile gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.


RO algoritması ile oluşturulan modelin performans metrikleri Tablo 5.7’de verilmiştir. Burada R^2 0,97 , MSE 1,39 , RMSE 1,18 , MAE 0,41 olarak hesaplanmıştır.

Tablo 5.7: RO algoritması performans ölçüm değerleri.

Ölçüm	Değer
R^2 Skor	0,97
MSE	1,39
RMSE	1,18
MAE	0,41

5.4.5 Algoritma Performanslarının Karşılaştırılması

Bu tez çalışmasında öğrenen rejeneratif enerji denetimi için oluşturulan algoritmaların performanslarının değerlendirildiği ölçüm metrik sonuçları Şekil 5.25'te verilmiştir. Sonuçlar değerlendirildiğinde veri setinde kullanılan bağımlı değişken ve bağımsız değişken verileri arasında doğrusal bir ilişki bulunmadığından performans açısından en kötü sonuçları DR modelinden alınmıştır. KNN algoritması DR algoritmasından biraz daha iyi sonuçlar vermesine rağmen yine de yeterli bulunmamıştır. En iyi sonuçlar KA ve RO algoritmalarından alınmıştır. Bu iki algoritma arasında kıyaslama yapıldığında ve 4 farklı algoritma içinde en iyi performans sonuçları, 0.97 R^2 , 1.39 MSE, 1.18 RMSE, 0.41 MAE performans değerleri ile RO algoritmasından alınmıştır.



Şekil 5.25: Algoritmaların karşılaştırılması, a) R^2 , b) MSE, c) RMSE, d) MAE değeri.

Öğrenen rejeneratif enerji denetimi modeli için test verileri ile yapılan çalışmada en iyi sonuçları veren RO algoritması kullanılarak oluşturulan modelimiz farklı bir veri seti kullanılarak da kullanılabilirliği test edilmiştir.

5.5 Deneysel Sonular ve Deęerlendirme


Bu tez alıřmasında drt farklı algoritma ile modelleme yapılmıřtır. Bu algoritmaların birbirleri arasında performans deęerlendirilmesi yapıldıęında en iyi performans gstergeleri RO algoritmasından alınmıř ve bu algoritma ile oluřturulan model test sisteminde farklı bir srř evirimi iin deneysel alıřmaları yapılmıřtır.

5.5.1 RO Algoritmasının Deneysel Deęerlendirilmesi

WLTP Class 1 srř profili dnya apında uyumlařtırılmıř hafif aralar test prosedrdr. Bu srř profili eęitim ve test iin kullandıęımız veri setimizde bulunmamaktadır. Oluřturulan modelimiz dřk gl aralar iin tasarlandıęından modelimizi test etmek iin en uygun veri seti olarak WLTP Class 1 srř profili seilmiřtir.

Tablo 5.8: WLTP Class 1 srř profilinin Rastgele Orman algoritması ile performans lm deęerleri.

lm	Deęer
R ² Skor	0,98
MSE	0,78
RMSE	0,88
MAE	0,27

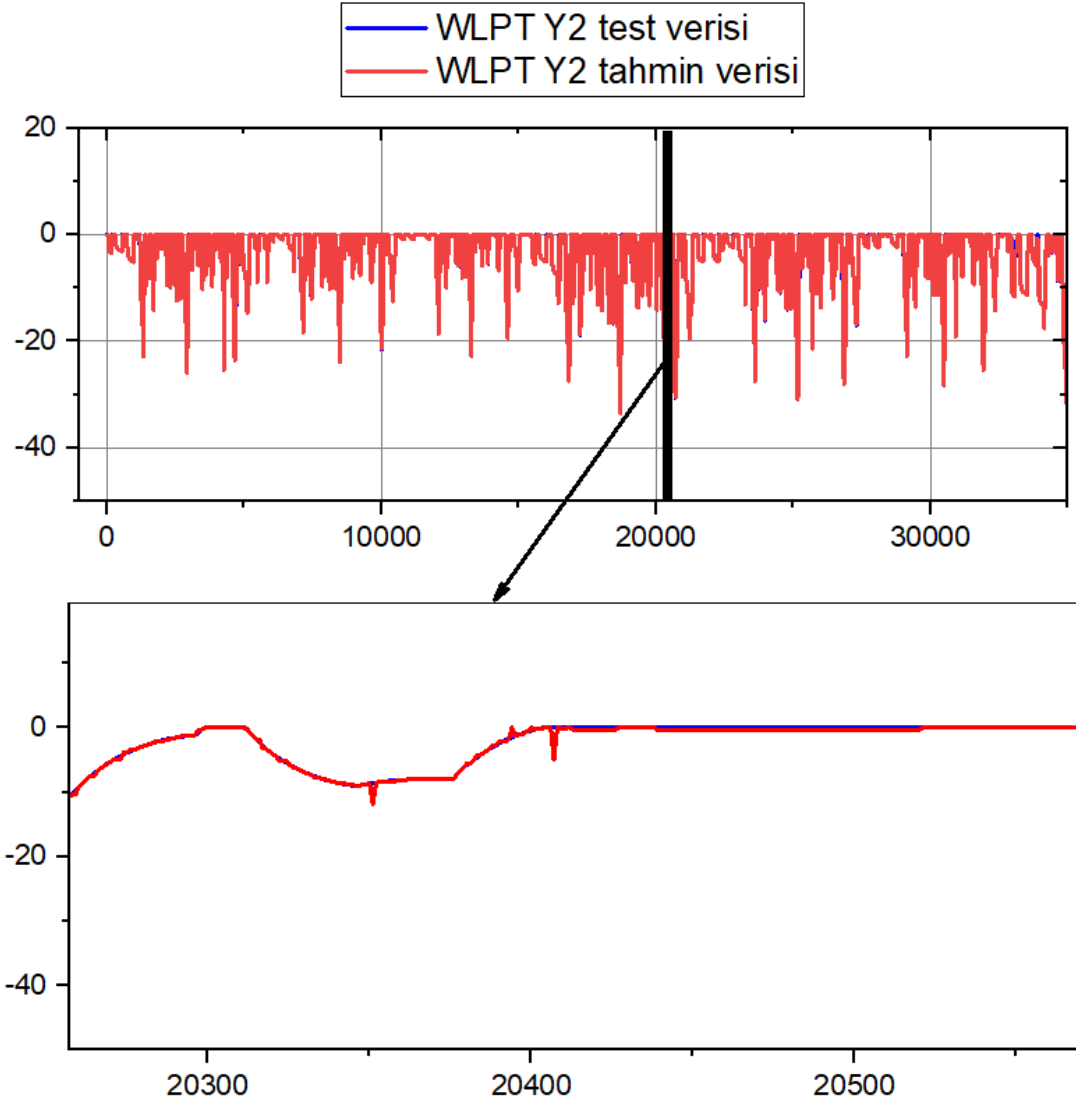


Şekil 5.26: RO algoritması ile WLTP Class 1 sürüş profilinde gerçek Y1 verisi ile tahmin edilen Y1 verisinin karşılaştırılması.

Modelimizin WLTP Class 1 ile test edilmesi sonucunda elde edilen performans metrikleri Tablo 5.8’de gösterilmiştir. Performans metrikleri incelendiğinde R^2 skoru 0.98 değeri ile yüksek bir tahmin başarımı elde edilmiştir. Diğer metrikler MSE 0.78, RMSE 0.88, MAE 0.27 düşük hata değerleri ile modelimizin başarısını kanıtlamışlardır.

Rastgele Orman algoritması ile oluşturulan modelimizin dış veri olan WLTP Class 1 sürüş profili ile çalıştırılması sonuç çıktıları Şekil 5.26 ve Şekil 5.27’de gösterilmiştir. Y1 ve Y2 verileri için yapılan tahmin sonuçları incelendiğinde çok


küçük farklılıklar ile gerçekte olması gereken veriyi modelimiz doğru bir şekilde tahmin etmiştir.



Şekil 5.27: RO algoritması ile WLTP Class 1 sürüş profilinde gerçek Y2 verisi ile tahmin edilen Y2 verisinin karşılaştırılması.

Rastgele Orman algoritması ile oluşturduğumuz modeli test sisteminde çalıştırmak için daha önceden yazmış olduğumuz Python kodu içine aktarılmıştır. Araç parametreleri ve sürüş profili HMI üzerinden girdikten sonra sistem çalıştırılmış ve Şekil 5.28, Şekil 5.29, Şekil 5.30 ve Şekil 5.31’de gösterilen sonuçlar elde edilmiştir.


Şekil 5.28’de gösterildiği üzere girilen sürüş profili referans hızını, araç hızı takip etmiş gerekli hızlanma ve yavaşlama eğrisini yakalamıştır.




Şekil 5.28: Test sisteminde WLPT Class 1 sürüş profili deneyinde referans hız ile ölçülen araç hızının karşılaştırılması.

Şekil 5.29’da öğrenen rejeneratif model tarafından tahmin edilen motor torkunu motorumuz takip etmiş ve negatif tork oluşturarak rejeneratif frenleme işlemini gerçekleştirmiştir.


Şekil 5.30’da hesaplana SoC değeri ile ölçülen güç değerleri karşılaştırılmıştır. Burada negatif güç talebinin oluştuğu rejeneratif frenleme durumunda bataryaya doğru enerji akışı ile SoC değeri artış göstermektedir. Şekil 5.31’de gösterilen batarya akım ve gerilim grafiğinde rejeneratif frenleme anında batarya akımı negatif değer almış ve batarya gerilim değeri yükselmiştir.



Şekil 5.29: Test sisteminde WLPT Class 1 sürüş profili deneyinde tahmin edilen motor torku ile ölçülen motor torkunun karşılaştırılması.



Şekil 5.30: WLPT Class 1 Sürüş profili deneyinde güç ile SoC değerinin karşılaştırılması.



Şekil 5.31: WLPT Class 1 sürüş profili deneyinde akım ile gerilim değerinin karşılaştırılması.

Bu tez çalışmasında öğrenme tabanlı rejeneratif mod kontrolü yapılmıştır. Öncelikle rejeneratif mod kontrolü yapabilen araç bileşenlerinden oluşan bir benzetim modeli Matlab/Simulink 'de oluşturulmuştur. Benzetim modelinde farklı durumla ele alınarak beş farklı durum için çalışma yapılmış ve sonuçları değerlendirilmiştir. Sonrasında EA'lar için araç bileşenlerinden oluşan EA test sistemi tasarlanmış ve sonrasında endüstriyel hale getirilerek üretimi sağlanmıştır. Test sisteminde ve benzetim modelinde yapılmış olan beş farklı deneyin uygulaması gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır. Sonuçlara bakıldığında test sistemi ile benzetim modeli çıktılarının örtüştüğü gözlemlenmiştir. Benzetim modeli üzerinden farklı durumları içeren veri seti oluşturulduktan sonra farklı algoritmalar ile model çalışması yapılmıştır. En iyi tahmin performansı sonuçlarını aldığımız algoritmamız ile farklı bir veri setinde doğrulama çalışması yapılmış ve başarılı sonuçlar elde edilmiştir.

6. SONUÇ VE ÖNERİLER

Günümüzdeki mevcut enerji krizi ve karbon salınımı EA'ların önemi günden güne artırmaktadır. EA'ların gelişimine engel olan menzıl problemi üzerine yapılan çalışmalar artmaya başlamıştır. Bu çalışmaların başında rejeneratif enerji geri kazanımı üzerine yapılan çalışmalar gelmektedir.

Bu tez çalışmasında EA'lar için rejeneratif enerji kazanımı ve denetimi çalışmaları yapılabilmesi için benzetim modeli ve test platformu oluşturulmuştur. Oluşturulan test platformu gerçek elektrik araç motoru ve bataryası barındırarak bir elektrikli aracın gerçek koşullar altında nasıl çalıştığına dair doğru bilgiler vermeye olanak sağlamıştır. Ayrıca bu test platformu her tür elektrik motorunun yükleme testlerini gerçekleştirebilecek ve sonuçlarını kayıt altına alabilecek performansa sahip bulunmaktadır. Test platformu bilgisayar üzerinden kontrol edilebilmekte ve bu sayede de her türlü programla dili ile programlanabilmektedir. Bilgisayar ile haberleşme sağlanarak ve Python programlama dili kullanarak Yapay Zeka algoritmalarının alt dalı olan Makine Öğrenmesi algoritmaları test edilmiştir.

Rejeneratif enerji denetimi araç sürücüsü yapısı, araç parametreleri, yol parametreleri, şehir trafiği gibi birçok etmene bağlıdır. Bu karmaşık yapıyı geleneksel programlama yöntemleri ile programlamak mümkün olmamaktadır. Bu nedenle öğrenen bir rejeneratif enerji denetiminin gerekliliği ortaya çıkmıştır.

Bu tez çalışmasında Yapay Zeka tabanlı bir rejeneratif enerji denetimi modeli tasarlanması ve uygulanması amaç edinilmiştir. Öncelikle hafif EA'lar için tüm genel koşulların örneklerini barındıran yapay veri seti oluşturulmuştur. Bu veri seti %70 eğitim ve %30 test verisi olacak şekilde iki parçaya ayrılmıştır. Eğitim verileri Doğrusal Regresyon, K-En Yakın Komşu, Karar Ağacı, Rastgele Orman algoritmaları ile eğitime tabi tutulmuş ve sonrasında eğitime girmemiş test verileri kullanılarak tahmin verileri alınmıştır. Test verileri ile tahmin edilen değerler alınıp algoritmaların performans değerlerini ölçmek için kullanılmıştır. Regresyon modellerinin performans ölçümlerinde sıklıkla kullanılan R^2 , MSE, RMSE, MAE değerleri hesaplanıp algoritmalar karşılaştırılmıştır. Bu algoritmaların içinde en düşük performans göstergesine Doğrusal Regresyon algoritması sahip olmuştur. Buda modelimizi eğittiğimiz verilerin doğrusal olmayışından kaynaklanmaktadır. En iyi öğrenmeyi en

dođru tahmin etme iřlemi ni gerekleřtiren, yksek performansa sahip olan Rastgele Orman algoritması olmuřtur. En yksek performansa sahip olan Rastgele Orman algoritması ile oluřturulan ğrenen rejeneratif mod modelimiz, deneysel dođrulama iřlemi ni gerekleřtirmek test platformuna yazılımı ierisine adapte edilmiřtir. Sonrasında eđitim ve test verilerimizden olmayan bařka bir veri seti oluřturulmuřtur. Bunun iin WLTP Class 1 srř profili tercih edilmiřtir. Bu srř profili dnya geneli harmonize edilmiř hafif EA'lar iin uygulanan test proseddr. Yapılan deneysel alıřmalarda, bu yeni veri seti ile 0,98 R^2 , 0,78 MSE, 0,88 RMSE, 0,27 MAE deđerleri alınarak yksek tahmin dođruluđu performansı alınmıřtır. Ayrıca hız profili takip edilmiř, frenleme anında rejeneratif enerji bataryaya aktarılmıř ve batarya SoC deđerinin ykseldiđi gzlemlenmiřtir. Bu sistem ile dnya geneli hafif tm EA'lara uygulanabilir bir model tasarımı ve uygulanması gerekleřtirilmiřtir. Bu alıřmanın lkemizde faaliyet gsteren EA retimi yapan firmalara kazandırılması sayesinde lkemize yerli rn aısından byk kazan olacaktır.

Tezin devamında ve nmze hedef olarak koyacađımız neriler ařađdaki gibi sıralanabilir.

- nerilen modele ikincil enerji kaynađı olarak ultrakapasitr eklenerek ve rejeneratif fren enerjisi aktarımı artırılabilir.
- Ayrıca enerji tketimi anında enerjinin hangi kaynak dan ekileceđi ile ilgili ğrenen bir model tasarlanıp uygulanabilir.
- Hibrit ğrenme algoritmaları ile ğrenen modelinin performansı daha da artabileceđi n grlmektedir.
- Bu alıřmanın en nemli bir sonucu olarak ortaya konulan sistem ve ynteme dayalı olarak otonom ya da src destek sistemi olarak rejeneratif etkiyi artıracak ve gvenli srř sađlayacak yarı otonom aralara uygulanabilirliđi nerilmektedir.

7. KAYNAKLAR

Acet, A., “SVM, NB, KNN, ADABOOST ve Random Forest sınıflandırma algoritmaları kullanılarak meme kanserinin tahmini”, Yüksek lisans tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya, (2022).

Barhoumi, E. M., Farhani, S., Bacha, F., “High efficiency power electronic converter for fuel cell system application”, *Ain Shams Engineering Journal*, 12 (3), 2655-2664, (2021).

Biao, J., Xiangwen, Z., Yangxiong, W., Wenchao, H., “Regenerative braking control strategy of electric vehicles based on braking stability requirements”, *International Journal of Automotive Technology*, 22, 465-473. (2021).

Carrese, S., Gemma, A., Spada, S., “Impacts of driving behaviours, slope and vehicle load factor on bus fuel consumption and emissions: a real case study in the city of Rome”, *Procedia - Social and Behavioral Science*. 87, 211-221, (2013).

Chan, C. C., “The state of the art of electric, hybrid, and fuel cell vehicles”, *Proceedings of the IEEE*. 95 (4), 704-718, (2007).

Chang, W.Y., “The state of charge estimating methods for battery: a review”, *ISRN Applied Mathematics*, 2013, 1-7, (2013).

Chau K. T., Li, W., “Overview of electric machines for electric and hybrid vehicles”, *International Journal of Vehicle Design*, 64 (1), 46-71, (2014).

Chen, C. H., Chi, W. C., Cheng, M. Y., “Regenerative braking control for light electric vehicles”, *IEEE Ninth International Conference on Power Electronics and Drive Systems*, 631-636, (2011).

Chung, S. U., Moon, S. H., Kim, D. J., Kim, J.M., “Development of a 20-pole-24-slot SPMSM with consequent pole rotor for in-wheel direct drive”, *IEEE Transactions on Industrial Electronics*, 63 (1), 302-309, (2016).

Ciceo, S., Mollet, Y., Sarrazin, M., van der Auweraer, H., Marţiş, C., “Model-based design and testing for the energy consumption analysis of the electric vehicles”, *EEA - Electrotehnica, Electronica, Automatica*. 64 (4), 46-51, (2016).

Crolla, D. A., and Cao, D., “The impact of hybrid and electric powertrains on vehicle dynamics, control systems and energy regeneration”, *Vehicle System*

Dynamics, 50, 95-109, (2012). <https://doi.org/10.1080/00423114.2012.676651>

Demircali, A. and Koroglu, S., “Jaya algorithm-based energy management system for battery- and ultracapacitor-powered ultralight electric vehicle”, *International Journal of Energy Research*, 44 (6), 4977-4985, (2020).

Ehsani, M., Gao, Y., Longo, S., and Ebrahimi, K. M., *Modern electric, hybrid electric, and fuel cell vehicles*, CRC press, (2018).

Gao, D. W., Mi C., Emadi, A., “Modeling and simulation of electric and hybrid vehicles”, *Proceedings of the IEEE*, 95 (4), 729-745, (2007).

Godfrey, A. J., and Sankaranarayanan, V., “A new electric braking system with energy regeneration for a BLDC motor driven electric vehicle”, *Engineering Science and Technology, an International Journal*, 21 (4), 704-713, (2018).

Gundabattini, E., Kuppan, R., Solomon, D. G., Kalam, A., Kothari, D. P., Abu Bakar, R., “A review on methods of finding losses and cooling methods to increase efficiency of electric machines”, *Ain Shams Engineering Journal*, 12 (1), 497-505, (2021).

He, H., Xiong, R., Zhao, K., Liu, Z., “Energy management strategy research on a hybrid power system by hardware-in-loop experiments”, *Applied Energy*, 112, 1311-1317, (2013).

He, H., Wang, C., Jia, H., Cui, X., “An intelligent braking system composed single-pedal and multi-objective optimization neural network braking control strategies for electric vehicle”, *Applied Energy*, 259, 114172, (2020).

Huda, N., Kaleg, S., Hapid, A., Kurnia, M. R., Budiman, A. C., “The influence of the regenerative braking on the overall energy consumption of a converted electric vehicle”, *SN Applied Sciences*, 2 (4), 1-8, (2020).

Husain, I., Islam, M. S., “Design, modeling and simulation of an electric vehicle system”, *SAE Technical Papers*, (1999). <https://doi.org/10.4271/1999-01-1149>

Husain, I., *Electric and Hybrid Vehicles Design Fundamentals*, CRC Press, (2005).

IEA, *World Energy Outlook 2020 – Analysis*, (2020).

Kartal, E., “Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama”, Doktora tezi,

İstanbul Üniversitesi Fen Bilimleri Enstitüsü, (2015).

Kesler, S., Boyacı, Ö. and Tümbek, M., “Elektrikli araçlarda enerji yönetimi ve verimliliğinin analiz edilmesi için bir test sistemi tasarımı”, *IV. International Ankara Conference on Scientific Research*, 67-70, (2021).

Kim, M. K., Jang, K. Y., Choo, B. H., Lee, J. B., Suh, B. S., Kim, T. H., “A novel IGBT inverter module for low-power drive applications”, *IEEE Annual Power Electronics Specialists Conference*, 2, 642-647, (2002)

Kotsiantis, S. B., “Supervised machine learning: A review of classification techniques”, *Informatica*, 31 (3), 249–268, (2007).

Li, Z., Khajepour, A., Song J., “A comprehensive review of the key technologies for pure electric vehicles”, *Energy*, 182, 824-839, (2019).

Li, X., Zhang, X., Wang, Y. “Regenerative braking control strategies with fixed ratio and variable ratio braking forces optimization distribution for electric vehicles during downhill process”, *International Journal of Automotive Technology*, 23 (3), 667-681. (2022).

Liu, W., Qi, H., Liu, X., Wang, Y., “Evaluation of regenerative braking based on single-pedal control for electric vehicles”, *Frontiers of Mechanical Engineering*, 15 (1), 166-179, (2020).

Massaron, L., Boschetti, A., *Regression analysis with Python*. Packt Publishing Ltd., (2016).

Maybury, L., Corcoran, P., Cipcigan, L. “Mathematical modelling of electric vehicle adoption: A systematic literature review”, *Transportation Research Part D: Transport and Environment*, 107, 103278, (2022).

Mediouni, H., Ezzouhri, A., Charouh, Z., El Harouri, K., El Hani, S., Ghogho, M., “Energy Consumption Prediction and Analysis for Electric Vehicles: A Hybrid Approach”, *Energies*, 15(17), 6490, (2022).

Mohammed, O. A., Abed N. Y., “Real-time simulation of electric machine drives with hardware-in-the-loop”, *The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 27, 929-938, (2008).

Mruzek M., Gajdác I., Kučera L., Gajdošík T., “The possibilities of increasing the electric vehicle range”, *Procedia Engineering*, 192, 621–625, (2017).

Nibert, J., Herniter, M. E., Chambers, Z., “Model-based system design for MIL, SIL, and HIL”, *EVS26 International Battery, Hybrid and Fuel Cell Electric Vehicle Symposium*, 2123-2132, (2012).

Oh, S.C., “Evaluation of motor characteristics for hybrid electric vehicles using the hardware-in-the-loop concept”, *IEEE Transactions on Vehicular Technology*, 54 (3), 817-824, (2005).

Park, G., Lee, S., Jin, S., Kwak, S. “Integrated modeling and analysis of dynamics for electric vehicle powertrains”, *Expert Systems with Applications*, 41 (5), 2595-2607. (2014).

Qi, L., Wu, X., Zeng, X., Feng, Y., Pan, H., Zhang, Z., Yuan, Y., “An electro-mechanical braking energy recovery system based on coil springs for energy saving applications in electric vehicles”, *Energy*, 117472, (2020).

Rosero, F., Fonseca, N., López, J. M., Casanova, J., “Effects of passenger load, road grade, and congestion level on real-world fuel consumption and emissions from compressed natural gas and diesel urban buses”, *Applied Energy*, 282 (B), 116195, (2021).

Sangtarash, F., Esfahanian, V., Nehzati, H., Haddadi, S., Bavanpour, M. A., Haghpanah, B., “Effect of different regenerative braking strategies on braking performance and fuel economy in a hybrid electric bus employing CRUISE vehicle simulation”, *SAE International Journal of Fuels and Lubricants*, 1 (1), 828-837, (2009).

Shang, Y., Ma, C., Yang, K., Tan, D., “Regenerative braking control strategy based on multi-source information fusion under environment perception”, *International Journal of Automotive Technology*, 23 (3), 805-815, (2022).

Sharma, A., Nusrat, R., Bhuiya, M. A., Youssef, M. Z., “Hardware-in-the-loop validation of different power train topologies’ models in electric vehicles: a plug-and-play capability”, *IEEE Open Journal of Vehicular Technology*, 2, 365-376 (2021).

Smith, J., Hinterberger, M., Schneider, C., Koehler, J., “Energy savings and increased electric vehicle range through improved battery thermal management”, *Applied Thermal Engineering*, 101, 647–656, (2016).

Song, C., Xiao, F., Peng, S., “Implementation of electric vehicle hardware-in-the-loop test platform”, *International Journal of Multimedia and Ubiquitous Engineering*, 10 (11), 147-158, (2016).

Subramaniyam, K. V., and Subramanian, S. C., “Electrified vehicle wheel slip control using responsiveness of regenerative braking”, *IEEE Transactions on Vehicular Technology*, 70 (4), 3208-3217, (2021).

Sung Chul, O., “Evaluation of motor characteristics for hybrid electric vehicles using the hardware-in-the-loop concept”, *IEEE Transactions on Vehicular Technology*, 54 (3), 817-824, (2005).

Şen, E., “Elektrikli araçların enerji talep tahmini”, Yüksek lisans tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri, (2022).

Tanaka, Y., Nakaoka, H., Mizutani, Y., Nakamura, E., “U.S. Patent No. 8,733,849. Washington”, DC: U.S. Patent and Trademark Office, (2014).

Tie, S.F., Tan, C.W., “A review of energy sources and energy management system in electric vehicles”, *Renewable and Sustainable Energy Reviews*, 20, 82-102, (2013).

Tümbek, M., “Elektrikli Araçlar İçin Dış Rotorlu Doğrudan Yol Vermeli Senkron Motor Tasarımı, Analizi Ve Sürülmesi”, Doktora tezi, *Pamukkale Üniversitesi Fen bilimleri Enstitüsü*, Denizli, (2019).

United States Environmental Protection Agency, "Dynamometer Drive Schedules [online]", (18 February 2022), <https://www.epa.gov/vehicle-and-fuel-emissions-testing/dynamometer-drive-schedules>, (2020).

West, J. G. W., “DC, induction, reluctance and PM motors for electric vehicles”, *Power Engineering Journal*, 8 (2), 77-88, (1994).

Wu, J., Liang, J., Ruan, J., “Efficiency comparison of electric vehicles powertrains with dual motor and single motor input”, *Mechanism and Machine Theory*, 128, 569-585, (2018).

Xu, W., Chen, H., Zhao, H., Ren, B., “Torque optimization control for electric vehicles with four in-wheel motors equipped with regenerative braking system”, *Mechatronics*, 57, 95-108, (2019).

Xue, X. D., Cheng, K. W. E., Cheung N. C., “Selection of electric motor drives for electric vehicles”, *Australasian Universities Power Engineering Conference*, 1-6, (2008).

Yang, Y., He, Q., Chen, Y., & Fu, C., “Efficiency optimization and control strategy of regenerative braking system with dual motor”, *Energies*, 13 (3), 711, (2020).

Zhang, J. M., Du, W. N., Wang, X. H., “Development of parallel regenerative braking controller”, *Advanced Materials Research*, 219, 1161-1164, (2011).

Zhang, L., and Cai, X., “Control strategy of regenerative braking system in electric vehicles”, *Energy Procedia*, 152, 496-501, (2018).

Zhang, Z., Wang, D., Zhang, C., Chen, J., “Electric vehicle range extension strategies based on improved AC system in cold climate-a review”, *International Journal of Refrigeration*, 88, 141-150, (2018).

Zhu, Z. Q., Howe, D., “Electrical machines and drives for electric, hybrid, and fuel cell vehicles”, *Proceedings of the IEEE*, 95, 746-765, (2007).

Zhu, Y., Hu, H., Xu, G., Zhao, Z., “Hardware-in-the-loop simulation of pure electric vehicle control system”, *International Asia Conference on Informatics in Control, Automation, and Robotics*, 254-258, (2009).