T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİKLİ ARAÇLARDA REJENERATİF FRENLEME İÇİN DERİN ÖĞRENME ALGORİTMASI GELİŞTİRİLMESİ

Ömer ERGÜN

YÜKSEK LİSANS TEZİ
Makine Mühendisliği Anabilim Dalı
Konstrüksiyon Programı

Danışman
Doç. Dr. İlyas İSTİF

Eş Danışman
Doç. Dr. Erkin DİNÇMEN

Haziran, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİKLİ ARAÇLARDA REJENERATİF FRENLEME İÇİN DERİN ÖĞRENME ALGORİTMASI GELİŞTİRİLMESİ

Ömer ERGÜN tarafından hazırlanan tez çalışması 24.06.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı Konstrüksiyon Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. İlyas İSTİF
Yıldız Teknik Üniversitesi
Danışman

Doç. Dr. Erkin DİNÇMEN
Işık Üniversitesi
Eş Danışman

Jüri Üyeleri

Doç. Dr. İlyas İSTİF, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Tarkan SANDALCI, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Olcay TÜRKOĞLU, Üye
Işık Üniversitesi _____

Danışmanım Doç. Dr. İlyas İSTİF sorumluluğunda tarafımca hazırlanan ELEKTRİKLİ ARAÇLARDA REJENERATİF FRENLEME İÇİN DERİN ÖĞRENME ALGORİTMASI GELİŞTİRİLMESİ başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Ömer ERGÜN

İmza

Bu çalışma, “Türkiye Bilimsel ve Teknik Araştırma Kurumu (TÜBİTAK) Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı’nın 122M994” numaralı projesi ile desteklenmiştir.

Aileme ithâfen

TEŞEKKÜR

Bu çalışmayı hazırlarken bana destek olan tüm kişi ve kurumlara en içten teşekkürlerimi sunmak isterim.

Öncelikle, tez sürecimde bana yol gösteren, bilgi ve deneyimleriyle çalışmama değer katan danışmanlarım Sayın Doç. Dr. İlyas İSTİF ve Doç. Dr. Erkin DİNÇMEN'e en içten teşekkürlerimi sunarım. Yönlendirmeleri ve tavsiyeleriyle çalışmam boyunca bana rehberlik ettikleri için kendilerine minnettarım.

Ayrıca, yüksek lisans eğitimim boyunca bana destek ve cesaret veren, çalışma sürecimde bana moral ve motivasyon sağlayan ve her zaman yanımda olan sevgili aileme teşekkür ederim.

Çalışmamda bana veri sağlayan ve işbirliği yapan TÜBİTAK'a da katkılarından dolayı teşekkür ederim. Çalışmalarımda bana zaman ayıran ve yardımcı olan tüm arkadaşlarıma ve çalışma arkadaşlarıma da teşekkürlerimi iletmek isterim.

Son olarak, bu süreçte bana manevi olarak destek olan tüm dostlarıma da en içten teşekkürlerimi sunuyorum.

Ömer ERGÜN

İÇİNDEKİLER

SİMGE LİSTESİ **ix**

KISALTMA LİSTESİ **xii**

ŞEKİL LİSTESİ **xiv**

TABLO LİSTESİ **xvi**

ÖZET **xvii**

ABSTRACT **xix**

1 GİRİŞ **1**

1.1 Literatür Çalışması 2

1.1.1 Sonuç ve Literatürdeki Boşluklar 6

1.2 Tezin Amacı 7

1.3 Tezin Metodolojisi 7

2 ELEKTRİKLİ ARAÇ MODELİ VE ELEKTRO-HİDROLİK FRENLEME YAPISI **9**

2.1 Matlab Virtual Vehicle Composer 10

2.1.1 Araç Hareket Denklemi 11

2.2 Tekerlek Modeli 13

2.3 Sürücü Modeli 13

2.4 Hidrolik Frenleme Modeli 15

2.5 Motor Modeli 16

2.6 Batarya Modeli 17

3 OPTİMİZASYON ALGORİTMASI **20**

3.1 UN / ECE Regülasyonları 20

3.2 Araç Yük Dağılımı 22

3.3 Dinamik Programlama 23

4 YSA VE KARAR AĞACI TABANLI HİBRİT KONTROL SİSTEMİ TASARIMI **32**
4.1 Veri Hazırlama ve Ön İşleme 32
4.2 Hibrit Sistem Yaklaşımı ve Mimarisi 34
4.3 Hiperparametre Optimizasyonu Süreci 35
4.3.1 Optimizasyon Yaklaşımı ve Parametre Aralıkları 36
4.3.2 Optimize Edilmiş Hiperparametreler 38
4.4 Hibrit Modelin Yapısal Detayları 39
4.4.1 YSA Bileşeni: Mimari ve Aktivasyon Fonksiyonları 39
4.4.2 Karar Ağacı Bileşeni: Yapı ve Parametreler 41
4.4.3 Eğitim Parametreleri ve Algoritmaları 41
4.5 Performans Değerlendirmesi ve Sonuçlar 43
4.5.1 Dahili Test Performansı 43
4.5.2 Bağımsız Test Senaryoları Üzerindeki Performans 43

5 HİBRİT KONTROL MODELİNİN SİMULASYON TABANLI PERFORMANS ANALİZİ VE KARŞILAŞTIRILMASI **47**
5.1 Simülasyon Ortamı ve Model Entegrasyonu 48
5.1.1 Hibrit Modelin Entegrasyonu 48
5.1.2 Referans Kontrol Stratejilerinin Uygulanması 49
5.2 Simülasyon Sonuçları ve Karşılaştırmalı Analiz 50
5.2.1 Senaryo 1: Eğitim Koşullarında UDDS Çevrimi Performansı 50
5.2.2 Senaryo 2: Farklı Araç Ağırlığı ile NYCC Çevrimi Performansı 51
5.2.3 Senaryo 3: Eğitim Aralığında Farklı Parametrelerle NYCC Çevrimi (İnterpolasyon Testi) 53
5.2.4 Senaryo 4: Eğitim Sınırları Dışında WLTP Class 3 Çevrimi (Ekstrapolasyon Testi) 54

6 BULGULAR VE DEĞERLERNDİRME **56**
6.1 Temel Bulguların Özeti 56
6.2 Bulguların Değerlendirilmesi ve Tartışma 57
6.2.1 Hibrit Modelin Performansının Mekanizması ve Sağlamlığı 57
6.2.2 Referans Yöntemlerle Karşılaştırmalı Değerlendirme 58
6.2.3 Literatürdeki Çalışmalarla Karşılaştırma 59
6.2.4 Çalışmanın Özgün Katkıları 60
6.3 Gelecek Çalışma Önerileri 61

7 SONUÇ **62**

KAYNAKÇA **64**

EK-A **67**

.1 Lastik Modeli Denklemleri 67

TEZDEN ÜRETİLMİŞ YAYINLAR **69**

SİMGE LİSTESİ

k	Adezyon katsayısı
h_{cg}	Ağırlık merkezi yüksekliği
v	Anlık araç hızı
$\mathbf{I}$	Araç gövdesinin atalet momentleri
x	Araç durum vektörü
m	Aracın toplam kütlesi / Gövde kütlesi
m_r, m_v	Arka aks yükü, aracın toplam kütlesi
SOC_0	Başlangıç şarj durumu
ΔE	Batarya enerjisindeki artış miktarı
P_{bat}	Batarya gücü
$P_{Kayßp}$	Batarya güç kaybı
C_{bat}	Batarya kapasitesi
V_T	Batarya terminal voltajı
P_{Depo}	Bataryada depolanan güç
I_{bat}	Bataryadan geçen akım
E_m	Bataryanın açık devre gerilimi
R_i	Bataryanın iç direnci
$\mathcal{T}$	Bir diskte oluşan fren torku (Nm)
R^2	Determinasyon katsayısı
z_t	Eğimli yoldaki frenleme oranı
ω	Elektrik motorunun açısal hızı (rad/s)
P_{EM}	Elektrik motorunun gücü (W)
T_m	Elektrik motoru rejeneratif fren torku

$\mathcal{T}_{EM}$	Elektrik motorunun torku (Nm)
η	Elektrik motorunun verimi
Φ, θ, ψ	Euler açıları (Roll, Pitch, Yaw)
J	Euler dönüşüm matrisi
μ_s, μ	Balata-disk arası statik ve kinetik sürtünme katsayısı
B_a	Fren silindiri çapı
R_d, R_i	Fren diski dış ve iç yarıçapı
z	Frenleme oranı / Normalize edilmiş araç ivmesi
T_{son}	Frenleme senaryosunun son anı
X_{min}, X_{max}	Giriş değişkeninin minimum ve maksimum değeri
$\mathbf{F}_b$	Gövdeye sabit koordinat sistemindeki net kuvvet vektörü
$\mathbf{M}_b$	Gövdeye sabit koordinat sistemindeki net moment vektörü
$\mathbf{V}_b$	Gövdeye sabit koordinat sistemindeki hız vektörü
p, q, r	Gövdeye sabitlenmiş açısal hız vektörü bileşenleri
$\hat{y}_{\text{EMa}}, \hat{y}_{\text{EMö}}$	Hibrit modelin nihai EMa ve EMö tork tahminleri
T_{hr}	Hidrolik fren torku
A1-A7	Karakteristik değişkenler (Yol eğimi, sürtünme, yük dağılımı vb.)
$\hat{y}_{\text{tree,EMa}}$	Karar Ağacının EMa tork tahmini
$\hat{y}_{\text{tree,EMö}}$	Karar Ağacının EMö tork tahmini
λ	L2 düzenlileştirme katsayısı
$J_{son-\Delta t}$	Optimum durum geçişi için batarya enerjisindeki artış miktarı
X, X_{norm}	Orijinal ve normalize edilmiş giriş değişkeni
R_o	Ortalama fren diski yarıçapı
α	Öğrenme oranı (YSA) / Yol eğimi açısı
$\mathcal{T}_{\text{EMö}}$	Ön aks elektrik motoru torku
γ	Ön aks fren torkunun toplam fren torkuna oranı
l_f, l_r	Ön ve arka aks ile ağırlık merkezi arasındaki mesafe
$F_{z,f}, F_{z,r}$	Ön ve arka aksa etki eden normal kuvvet
$F_{x,f}, F_{x,r}$	Ön ve arka aksa uygulanan frenleme kuvveti

k_f, k_r	Ön ve arka akstaki teorik adezyon katsayısı
N_p, N_s	Paralel ve seri hücre sayısı
a_r, c_r, b_r	Statik, doğrusal ve aerodinamik yuvarlanma dirençleri
μ	Sürtünme katsayısı / Yolun adezyon katsayısı
K_{pt}	Sürücü modelinde çekiş kuvveti sabiti
$\mathcal{T}_{\text{fren}}^{\text{toplam}}$	Talep edilen toplam fren torku
N_{balata}	Tekerlek başına balata sayısı
r	Tekerlek yarıçapı
N	Tekerlek hızı
L	Toplam aks mesafesi
i_t	Transmisyon oranı
P	Uygulanan fren basıncı (Pa)
K	Uygulanan normalize edilmiş basınca karşılık gelen basınç faktörü
y_{dec}	Yavaşlama komutu
g	Yerçekimi ivmesi sabiti
F_r	Yuvarlanma direnci
W_{nn}, W_{tree}	YSA ve Karar Ağacı ağırlıkları
$\hat{y}_{\text{nn,EMa}}$	YSA'nın EMa tork tahmini
$\hat{y}_{\text{nn,EMö}}$	YSA'nın EMö tork tahmini
Δt	Zaman adımı

KISALTMA LİSTESİ

ABC	Yapay Arı Kolonisi
DM-EV	Çift Motorlu Elektrikli Araç
DOF	Serbestlik Derecesi (Degrees of Freedom)
DP	Dinamik Programlama
EA	Elektrikli Araç
ECE	Ekonomik Avrupa Komisyonu
EM	Elektrik Motoru
EMa	Arka Aks Elektrik Motoru
EMö	Ön Aks Elektrik Motoru
EMS	Enerji Yönetim Sistemi
ESS	Enerji Depolama Sistemi
EV	Elektrikli Araç (Electric Vehicle)
HFa	Arka Hidrolik Fren
HFö	Ön Hidrolik Fren
IDA	Bağımsız Tahrikli Aks
KA	Karar Ağacı (Decision Tree)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MFT	Motor Arıza Toleransı (Motor Fault Tolerance)
MPC	Model Öngörülü Kontrol
MSE	Ortalama Karesel Hata (Mean Squared Error)
NEDC	Yeni Avrupa Sürüş Döngüsü (New European Driving Cycle)
NSGA-II	Baskın Olmayan Sıralamalı Genetik Algoritma II
NYCC	New York Şehir Döngüsü (New York City Cycle)

OB	Optimizasyon Tabanlı
PINN	Fizik Bilgili Yapay Sinir Ağı (Physics-Informed Neural Network)
RB	Kural Tabanlı
RBS	Rejeneratif Frenleme Sistemi
ReLU	Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
RMSE	Kök Ortalama Karesel Hata (Root Mean Square Error)
SOC	Bataryanın Şarj Durumu (State of Charge)
TPO	Tork Paylaştırma Oranı
UDDS	Kentsel Dinamometre Sürüş Programı (Urban Dynamometer Driving Schedule)
UN/ECE	Birleşmiş Milletler Avrupa Ekonomik Komisyonu
VCU	Araç Kontrol Ünitesi
VVC	Sanal Araç Oluşturucu (Virtual Vehicle Composer)
WLTP	Dünya Çapında Uyumlaştırılmış Hafif Araçlar Test Prosedürü
YSA	Yapay Sinir Ağı

ŞEKİL LİSTESİ

Şekil 2.1 Elektro-Hidrolik Frenleme Yapısı 9
Şekil 2.2 14 serbestlik derecesine sahip araç modeli 10
Şekil 2.3 Araç Dinamiği Şeması 11
Şekil 2.4 Disk frenlemenin yapısı 15
Şekil 2.5 Motor verim haritası 17
Şekil 2.6 Batarya karakteristikleri: (a) Açık devre gerilimi, (b) İç direnç. . . 18
Şekil 3.1 Ön aks elektrik motoru tork uzayı 23
Şekil 3.2 $T_{son} - \Delta t$ anındaki en yüksek seviye torktan durum geçişleri . . . 25
Şekil 3.3 Batarya gücünün P_1'den P_2'ye Δt zamanındaki değişimi 26
Şekil 3.4 $T_{son} - \Delta t$ anındaki en üst seviye torkun bir altındaki aşamadan durum geçişleri 27
Şekil 3.5 $T_{son} - 2\Delta t$ anındaki en yüksek seviye torktan durum geçişleri . . 28
Şekil 3.6 $T_{son} - 2\Delta t$ anındaki en üst seviye torkun bir altındaki aşamadan durum geçişleri 29
Şekil 3.7 Algoritmanın akış şeması 30
Şekil 3.8 Ön aks elektrik motoru için şematik optimum tork geçişleri 31
Şekil 4.1 EPA Kentsel Dinamometre Sürüş Çevrimi (UDDS) hız profili. . . 33
Şekil 4.2 Önerilen hibrit Yapay Sinir Ağı - Karar Ağacı model mimarisi. . . 35
Şekil 4.3 Bayesian optimizasyon sürecinin ilerleyişi: Her denemedeki validasyon hatası (Ort. RMSE) ve o ana kadar bulunan en iyi hata değeri. 37
Şekil 4.4 Seçili hiperparametrelerin validasyon hatası (Ort. RMSE) üzerindeki etkileri. 38
Şekil 4.5 Optimize edilmiş YSA modelinin mimarisi. 40
Şekil 4.6 Karar ağacı modelinin genel yapısı (EMö ve EMa için ayrı ağaçlar). 42
Şekil 4.7 Bağımsız test senaryolarında hata metrikleri (RMSE, MAE) ve determinasyon katsayısı (R^2) değerlerinin karşılaştırmalı gösterimi. 45
Şekil 4.8 Bağımsız test senaryoları: DP referans (Gerçek) ve hibrit model tahminleri (Tahmin edilen) EMö ve EMa tork değerlerinin zaman içindeki değişimi. 46
Şekil 5.1 Hibrit kontrol modelinin araç simülasyon modeline entegrasyon yapısı. 48

Şekil 5.2 Hibrit modelin sadece frenleme durumlarında aktive edilmesi için kullanılan etkinleştirilmiş alt sistem mantığı. 49
Şekil 5.3 Senaryo 1 (UDDS, Eğitim Koşulları): kontrol stratejilerinin SOC karşılaştırması 51
Şekil 5.4 Senaryo 2 (NYCC, Farklı Ağırlık): Kontrol stratejilerinin SOC karşılaştırması. 52
Şekil 5.5 Senaryo 3 (NYCC, İnterpolasyon): Kontrol stratejilerinin SOC karşılaştırması. 54
Şekil 5.6 Senaryo 4 (WLTP, Ekstrapolasyon): Kontrol stratejilerinin SOC karşılaştırması. 55

TABLO LİSTESİ

Tablo 3.1 Araç parametreleri 23
Tablo 4.1 Hibrit model geliştirme sürecinde kullanılan senaryo koşulları. . 33
Tablo 4.2 Bayesian optimizasyonu ile belirlenen optimum hiperparametre değerleri. 39
Tablo 4.3 Hibrit modelin dahili test seti üzerindeki performans metrikleri. . 43
Tablo 4.4 Bağımsız test senaryolarına ait hibrit modelin performans metrikleri. 44
Tablo 5.1 Senaryo 1 (UDDS, Eğitim Koşulları) sonunda elde edilen SOC sonuçları. 50
Tablo 5.2 Senaryo 2 (NYCC, Farklı Ağırlık) sonunda elde edilen SOC sonuçları. 52
Tablo 5.3 Senaryo 3 (NYCC, İnterpolasyon) sonunda elde edilen SOC sonuçları. 53
Tablo 5.4 Senaryo 4 (WLTP, Ekstrapolasyon) sonunda elde edilen SOC sonuçları. 55

ÖZET

ELEKTRİKLİ ARAÇLARDA REJENERATİF FRENLEME İÇİN DERİN ÖĞRENME ALGORİTMASI GELİŞTİRİLMESİ

Ömer ERGÜN

Makine Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Doç. Dr. İlyas İSTİF
Eş Danışman: Doç. Dr. Erkin DİNÇMEN

Bu çalışma, çift motorlu (ön ve arka aksta bağımsız tahrikli) elektrikli araçlarda rejeneratif frenleme verimliliğini artırmak amacıyla hibrit bir kontrol stratejisi sunmaktadır. Geleneksel sabit oranlı tork paylaşımına ve Simulink araç modelinde bulunan mevcut kural tabanlı kontrole kıyasla, bu dinamik yaklaşım geri kazanılan enerjiyi en üst düzeye çıkarmayı hedefler. Öncelikle, Dinamik Programlama (DP) yöntemiyle, yedi farklı karakteristik değişkeni (yol eğimi, sürtünme katsayısı, araç yük dağılımı, hız, ivme/frenleme oranı, batarya şarj durumu ve toplam fren torku) dikkate alan çeşitli senaryolar için UN/ECE frenleme regülasyonlarıyla uyumlu optimal rejeneratif fren torku dağılımları belirlenmiştir. Bu optimal veriler, Yapay Sinir Ağı (YSA) ve Karar Ağacı (KA) tabanlı hibrit bir kontrol modelinin eğitimi için kullanılmış olup; model, anlık koşullara göre ön ve arka akslardaki rejeneratif fren torklarını belirler. Ayrıntılı (14 serbestlik dereceli) bir Simulink araç modeline entegre edilen sistemin performansı, farklı sürüş çevrimleri (UDDS, NYCC, WLTP) ve araç/çevre parametrelerini içeren eğitim, interpolasyon ve ekstrapolasyon test senaryolarında değerlendirilmiştir. Simülasyon sonuçları, geliştirilen hibrit modelin, referans yöntemlere kıyasla batarya şarj durumunu (SOC) korumada %1.26 ila %5.06 arasında değişen iyileşmeler sağladığını göstermiştir. Bu, sunulan kontrol sisteminin farklı ve zorlu koşullar altında dahi optimal tork dağılımı kararları alarak enerji verimliliğini artırma potansiyelini ortaya koymaktadır.

Anahtar Kelimeler: Elektrikli araçlar, rejeneratif frenleme, dinamik programlama, yapay sinir ağı–karar ağacı hibrit kontrol.

ABSTRACT

DEVELOPMENT OF DEEP LEARNING ALGORITHM FOR REGENERATIVE BRAKING IN ELECTRIC VEHICLES

Ömer ERGÜN

Department of Mechanical Engineering
Master of Science Thesis

Supervisor: Assoc. Prof. Dr. İlyas İSTİF
Co-supervisor: Assoc. Prof. Dr. Erkin DİNÇMEN

This study presents a hybrid control strategy to enhance regenerative braking efficiency in dual-motor (front and rear independently driven axles) electric vehicles. Compared to conventional fixed-ratio torque distribution and a Simulink default controller, this dynamic approach aims to maximize regenerated energy. Initially, optimal regenerative braking torque distributions, compliant with UN/ECE braking regulations, were determined using Dynamic Programming (DP) for various scenarios, considering seven characteristic variables (road grade, friction coefficient, vehicle load distribution, velocity, acceleration/braking rate, battery state of charge, and total braking torque). These optimal data were used to train a hybrid control model based on Deep Neural Networks (DNN) and Decision Trees (DT); the model determines the regenerative braking torques for the front and rear axles based on instantaneous conditions. The performance of the system, integrated into a detailed (14 degrees of freedom - DOF) Simulink vehicle model, was evaluated under training, interpolation, and extrapolation test scenarios involving different driving cycles (UDDS, NYCC, WLTP) and vehicle/environmental parameters. Simulation results demonstrated that the developed hybrid model, compared to reference methods, achieved improvements in preserving battery State of Charge (SOC) ranging from 1.26% to 5.06%. This highlights the potential of the proposed control system to enhance energy efficiency by making optimal torque distribution decisions, even under varied and challenging

conditions.

Keywords: Electric vehicles, regenerative braking, dynamic programming, artificial neural network–decision tree hybrid control.

1
GİRİŞ

Son zamanlarda çevre kirliliği ve küresel ısınmaya yönelik artan endişeler, içten yanmalı motorlu araçların egzoz emisyonlarına bağlı olarak giderek büyümüş ve elektrikli araçlara (EV) olan ilgiyi artırmıştır. Elektrikli araçlar, çevre dostu olmaları ve yenilenebilir enerji kaynaklarıyla çalışabilmeleri nedeniyle sürdürülebilir bir ulaşım çözümü sunmaktadır. Ancak mevcut elektrikli araçlar, yetersiz şarj altyapısı, geleneksel içten yanmalı motorlu araçlara nisbeten fiyat dezavantajı, uzun şarj süreleri gibi zorluklarla karşı karşıyadır. Bununla birlikte, batarya teknolojilerindeki gelişmelere rağmen mevcut elektrikli araçlar, hâlâ geleneksel içten yanmalı motorlu araçlarla aynı düzeyde menzil sağlayamamakta ve özellikle soğuk havalarda, bataryanın şarj depolama kapasitesinin azalmasıyla birlikte uzun soluklu yolculuklara çıkılmasını daha da zor hale getirmektedir [1, 2]. Bu durum, enerji verimliliğini artırmaya yönelik yenilikçi yaklaşımları gerekli kılmaktadır.

Araç bileşenlerinin fiziksel ve operasyonel kısıtlamaları dahilinde, sürücünün güç isteklerinin mümkün olduğunca verimli bir şekilde ele alınmasından sorumlu olan eneryi yönetim sistemleri (EMS) bu verimliliği arttırmak için bir numaralı odak noktası olmuştur. EMS, sürücünün tahrik taleplerini yönetmenin yanında frenleme isteklerini de yönetmektedir. Güvenlik yönüne ek olarak, elektrikli araçların yavaşlamasını yönetmek, enerji verimliliğini optimize etmek için önemlidir. Şehir içi veya hibrit sürüş çevrimleri düşünüldüğünde, frenleme sırasındaki enerji kaybı %39'lara kadar çıkarken, trafiğin yoğun olduğu şehirlerde, işe gidiş geliş sırasında bu oran rahatlıkla %50'nin üzerine çıkabilmektedir [3]. Her ne kadar bu enerjinin tamamını geri kazanmak mümkün olmasa da, bu durum rejeneratif frenleme sisteminin (RBS) sürüş menzilini uzatmada önemli bir potansiyele sahip olduğunu göstermektedir. Yapılan çalışmalar, RBS ile donatılmış bir aracın şarj başına daha uzun sürüş menzili, aynı sürüş menzili için daha düşük yakıt maliyeti, batarya fiyatı ve bakım maliyeti sağlayabileceğini göstermektedir [3]. Rejeneratif frenleme, frenleme sırasında oluşan kinetik enerjiyi elektrik enerjisine dönüştürerek aracın bataryasında depolamayı mümkün kılar. Bu enerji

geri kazanımı, araçların toplam enerji verimliliğini artırırken, şarj ihtiyacını azaltarak kullanıcı deneyimini iyileştirir. Ancak, birkaç sınırlama nedeniyle sadece rejeneratif frenlemeye dayanarak aracı yavaşlatmak her zaman mümkün değildir. Birincisi, eğer bataryanın şarj durumu (SOC) maksimum sınırına yakınsa, bataryanın aşırı şarj olması ve hasar görmesi riskinden kaçınmak için rejeneratif frenleme kullanılmamalıdır [4]. İkincisi, yoğun rejeneratif frenleme, yüksek şarj akımları ve aşırı ısınma riski nedeniyle bataryaya zarar verebilir [5, 6]. Son olarak rejeneratif frenleme, elektrik motorunun maksimum enerji üretim kapasitesi ve inverterin DC bağlantı akım yönüyle de sınırlanmalıdır [7].

Bu bağlamda, rejeneratif frenleme sistemlerinin optimum kontrolü, bir yandan elektrikli araçların performansını artırmak ve menzil kısıtlamalarını önemli ölçüde gidermek için çözüm odaklı bir yaklaşım, öbür yandan ise karmaşık ve dinamik araç sistemleri nedeniyle önemli bir mühendislik problemi olarak karşımıza çıkmaktadır. Araç dinamiklerinin (örneğin, hız, ağırlık dağılımı ve frenleme yoğunluğu) değişkenliği, enerji geri kazanımını maksimize etmek için hem hidrolik hem de elektrik motorları arasında optimum bir dengenin sürekli olarak uyarlanmasını gerektirmektedir. Geleneksel kontrol yöntemleri, bu tür dinamik koşullara yeterince hızlı ve esnek bir şekilde uyum sağlayamamaktadır. Bu süreç, sürücünün frenleme taleplerine hızlı ve doğru bir şekilde yanıt verebilen, dinamik koşullara adapte olabilen ve araç sistemlerini sürekli olarak optimize eden yenilikçi kontrol algoritmalarını zorunlu kılmaktadır.

1.1 Literatür Çalışması

Rejeneratif frenleme yönetiminin verimliliğini ve etkinliğini en üst düzeye çıkarmak için, hidrolik fren sistemleri ile elektrik motorları arasındaki optimum Tork Paylaştırma Oranı'nın (TPO) belirlenmesine yönelik çeşitli yaklaşım ve kontrol stratejileri incelenmiştir. Bu stratejiler; kural tabanlı yöntemler, optimizasyon tabanlı yöntemler ve öğrenme tabanlı yöntemler olarak üç ana grupta toplanabilir.

Deterministik kural tabanlı bir (RB) kontrol stratejisi, TPO'nun belirlenebilmesi için benimsenebilecek en basit yaklaşımdır. Örneğin, bu çalışmada tam bir elektrikli araç modeli oluşturmak için kullanılan Matlab Virtual Vehicle Composer (VVC) uygulaması varsayılan olarak, çift motorlu elektrikli araç (DM-EV) için bir tork bölme kuralı kullanmıştır. Bu kurala göre, arka elektrik motoru sürücünün fren torku isteğini öncelikli olarak ve maksimum tork kapasitesine ulaşıncaya kadar karşılamaktadır. Bu durumda ön elektrik motoru, talebi aşan

tork gereksinimini karşılamaktan sorumlu olup bu iki motorun fren torku talebini karşılayamadığı ani frenleme gibi durumlarda geri kalan tork mekanik frenler tarafından karşılanmaktadır. Ancak, maksimum torka dayalı bu yöntem, verimli bir uygulama için fazlasıyla basittir. Kısaca, çift motorlu modda tork dağılımı, aktarma organı verimliliği dikkate alınarak daha etkili bir şekilde yönetilebilir.

Buna benzer kural tabanlı bir kontrol uygulayan çalışmada Ruan vd., rejeneratif frenleme sırasındaki enerji geri kazanımı ile güvenlik performansı arasında denge sağlamayı amaçlamak üzere Eco, Sport ve Safety olmak üzere üç mod belirlemiş ve bunun yanında, çok hızlı ve sık frenleme talepleri nedeniyle oluşabilecek motor arızalarını önlemek adına yine RB tabanlı "Motor Fault Tolerance" (MFT) adında bir fail-safe mekanizması geliştirmiştir. Eco modu, enerji geri kazanımını maksimize etmeye odaklanır. Frenleme kuvveti düşük kritik noktaya kadar öncelikli olarak ön elektrik motoruyla sağlanır, ardından Ekonomik Avrupa Komisyonu (ECE) düzenlemelerine uygun şekilde hidrolik ve elektrikli frenleme arasında dağılım yapılır. Sport modu, dinamik performansı artırmayı hedefler. Bu modda mekanik frenleme önceliklidir, rejeneratif frenleme oranı ise kasıtlı olarak düşük tutulur. Safety modu, güvenliği ön planda tutar. Tork dağılımı elektrik motorları arasında yapılır ve gerektiğinde ABS ile birlikte çalışarak frenleme güvenliğini sağlar. MFT mekanizması ise, motor arızası algılandığında veya fren torku sınırına ulaşıldığında hidrolik frenleri devreye alarak güvenli frenleme sürekliliğini sağlamaktadır [3]. Bu çalışmanın düşük verimliliğe sahip tek motorlu EV mimarisi kullanması bir eksik olarak karşımıza çıkmaktadır.

Yine kural tabanlı bir yöntem olan bulanık mantık kontrolde, önceden tanımlanmış üyelik fonksiyonları ve bulanık kurallar gibi insan uzmanlığına dayanan bir yapı bulunmaktadır. Bu durum, sistematik bir metodolojiden yoksun olmasına ve dinamik koşullara uyum sağlama konusunda zorluklara neden olmaktadır. Bu tip kontrol yöntemlerinin avantajları, basit bir metodolojiye sahip olması, araç kontrol ünitesine (VCU) kolayca uygulanabilirliği ve sürüş çevrimlerine dair önceden bir bilgiye bağımlı olmaması olarak sayılabilir. Buna karşılık, RB kontrol stratejilerinin optimum performans sağlayamaması en büyük eksiklikleridir. Bu nedenle, mühendisler bu tür dezavantajları gidermek için genellikle optimizasyon tabanlı (OB) yaklaşımlara yönelmiştir.

OB yöntemler, sistematik yaklaşımlar olup daha az insan uzmanlığı gerektirmesinin yanında matematiksel modeller ve optimizasyon algoritmaları kullanarak belirli bir amaç fonksiyonunu (örneğin, enerji geri kazanımı veya fren kararlılığı) maksimize etmeye odaklanan temel bir prensibe dayanır. Bu maksimizasyon işlemi yerel olarak, sürüş çevriminin her bir zaman adımı için bir arama yöntemiyle optimum

kontrol değişkenlerinin ayrı ayrı hesaplandığı bir şekilde gerçekleştirilebilir. Bu konuda Li vd., tek motorlu bir elektrikli aracın yokuş aşağı sürüşü sırasındaki frenleme kuvvetlerinin ön ve arka aksta nasıl dağıtılacağını belirlemek için, farklı frenleme yoğunluğu ve yol eğimi açılarına göre TPO'yu optimize eden değişken oranlı bir optimizasyon algoritması kullanmış ve bunu sabit oranlı paylaştırma ile UDDS kentsel yol çevrimi için performans açısından karşılaştırmıştır [8]. Çalışmanın tek tip sürüş çevrimi kullanması, sadece boyuna araç dinamiğinin dikkate alması, sürücü davranışlarını ve değişik yol tiplerini dikkate almaması eksik yönleridir.

Bunun yanında maksimizasyon işlemi, bize global optimum kontrol eylemlerini verecek şekilde global olarak da gerçekleştirilebilir. Genel olarak global optimum kontrol stratejileri, diğer tüm kontrol stratejileri için bir performans ölçütü oluşturur. Örneğin Zhou vd., frenleme sırasındaki rejenere edilen enerjiyi optimize etmek için NSGA-II tabanlı çok amaçlı optimum kontrol stratejisi önermiş ve üç farklı sürüş çevrimi için bulanık kontrol yöntemine kıyasla daha fazla enerji yenilendiğini göstermiştir. [9] Buna benzer başka bir çalışmada Chen vd., ECE R13 regülasyonu dahilinde farklı araç yükleri ve yol eğimi değerleri için genetik algoritma kullanarak optimun paylaştırma oranını belirlemiştir [10]. Diğer bir OB yöntemi ise Tang vd. tarafından, değişik frenleme yoğunlukları ve araç yükleri için, optimum fren kuvveti paylaştırma oranını belirlemek adına önerilmiştir. Bu paylaştırma oranı, ECE R13 regülasyonu, ideal frenleme kuvveti paylaştırma eğrisi, ön tekerlek kilitlenme eğrisi, yükteki değişimler ve farklı yol sürtünme katsayıları gibi kısıtlamalar göz önünde bulundurularak yapay arı kolonisi (ABC) algoritması ile belirlenmiştir. Sonuç olarak, sabit oranlı paylaştırmaya oranla kayda değer bir enerji yenileme artışı gözlenmiş. Bunun yanında, aynı yol tipi ve araç yükü için frenleme yoğunluğu arttıkça bu oranın azaldığı ve yine yol sürtünme katsayısındaki azalma ve frenleme aciliyetindeki artmayla bu oranın azaldığı sonucuna varmışlardır [11]. Ancak buna benzer, regülasyonlarda belirlenen ideal tork eğrilerini temel alan paylaştırma yöntemleri her motor için her zaman en verimli çalışma noktalarına karşılık gelemeyebileceğinden en iyi verimliliği üretmeyebilir. Li vd. tarafından, hem enerji verimliliği hem de kontrol performansı dikkate alınarak oyun teorisi optimizasyonuna dayalı bir rejeneratif frenleme kontrol stratejisi önerilmiştir. Çalışmada, her tekerde bir motoru bulunan elektrikli araçlar için, ECE regülasyonları, araç hızı, frenleme yoğunluğu, motor tork limitleri ve batarya şarj durumu gibi kısıtlar dahilinde frenlemenin stabilitesi, konforu ve rejenere edilen frenleme enerjisinin maksimize edilmesi değerlendirilmiş ve sonuçlar bulanık kontrol yöntemiyle ulaşılan sonuçlarla karşılaştırılmıştır [12].

Verilen çalışmardan OB yöntemlerinin her ne kadar RB yöntemlerine göre daha

yüksek performansa sahip olduğu görülse de, yüksek hesaplama maliyetine sahip olmaları, verdikleri optimum sonuçların bir veya birkaç sürüş çevrimi ve araç değişkeni ile kısıtlı olmalarından ötürü tüm olası sürüş koşulları için optimum sonuçlar verememeleri büyük bir eksiklik olarak karşımıza çıkmaktadır. Bu nedenle mühendisler, mevcut trafik durumunu ve sürüş örgüsünü tanımlayabilmek ve bu tanımlamaya dayanarak en uygun TPO'yu belirleyebilmek adına model öngörülü kontrol ve makine öğrenimi tekniklerine yönelmiştir. Örneğin Tang vd., çift motorlu bir elektrikli araçta acil frenleme durumları için, motorun ve hidrolik fren sisteminin dinamik özellikleri ve tork limitlerini göz önünde bulundurarak, model öngörülü kontrole (MPC) dayalı bir koordineli kontrol stratejisi önermiştir. Çalışmada, optimum tork paylaştıma oranını elde etmek için traversal metod kullanılmış olup buradan elde edilen değerlerle gerçekleştirlen kontrol yöntemi, fren mesafesi, frenleme süresi, rejeneratif enerjinin verimliliği ve kayma oranı açısından geleneksel koordineli kontrol stratejisi ile karşılaştırılmıştır. Bu dört konunun her birinde kayda değer performans artışı sağlamıştır (Rejenere edilen enerjide %22.76'dan daha fazla) [13]. Yine benzer bir çalışmada Xu vd. tarafından, dört tekerlek içi motorlu bir elektrikli araç için MPC tabanlı bir rejeneratif frenleme torku dağıtım yöntemi geliştirilmiştir [14]. Benzer bir çalışmada Zhang vd., adaptif kübik exponansiyel tahmin ve dinamik programlamaya dayalı yepyeni bir öngörülü kontrol metodu önermiştir. Önerilen kontrol yapısında, adaptif kübik exponansiyel tahmin, aracın geçmiş verilerini kullanarak, araç hızı ve frenleme yoğunluğu gibi gelecekteki temel parametreleri tahmin eder ve dinamik programlamanın parametlerini oluşturur. DP ise, ön ve arka motor frenleme torklarını ve hidrolik basınçları optimize ederek araç için kontrol parametreleri sağlar [15]. Yukarıda zikredilen öngörüye dayalı yaklaşımlarda prensip olarak kontrol kararları, gerçek zamanlı maliyet fonksiyonunun hesaplanmasıyla elde edilir. Sonuç olarak, ağır bir hesaplama yükü donanım işlemcisini zorlayabilmektedir. Bu gibi yöntemlerin bir başka eksi yönü ise büyük ölçüde öngörülerinin doğruluğuna dayanmalarıdır. Bu yüzden araç herhangi bir sürüş sırasında öngörülemeyen bir durumla karşılaşırsa, EMS'den optimum olmayan bir performans elde edilme ihtimali vardır.

Son zamanlarda gelişen yapay zeka teknolojisi ile birlikte, öğrenme tabanlı yöntemlerle, karmaşık ve dinamik sistemler üzerinde yüksek doğrulukla optimuma yakın çözümler elde edebilmişlerdir. Yapılan çalışmalarda bu öğrenmenin, denetimli (supervised), denetimsiz (unsupervised), pekiştirmeli (reinforcement), fizik tabanlı (physics-informed) veya hibrit şeklinde olduğu görülmektedir.

Örneğin Kiddee vd., bir yapay sinir ağı (YSA) kullanarak ön ve arka aks frenleme kuvvetlerini ve ön aks rejeneratif frenleme kuvvetini hesaplamaktadır. Bu yaklaşımda YSA'nın girdileri, araç hızı, sürücü fren pedalı girdisi, batarya şarj

durumu ve ultra-kapasitör şarj durumu gibi enerji depolama birimlerinin güncel durumunu ve aracın anlık sürüş koşullarını içermektedir. İki farklı enerji depolama ünitesine sahip bir yapıda, YSA temelli kontrolcü farklı kaynaklar arasındaki güç ve tork dağılımını optimize ederek enerjiyi daha verimli kullanmayı hedeflemiştir [16]. Yavaşoğlu vd., iki motorlu bir elektrikli araçta, bir motor batarya ve yakıt hücresiyle, diğeri ise ultra-kapasitör ile beslenecek şekilde tasarlanan güç yönetim stratejisinde YSA kullanılmıştır. YSA'nın 22 giriş değişkeni arasında hız, ivme, güç değerleri ve enerji depolama ünitelerinin şarj durumları (SOC) bulunmakta; YSA dört farklı güç bileşeninin (PUC, PFC, PBat, PConv) optimizasyonunda rol oynamaktadır [17]. He vd., frenleme anında elektrik motoru ve hidrolik fren sistemi arasındaki güç dağılımını optimize etmek için YSA tabanlı bir kontrolcü kullanmıştır. Burada YSA girdi olarak batarya şarj durumu (SOC), araç hızı (v) ve normalize edilmiş araç ivmesini (z) alırken, çıktı olarak elektrik motoru rejeneratif fren torku (Tm) ve hidrolik fren torkunu (Thr) üretmektedir. Bu sayede, YSA, farklı sürüş senaryolarında anlık olarak enerji geri kazanımını maksimize ederken, güvenli frenleme için gereken hidrolik destekle denge sağlar [18]. Tian vd., hibrit elektrikli bir şehir otobüsünde enerji yönetimi için YSA tabanlı bir kontrolcü önermiştir. Burada YSA, gerçek zamanlı olarak elektrik motoru ve içten yanmalı motor arasındaki güç dağılımını belirleyerek hem yakıt hem de elektrik tüketimini minimize etmeye çalışmaktadır. YSA'nın eğitiminde, DP kullanılarak elde edilen optimum enerji yönetim sonuçları referans alınmıştır. YSA'nın girdileri, talep edilen güç, enerji depolama sisteminin (ESS) enerji seviyesi, ivme, araç hızı ve "length ratio" olarak tanımlanan, aracın mevcut konumu ile kalan mesafe oranıdır. Bu girdi tasarımı, YSA'nın ileriye dönük bir perspektif sunmasına olanak tanır [19]. Prasanth vd., elektrikli araçlarda rejeneratif frenleme kuvvetini maksimize etmek amacıyla rastgele orman (random forest) ve polinomal regresyon algoritmaları kullanmıştır [20]. Bir başka çalımada ise Zeng vd. tarafından pekiştirmeli öğrenme yöntemi olan Q-öğrenme ile trenler için hız eğrileri ve enerji geri kazanımı optimize edilmiştir [21]. Son zamanlarda yapılan bir diğer çalışmada Yang vd., tamamen elektrikli bir maden kamyonu için derin pekiştirmeli öğrenme algoritmasına dayanan bir rejeneratif frenleme stratejisi geliştirmiş ve sonuç olarak enerji verimliliğinin %18.15'e kadar artırılabileceği gösterilmiştir [22].

1.1.1 Sonuç ve Literatürdeki Boşluklar

Yapılan literatür incelemesi, öğrenme yöntemlerinin rejeneratif frenleme ve enerji yönetimi stratejilerinde giderek önem kazandığını göstermektedir. Bununla birlikte, bu alanda elektrikli araçlar için çok fazla çalışma mevcut olmamakla birlikte, mevcut yaklaşımların da kısıtlı sayıda parametreyi göz önünde bulundurmaları,

tam araç dinamiğini veya farklı senaryo kombinasyonlarını yeterince bütüncül değerlendirmemeleri büyük bir eksiklik olarak karşımıza çıkmaktadır. Çalışmada sunulan yaklaşım, bu boşlukları doldurmaya yönelik bir adımdır. Çok boyutlu karakteristik değişken seti, Yapay sinir ağı - Karar ağacı tabanlı kontrolcü, DP ile elde edilen optimum sonuçların eğitim verisi olarak kullanılması yaklaşımıyla kontrol sınırlarının korunması, literatürdeki eksik noktaları ele alan bütüncül ve dinamik bir kontrol stratejisi sunmaktadır. Bu sayede, değişken ve öngörülemeyen koşullara daha hızlı adaptasyon, maksimum enerji geri kazanımı, araç güvenliğinin sağlanması ve regülasyonlara uyumluluk hedeflenmektedir.

1.2 Tezin Amacı

Bu çalışma, ön ve arka aksta birer elektrik motoru bulunan bir elektrikli araçta, sürücü fren isteğinin karşılanması, aracın yanal kararlılığının korunması, aktüatör limitleri ve batarya limitleri gibi kısıtlar dahilinde, rejeneratif frenleme performansını artırmayı, yani enerji geri kazanımını maksimize ederek elektrikli araçların menzil sınırlamalarını önemli ölçüde azaltmayı hedeflemektedir.

1.3 Tezin Metodolojisi

Literatürün gözden geçirilmesi sonucunda, mevcut rejeneratif frenleme sistemlerinin kontrolünde çevresel koşullar, araç dinamikleri ve sürücü davranışlarının bütüncül şekilde ele alınmadığı, ayrıca elde edilen çözümlerin dinamik ve değişken koşullara yeterince hızlı uyum sağlayamadığı belirlenmiştir. Bu tespit edilen eksiklikten yola çıkarak çalışmada, belirlenen amaç doğrultusunda YSA - KA tabanlı bir kontrol metodolojisi uygulanacaktır.

Bu bağlamda, 7 farklı karakteristik değişken göz önünde bulundurularak sürüş senaryoları oluşturulacak, her bir senaryo için dinamik programlama yöntemi kullanılarak, sürücünün fren tork isteği ve regülasyonlarda belirlenen kısıtlamalar dahilinde, maksimum enerji geri kazanımını sağlayacak optimum tork paylaştırma oranı ($\gamma = \mathcal{T}_n/\mathcal{T}_{toplam}$) elde edilecektir. Burada γ ön aks fren torkunun toplam fren torkuna oranını, EMö ön aks elektrik motoru fren torkunu, EMa ise arka aks elektrik motoru fren torkunu ifade etmektedir. Optimizasyon probleminin karakteristik değişkenleri ise şu şekilde belirlenmiştir: A1 = Yol eğimi (grade), A2 = Yol sürtünme koşulu (adhesion coefficient), A3 = Araç yük dağılımı (vehicle mass distribution), A4 = Araç hızı (velocity), A5 = Araç ivmesi (acceleration) - Frenleme oranı (Braking rate), A6 = Bataryanın şarj durumu (SOC), A7 = Toplam fren torku. Sürüş sırasında bu 7 değişkenin çeşitli kombinasyonlarından oluşan

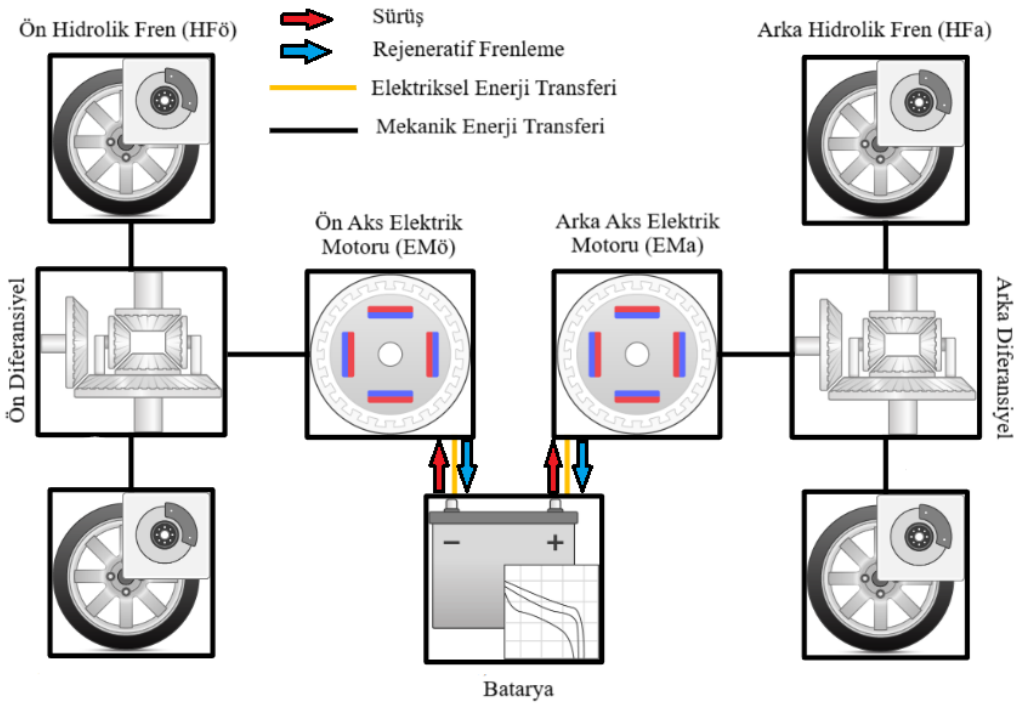
sürüş senaryoları, geri kazanılacak fren enerjisini maksimize edecek aktüatörler arası optimum tork paylaştırma oranları hesaplanarak fren aktüatörleri kontrol edilecektir. Senaryoların koşturulması ve dinamik programlama hesaplamalarının gerçekleştirilebilmesi için ön ve arka aksında birer elektrik motoru bulunan 14 serbestlik derecesine sahip tam bir araç modeli MATLAB VVC ile oluşturulacaktır.

Dinamik programlamadan elde edilen sonuçlar, bir yapay sinir ağı (YSA) - karar ağacı (KA) hibrit modelinin eğitim kümesini oluşturmak amacıyla kullanılacaktır. Daha önce tanımlanan 7 karakteristik değişken (A1–A7) girdi olarak alınacak ve nihâî olarak EMö ve EMa kontrol çıkışları elde edilecektir.

Son aşamada araç modelinin kontrolü, eğitilen modelin araç modeline entegresi ile gerçekleştirilecek, sonuçlar dinamik programlama ile elde edilecek optimal sonuçlar ile ve Matlab'de bulunan hazır paylaştırma yöntemiyle karşılaştırılarak hibrit modelin hem kontrol performansının optimalitesi hem de değişken olmayan kontrol yöntemlerine göre ne kadar iyi gelişme sağladığı analiz edilecektir.

2
ELEKTRİKLİ ARAÇ MODELİ VE ELEKTRO-HİDROLİK FRENLEME YAPISI

Bu bölümde, söz konusu kontrol algoritmasının tasarımında temel alınan elektrikli araç modeli ve elektro-hidrolik frenleme yapısı detaylı şekilde incelenecektir. Öncelikle elektrikli araçta kullanılan güç aktarma organları, motor ve batarya dinamikleri ile ilgili temel bilgiler sunulacak; ardından elektro-hidrolik fren sisteminin bileşenleri ve çalışma prensipleri açıklanacaktır. Böylece sonraki bölümlerde yer alacak optimizasyon ve kontrol yaklaşımının dayandığı fiziksel model ve yapısal bileşenler netleştirilmiş olacaktır.



Şekil 2.1 Elektro-Hidrolik Frenleme Yapısı

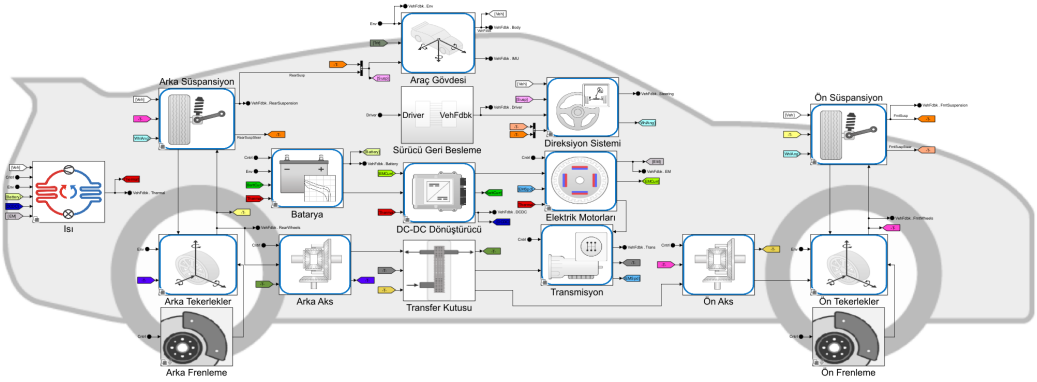
Şekil 2.1'de, çalışmada ele alınan elektro-hidrolik frenlemeye sahip bir elektrikli aracın temel konfigürasyonu görülmektedir. Burada:

- **Sürüş:** Aracın sürüş sırasındaki batarya ve EM arasındaki enerji akışını simgeler.
- **Rejeneratif Frenleme:** Rejeneratif frenleme esnasında oluşan kinetik enerjinin elektrik enerjisine dönüştürülmesini ifade eder.
- **Elektriksel Enerji Transferi:** Batarya ve elektrik motorları arasında gerçekleşen elektrik akışını gösterir.
- **Mekanik Enerji Transferi:** Diferansiyeller, tekerlekler ve şaftlar üzerinden aktarılan mekanik kuvvet ve torku ifade eder.

Görüldüğü gibi araçta ön ve arka aksta birer tane olmak üzere iki elektrik motoru (EMö ve EMa) ve hidrolik frenleme sistemi (HFö, HFa) ile birlikte aracı yavaşlatacak 4 tane aktüatör bulunmaktadır. Bu konfigürasyonda, ön diferansiyel ve arka diferansiyel sayesinde tekerleklere tahrik veya fren torku dağıtılırken, batarya hem sürüş için gerekli enerjiyi elektrik motorlarına sağlar hem de rejeneratif frenleme sırasında geri kazanılan enerjiyi depolar. Böylece fren anında, EMö ve EMa jeneratör modunda çalışarak bataryayı şarj ederken, gelen talep ve sınırları aştığı noktalarda hidrolik frenlerdevreye girerek ilave fren torku sağlar.

2.1 Matlab Virtual Vehicle Composer

Frenleme ve rejeneratif enerji geri kazanımı gibi dinamik süreçlerin gerçeğe en yakın bir şekilde analiz edilebilmesi için, MATLAB Virtual Vehicle Composer uygulaması kullanılarak araç gövdesinde 6 ve her bir tekerde 2'şer olmak üzere toplam 14 serbestlik derecesine sahip bir araç modeli oluşturulmuştur, Şekil 2.2.



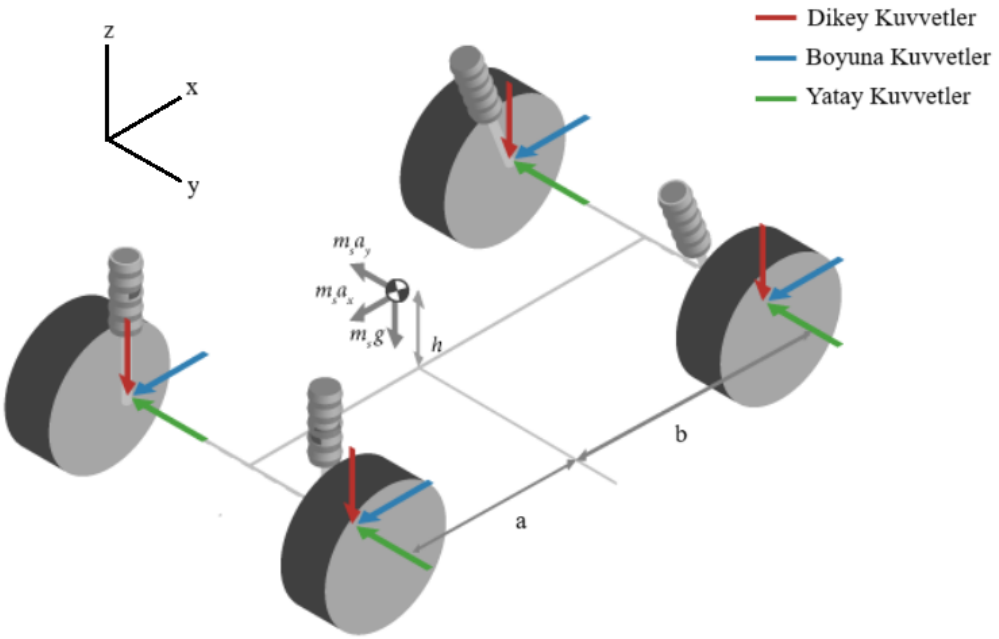
Şekil 2.2 14 serbestlik derecesine sahip araç modeli

Modelde, boyuna, yanal, dikey, yunuslama, yalpa ve sapma hareketlerini hesaplamak için altı serbestlik derecesine (DOF) sahip, rijit, iki akslı bir

araç gövdesi bulunmaktadır. Model, gövde kütlesi, eylemsizlik, aerodinamik sürüklenme, yol eğimi ve akslar arasındaki süspansiyon, dış kuvvetler ve momentlere bağlı ağırlık dağılımını hesaba katar.

2.1.1 Araç Hareket Denklemi

Araç hareketini ifade etmek amacıyla, rijit gövdeli araç dinamiği, rüzgâr sürükleme etkileri, eylemsizlik kuvvetleri ve koordinat dönüşümleri birlikte ele alınmıştır [23]. Gövdeye sabitlendirilmiş koordinat sistemi, aynı zamanda araç referans koordinat sistemidir, Şekil 2.3.



Şekil 2.3 Araç Dinamiği Şeması

Gövdeye sabitlendirilmiş koordinat sistemindeki öteleme hareketi, aşağıda verilen denklem ile hesaplanır (burada uygulanan kuvvetler $\begin{bmatrix} F_x & F_y & F_z \end{bmatrix}^T$ gövdeye sabit koordinat sisteminde ifade edilir ve gövde kütlesinin (m) değişmez olduğu varsayılır):

$$\overline{\mathbf{F}}_b = \begin{bmatrix} F_x \\ F_y \\ F_z \end{bmatrix} = m\left(\dot{\overline{\mathbf{V}}}_b + \overline{\boldsymbol{\omega}} \times \overline{\mathbf{V}}_b\right) \tag{2.1}$$

$$\overline{\mathbf{M}}_b = \begin{bmatrix} L \\ M \\ N \end{bmatrix} = \mathbf{I}\,\dot{\overline{\boldsymbol{\omega}}} + \overline{\boldsymbol{\omega}} \times \left(\mathbf{I}\,\overline{\boldsymbol{\omega}}\right) \tag{2.2}$$

$$\mathbf{I} = \begin{bmatrix} I_{xx} & -I_{xy} & -I_{xz} \\ -I_{yx} & I_{yy} & -I_{yz} \\ -I_{zx} & -I_{zy} & I_{zz} \end{bmatrix} \tag{2.3}$$

Burada; $\overline{\mathbf{F}}_b$ [N] gövdeye sabit koordinat sistemindeki net kuvvet vektörü, $\overline{\mathbf{V}}_b$ [m/s] gövdeye sabit koordinat sistemindeki hız vektörü, $\overline{\boldsymbol{\omega}}$ [rad/s] gövdeye sabit koordinat sistemindeki açısal hız vektörü, $\overline{\mathbf{M}}_b$ [N·m] gövdeye sabit koordinat sistemindeki net moment (dönme momenti) vektörü, $\mathbf{I}$ [kg·m^2] araç gövdesinin atalet momentleri ve m [kg] aracın toplam kütlesidir.

Gövdeye sabitlenmiş açısal hız vektörü $\begin{bmatrix} p & q & r \end{bmatrix}^T$, ile Euler açılarının değişim oranı, $\begin{bmatrix} \dot{\phi} & \dot{\theta} & \dot{\psi} \end{bmatrix}^T$, arasındaki ilişki aşağıdaki denklemlerle belirlenir:

$$\begin{aligned} \begin{bmatrix} p \\ q \\ r \end{bmatrix} &= \begin{bmatrix} \dot{\phi} \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\phi & \sin\phi \\ 0 & -\sin\phi & \cos\phi \end{bmatrix} \begin{bmatrix} 0 \\ \dot{\theta} \\ 0 \end{bmatrix} \\ &\quad + \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\phi & \sin\phi \\ 0 & -\sin\phi & \cos\phi \end{bmatrix} \begin{bmatrix} \cos\theta & 0 & -\sin\theta \\ 0 & 1 & 0 \\ \sin\theta & 0 & \cos\theta \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ \dot{\psi} \end{bmatrix} \\ &\equiv \mathbf{J}^{-1} \begin{bmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{bmatrix} \end{aligned} \tag{2.4}$$

Buradan $\mathbf{J}$ matrisinin tersini alarak, Euler değişim vektörünü belirlemek için gerekli bağıntı şu şekilde elde edilir:

$$\begin{bmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{bmatrix} = \mathbf{J} \begin{bmatrix} p \\ q \\ r \end{bmatrix} = \begin{bmatrix} 1 & \sin\phi\,\tan\theta & \cos\phi\,\tan\theta \\ 0 & \cos\phi & -\sin\phi \\ 0 & \dfrac{\sin\phi}{\cos\theta} & \dfrac{\cos\phi}{\cos\theta} \end{bmatrix} \begin{bmatrix} p \\ q \\ r \end{bmatrix} \tag{2.5}$$

Uygulanan kuvvetler ve momentler, sürükleme, yer çekimi, dış kuvvetler ve süspansiyon kuvvetlerinin toplamıdır:

$$\overline{\mathbf{F}}_b = \begin{bmatrix} F_x \\ F_y \\ F_z \end{bmatrix} = \begin{bmatrix} F_{dx} \\ F_{dy} \\ F_{dz} \end{bmatrix} + \begin{bmatrix} F_{gx} \\ F_{gy} \\ F_{gz} \end{bmatrix} + \begin{bmatrix} F_{\text{extx}} \\ F_{\text{exty}} \\ F_{\text{extz}} \end{bmatrix} + \begin{bmatrix} F_{\text{FLx}} \\ F_{\text{FLy}} \\ F_{\text{FLz}} \end{bmatrix} + \begin{bmatrix} F_{\text{FRx}} \\ F_{\text{FRy}} \\ F_{\text{FRz}} \end{bmatrix} + \begin{bmatrix} F_{\text{RLx}} \\ F_{\text{RLy}} \\ F_{\text{RLz}} \end{bmatrix} + \begin{bmatrix} F_{\text{RRx}} \\ F_{\text{RRy}} \\ F_{\text{RRz}} \end{bmatrix} \tag{2.6}$$

$$\overline{\mathbf{M}}_b = \begin{bmatrix} M_x \\ M_y \\ M_z \end{bmatrix} = \begin{bmatrix} M_{dx} \\ M_{dy} \\ M_{dz} \end{bmatrix} + \begin{bmatrix} M_{\text{extx}} \\ M_{\text{exty}} \\ M_{\text{extz}} \end{bmatrix} + \begin{bmatrix} M_{\text{FLx}} \\ M_{\text{FLy}} \\ M_{\text{FLz}} \end{bmatrix} + \begin{bmatrix} M_{\text{FRx}} \\ M_{\text{FRy}} \\ M_{\text{FRz}} \end{bmatrix} + \begin{bmatrix} M_{\text{RLx}} \\ M_{\text{RLy}} \\ M_{\text{RLz}} \end{bmatrix} + \begin{bmatrix} M_{\text{RRx}} \\ M_{\text{RRy}} \\ M_{\text{RRz}} \end{bmatrix} + \overline{\mathbf{M}}_F \tag{2.7}$$

2.2 Tekerlek Modeli

Aracın yol ile temasını sağlayan tekerleklerin dinamiği frenleme kuvvetlerinin oluşumunu ve dolayısıyla aracın toplam fren torku isteğini doğrudan belirler. Bu çalışmada, boylamsal ve yanal kayma koşullarını aynı anda dikkate alarak lastiğin dinamik davranışı yansıtması için geliştirilmiş bir Magic Formula yaklaşımı benimsenmiştir [24]. Bu doğrultuda, tekerde oluşan boyuna ve yanal kuvvetler şu denklemlerle verilir:

$$F_x = \left(D_x \sin\left[C_x \arctan\left\{B_x\kappa_x - E_x\left(B_x\kappa_x - \arctan\left(B_x\kappa_x\right)\right)\right\}\right] + S_{Vx}\right) G_{x\alpha} \tag{2.8}$$

$$F_y = G_{y\kappa}F_{yp} + S_{Vy\kappa} \tag{2.9}$$

Ek-A'da 7, denklemler ile ilgili detaylı bilgi verilmektedir.

2.3 Sürücü Modeli

Bu bölümde ele alınan sürücü modeli, C. C. MacAdam tarafından geliştirilen optimal tek noktalı önizlemeli (ileriye bakışlı) bir kontrol modelini temel almaktadır [25–27]. Model, sürücünün önceden tanımlanmış bir yolu veya hız profilini takip etme sırasındaki kontrol davranışını temsil eder. Model, araç dinamiklerini doğrusal olarak ele alır (single track - bicycle), ayrıca T^* saniye ilerideki tek bir noktada öngörülen hata sinyalini en aza indirir ve sürücü gecikmesini de hesaba katar.

Modelde, aracın uzunlamasına hareketi aşağıdaki doğrusal dinamik denklemlerle

ifade edilir:

$$x_1 = v \tag{2.10}$$

$$\dot{x}_1 = x_2 = \frac{K_{pt}}{m} - g\sin(\gamma) + F_r x_1 \tag{2.11}$$

Durum denklemleri matris formunda şu şekilde gösterilir:

$$\dot{x} = Fx + \mathrm{g}\bar{u} \tag{2.12}$$

Burada;

$$x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \tag{2.13}$$

$$F = \begin{bmatrix} 0 & 1 \\ \frac{F_r}{m} & 0 \end{bmatrix} \tag{2.14}$$

$$\mathrm{g} = \begin{bmatrix} 0 \\ \frac{K_{pt}}{m} \end{bmatrix} \tag{2.15}$$

$$\bar{u} = u - \frac{m^2}{K_{pt}} g\sin(\gamma) \tag{2.16}$$

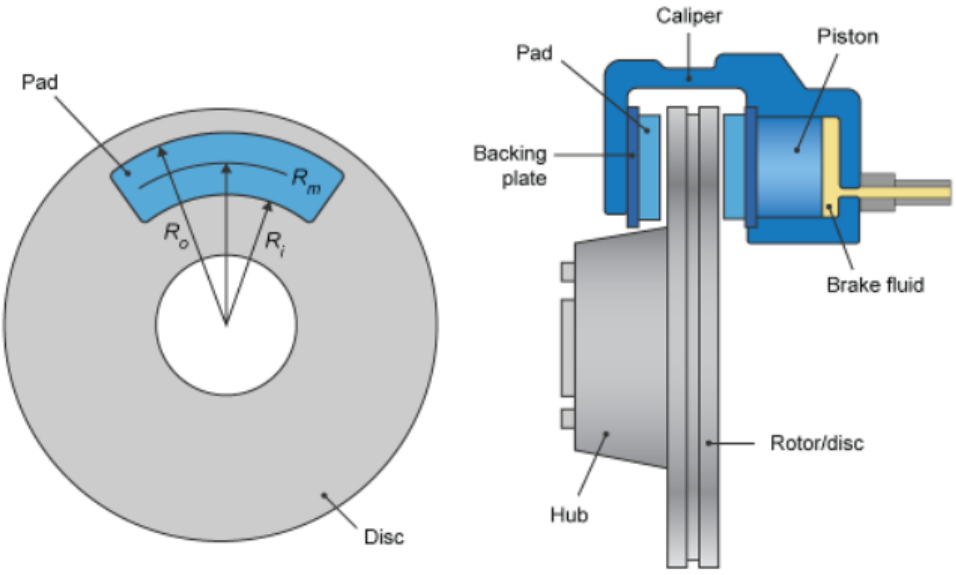
Yuvarlanma direncini (F_r) ise aşağıdaki denklemler ile hesaplanır:

$$F_r = -\left[\tanh(x_1)\left(\frac{a_r}{x_1} + c_r x_1\right) + b_r\right] \tag{2.17}$$

Burada; x araç durum vektörü, v aracın hızı (ki aynı zamanda x_1 olarak da tanımlanır), m araç kütlesi, K_{pt} çekiş kuvveti ve fren limitini belirten sabit, γ yol eğim açısı, g yerçekimi ivmesi sabiti, F_r yuvarlanma direnci, a_r - c_r - b_r sırasıyla statik - doğrusal - aerodinamik yuvarlanma dirençleri, F sistem matrisi ve g kontrol katsayısı vektörünü temsil etmektedir.

2.4 Hidrolik Frenleme Modeli

Elektrikli araç modelinde, her bir tekerlekte diskli hidrolik fren sistemi kullanılmaktadır. Elektrik motorlarının gücünün yetmediği ani frenleme gibi yüksek torka ihtiyaç duyulan durumlarda, rejeneratif frenlemenin uygun olmadığı çok düşük hızlarda veya bataryanın doluya yakın olduğu durumlarda hidrolik fren sistemi devreye girer. Sürücü fren pedalına bastığında, ana silindirde üretilen basınç fren sıvısı aracılığıyla kalipere iletilir. Kaliper, balataları diske doğru bastırarak diskte sürtünme kuvveti oluşturur. Bu kuvvet, ortalama yarıçap (R_o) üzerinden etki ederek fren torku ($\mathcal{T}$) meydana getirir. Bu tork, aracın kinetik enerjisini sürtünme yoluyla ısı enerjisine dönüştürerek aracı yavaşlatır, Şekil 2.4.



Şekil 2.4 Disk frenlemenin yapısı

Oluşan fren torku şu denklemle hesaplanır:

$$\mathcal{T} = \begin{cases} \dfrac{\mu\, P\, \pi\, B_a^2\, R_o\, N_{\text{balata}}}{4}, & \text{tekerlek hızı } N \neq 0 \text{ ise,} \\ \dfrac{\mu_{\text{statik}}\, P\, \pi\, B_a^2\, R_o\, N_{\text{balata}}}{4}, & \text{tekerlek hızı } N = 0 \text{ ise,} \end{cases} \tag{2.18}$$

$$R_o = \frac{R_d + R_i}{2}. \tag{2.19}$$

Burada, $\mathcal{T}$ bir diskte oluşan fren torku (Nm), P uygulanan fren basıncı (Pa), N

tekerlek hızı, N_{balata} disk frende kullanılan balata sayısı, μ_{statik} balata-disk arası statik sürtünme katsayısı, μ balata-disk arası kinetik sürtünme katsayısı, B_a fren silindiri çapı, R_o fren diskine etkiyen balata kuvvetinin ortalama yarıçapı, R_d fren balatasının dış yarıçapı, R_i fren balatasının iç yarıçapıdır. Frenleme sırasında aracın ihtiyaç duyduğu toplam fren torku ise, tüm disklerdeki bireysel tork bileşenlerinin toplamıyla aşağıdaki gibi hesaplanır:

$$\mathcal{T}_{\text{fren}}^{toplam} = \sum_{i=1}^{4} (\mu \cdot \pi \cdot B_a^2 \cdot 2 \cdot R_o \cdot \frac{N_{\text{balata}}}{4}) \cdot P_i \tag{2.20}$$

$$P_i = \begin{cases} y_{dec} \cdot \text{Ön faktör } (1) \cdot K, & \text{öndeki diskler için } (i = 1, 2) \\ y_{dec} \cdot \text{Arka faktör } (0.6) \cdot K, & \text{arkadaki diskler için } (i = 3, 4) \end{cases} \tag{2.21}$$

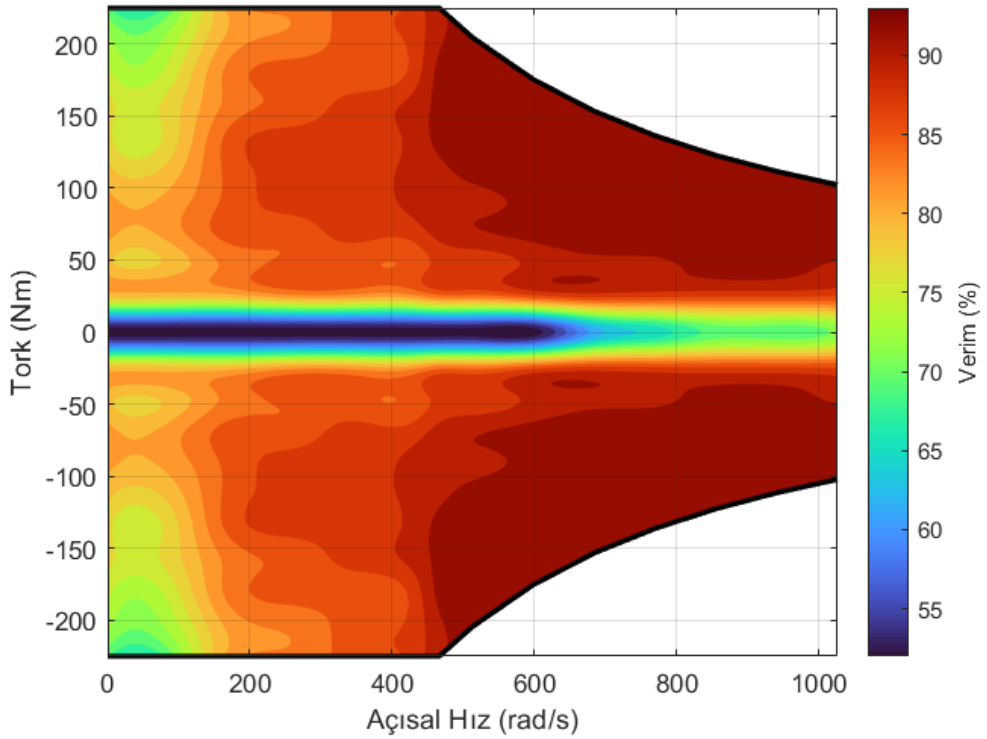
Burada; y_{dec} sürücü modelinde üretilen normalize edilmiş yavaşlama komutu, K basınç faktörü (8000000 Pa), P_i sırasıyla her bir diske iletilen fren basıncı, $\mathcal{T}_{\text{fren}}^{toplam}$ ise frenleme esnasında talep edilen toplam fren torkudur.

2.5 Motor Modeli

Modelde, ön ve arka akslarda aynı özelliklere sahip iki elektrik motoru (EM) bulunmaktadır. Motorun tork ve açısal hızına bağlı verim haritası Şekil 2.5'de gösterilmiştir.

Motorların maksimum tork değeri $\pm 225\,\text{Nm}$ ve maksimum gücü $105\,\text{kW}$'tır. Pozitif bölge, motorun enerji tükettiği durumları temsil ederken, negatif bölge aracın mekanik enerjisinin elektrik enerjisine dönüştürüldüğü durumları ifade eder. Rejeneratif frenleme sırasında bataryayı şarj edecek ön ve arka akslardaki güç değeri ise aşağıdaki şekilde hesaplanmaktadır:

$$P_{\text{EM}} = \mathcal{T}_{\text{EM}} \cdot \omega \cdot \eta \tag{2.22}$$



Şekil 2.5 Motor verim haritası

P_{EM} : Elektrik motorunun gücü (W),

$\mathcal{T}_{\text{EM}}$: Elektrik motorunun torku (Nm),

ω : Elektrik motorunun açısal hızı (devir/dakika),

η : Elektrik motorunun verimidir.

2.6 Batarya Modeli

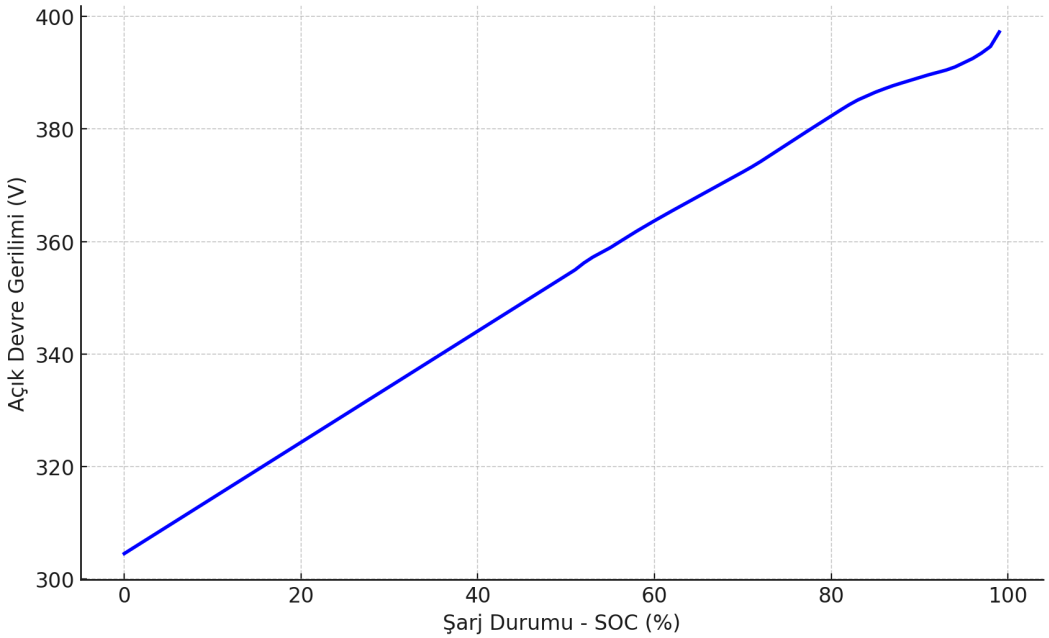
Lityum-iyon batarya modeli, çeşitli çalışma noktalarındaki batarya performansını karakterize etmek için modelde kullanılmıştır. Bataryada, her bir hücrenin kütlesi 0.0495 kg olan, 96 seri ve 94 paralel hücre bulunmaktadır.

Batarya çıkış voltajını belirlenmesinde kullanılan, SOC ve batarya sıcaklığına bağlı olarak değişen açık devre gerilimi ve iç direnç grafikleri Şekil 2.6 'de gösterilmektedir.

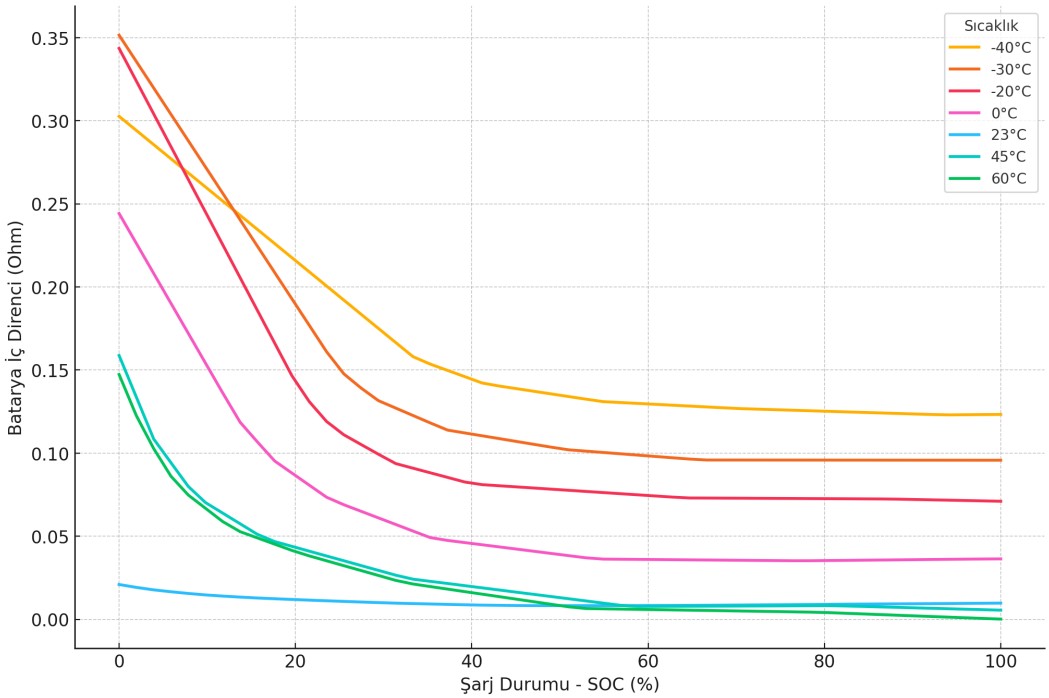
$$E_m = f(SOC) \tag{2.23}$$

$$R_{\text{iç}} = f(T, SOC) \tag{2.24}$$

Burada; E_m (V), bataryanın açık devre gerilimini, $R_{\text{iç}}$ (Ω), bataryanın iç direncini ifade eder.



(a)



(b)

Şekil 2.6 Batarya karakteristikleri: (a) Açık devre gerilimi, (b) İç direnç.

Bataryanın SOC dinamiği şu şekilde verilir:

$$SOC = SOC_0 - \frac{1}{C_{\text{bat}}} \int_0^t I_{\text{bat}}\, dt \tag{2.25}$$

Burada; SOC_0, başlangıç şarj durumu; C_{bat}, batarya kapasitesi; I_{bat}, bataryadan geçen akımı temsil eder.

Batarya sisteminin deşarj gücü dinamiği şu şekilde verilir:

$$P_{\text{bat}} = -V_{\text{bat}} I_{\text{bat}} \tag{2.26}$$

$$V_T = E_m - I_{\text{bat}} R_{\text{iç}} \tag{2.27}$$

Burada; P_{bat} batarya gücü, V_{bat} bataryanın voltajını temsil etmektedir.

(2.26) ve (2.27) denklemleri birleştirilip, P_{bat}'ın ikinci dereceden denklemi çözüldüğünde bataryadan geçen akım şu şekilde elde edilir:

$$I_{\text{bat}} = \frac{E_{\text{m}} - \sqrt{E_{\text{m}}^2 - 4 P_{\text{bat}} R_{\text{iç}}}}{2 R_{\text{iç}}} \tag{2.28}$$

Son olarak, rejeneratif frenleme sırasında bataryada depolanan güç şu şekilde elde edilir:

$$P_{\text{Depo}} = P_{\text{Bat}} + P_{\text{Kayıp}} \tag{2.29}$$

Burada $P_{\text{Kayıp}}$, batarya güç kaybıdır ve şu şekilde hesaplanır:

$$P_{\text{Kayıp}} = -N_p N_s I_{\text{bat}}^2 R_{\text{iç}} \tag{2.30}$$

Burada N_p ve N_s, sırasıyla paralel ve seri hücre sayısını ifade etmektedir.

3
OPTİMİZASYON ALGORİTMASI

Ön ve arka akslar arasındaki fren kuvveti dağılım oranı ile her iki motorun ürettiği rejeneratif fren kuvvetlerinin toplam fren kuvvetine oranı, ön ve arka aksta birer motoru olan elektrikli araçlarda hem frenleme kararlılığını hem de enerji geri kazanım verimliliğini belirleyen kritik bir öneme sahiptir.

Bu bölümde, 2. Bölüm'de tam modeli verilen bir elektrikli aracın frenleme durumlarında rejeneratif frenleme sayesinde geri kazanılan enerjiyi maksimize etmesi için toplam fren torkunu ön ve arka akslar arasında dağıtan optimizasyon algoritması ele alınmaktadır. Öncelikle regülasyonlara uygun kısıtlamalar, araç kararlılık kriterleri ve araç yük dağılımı gibi algoritmanın temel çerçevesi matematiksel olarak ifade edilmekte, ardından dinamik programlama algoritmasının yapısı, durum uzayı tanımı, maliyet fonksiyonu ve çözüm adımları sistematik bir şekilde açıklanmaktadır.

Son olarak, elde edilen optimum sonuçların nasıl bir veri kümesine dönüştürüldüğü ve bu verilerin ileri aşamalarda Yapay Sinir Ağı (YSA) - Karar Ağacı (KA) tabanlı hibrit kontrolcünün eğitiminde nasıl kullanılacağına dair genel bir çerçeve sunulmaktadır.

3.1 UN / ECE Regülasyonları

Aracın frenleme güvenliğini sağlamak amacıyla UN / ECE belirli düzenlemeler belirlemiştir. ECE R13-H fren düzenlemelerine göre binek araçlar için, ön ve arka aksların fren kuvveti dağılımı aşağıdaki gereklilikleri karşılamalıdır, [28]:

1. Aracın tüm yük durumları için, frenleme oranı $z = 0.15 \sim 0.8$ aralığındayken, arka aksın adezyon eğrisi (adhesion utilization curve), ön aksınkinden büyük olmamalıdır [regülasyon 3.1.(A)];

$$k_f \geq k_r \tag{3.1}$$

2. Adezyon katsayısı k, $0.2 \sim 0.8$ aralığındayken, frenleme oranı aşağıdaki koşulu sağlamalıdır, [regülasyon 3.1.(B)]:

$$z \geq 0.1 + 0.7(k - 0.2) \tag{3.2}$$

Eğer, $k = 0.2$ ve $k = 0.8$ değerleri sırasıyla 3.2 eşitsizliğinde yerine koyulursa, z'nin değişim aralığı $0.1 \leq z \leq 0.52$ olarak bulunur. Ön ve arka tekerleklerin adezyon katsayıları z'nin bu aralığı için aşağıdaki koşulları sağlar:

$$k_f \leq \frac{z + 0.04}{0.7} \tag{3.3}$$

$$k_r \leq \frac{z + 0.04}{0.7} \tag{3.4}$$

Burada; k_f ve k_r sırayla ön ve arka akstaki teorik adezyon katsayısını, yani tekerleklerin frenleme sırasında yol tutuşunu ne kadar etkin kullandığını gösteren katsayıyı temsil etmektedir. Araç potansiyel etkisi göz önüne alındığında, aracın eğimli bir yolda giderkenki frenleme oranı, ön ve arka adezyon katsayısı sırasıyla şu şekilde tanımlanır [8]:

$$z_t = z \cos \alpha + \sin \alpha \tag{3.5}$$

$$k_{\mathrm{f}} = \frac{F_{x,\mathrm{f}}}{F_{z,\mathrm{f}}} = \frac{\gamma z_t L}{l_r \cos(\alpha) + z_t h_{cg}} \tag{3.6}$$

$$k_{\mathrm{r}} = \frac{F_{x,\mathrm{r}}}{F_{z,\mathrm{r}}} = \frac{(1 - \gamma) z_t L}{l_f \cos(\alpha) - z_t h_{cg}} \tag{3.7}$$

Burada; $F_{x,f}$ ve $F_{x,r}$ normal frenleme koşulları altında frenlerin sırasıyla ön ve arka aksa uyguladığı kuvvetler, $F_{z,f}$ ve $F_{z,r}$ frenleme sırasında yol yüzeyinden sırasıyla ön ve arka aksa etki eden normal kuvvetler, l_f ön aks ile ağırlık merkezi arasındaki mesafe, l_r arka aks ile ağırlık merkezi arasındaki mesafe, L toplam aks mesafesi, α yol eğimi, h_{cg} ağırlık merkezi yüksekliği, γ ise frenleme kuvveti paylaştırma oranıdır.

Denklem 3.6 ve 3.7'yi sırasıyla 3.1, 3.3 ve 3.4'te yerlerine koyduğumuzda, frenleme

kuvveti paylaştırma oranına dair şu eşitsizlikler elde edilir:

$$\gamma \geq \frac{l_r cos\alpha + z_t h_{cg}}{L\, cos\alpha} \qquad 0.15 \leq z_t \leq 0.8 \tag{3.8}$$

$$\gamma \leq \frac{(z_t + 0.04)(l_r cos\alpha + z_t h_{cg})}{0.7 z_t L} \qquad 0.1 \leq z_t \leq 0.52 \tag{3.9}$$

$$\gamma \geq 1 - \frac{(z_t + 0.04)(l_f cos\alpha - z_t h_{cg})}{0.7 z_t L} \qquad 0.1 \leq z_t \leq 0.52 \tag{3.10}$$

Böylelikle, ECE düzenlemesi kısıtlamaları altında, ön tekerlekler için adezyon katsayısı, arka tekerleklere kıyasla her zaman daha yüksekt olup frenleme kararlılığı sağlanmaktadır.

Bununla birlikte, frenleme sürecinde, tekerleklerin kullanım katsayılarının yolun adezyon katsayısından (μ) düşük olması istenir. 3.1'deki eşitsizlik dikkate alınarak, ön tekerleklerin kullanım katsayısının arka tekerleklerinkinden daha büyük olması sağlandığına göre, yalnızca ön tekerleklerin kullanım katsayısının yolun adezyon katsayısından düşük olması gerektiği ele alınır, bu da şu şekilde ifade edilir:

$$\gamma < \frac{\mu(z_t h_{cg} + l_r cos\alpha)}{z_t L} \tag{3.11}$$

3.2 Araç Yük Dağılımı

ISO 10392:2011 standardına göre, araç yükündeki değişikliklerin, h_{cg}, l_f ve l_r gibi aracın yapısal parametreleri üzerinde etkisi vardır [29]. Bu yapısal parametreler, fren kuvvetlerinin dağılımını ve genel frenleme performansını etkilemektedir.

Ön aks merkezi ile ağırlık merkezi arasındaki yatay mesafe, l_f, şu denklemle belirlenir:

$$l_f = \frac{m_r}{m_v} \times L \tag{3.12}$$

Burada; m_r arka aks yükü, m_v ise aracın toplam kütlesidir. Bu çalışmada, ek yüklerin ağırlık merkezine yakın bir konumda bulunduğu varsayımı üzerinden aracın ağırlık merkezinin yüksekliği h_{cg} sabit kabul edilmiştir. Araç modelinde kullanılan parametreler Tablo 3.1'de sunulmuştur.

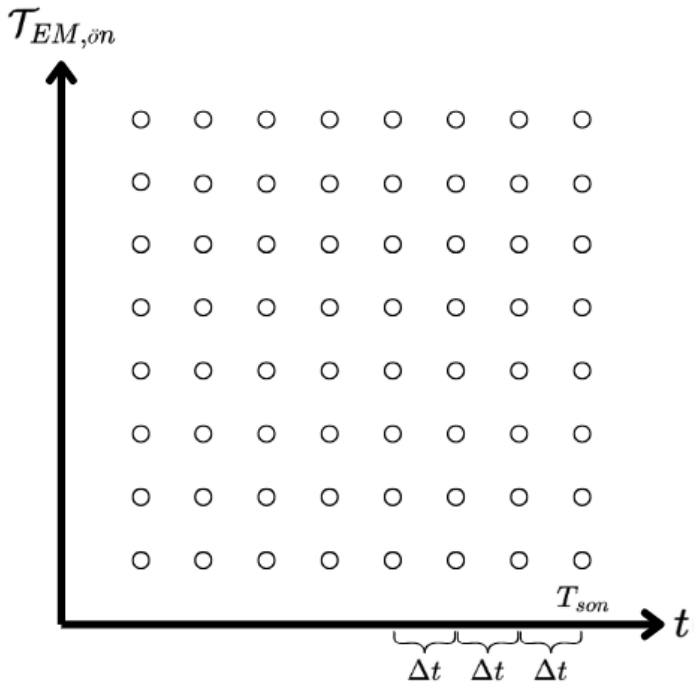
Tablo 3.1 Araç parametreleri

Tanım	Sembol	Değer
Araç kütlesi (boş ağırlık)	m	2000 kg
Kütle merkezi ile ön aks arası mesafe	l_f	1.09 m
Kütle merkezi ile arka aks arası mesafe	l_r	1.7 m
Kütle merkezi yüksekliği	h_{cg}	0.627 m
Tekerlek yarıçapı	r	0.327 m
Transmisyon oranı	i_t	3.32

3.3 Dinamik Programlama

Frenleme sırasında rejeneratif frenleme enerjisini maksimize etmek amacıyla, toplam fren torkunun ön ve arka akslar arasında optimum dağılımını belirleyen bir Dinamik Programlama (DP) algoritması geliştirilmiştir.

DP hesaplamaları için öncelikle, ön aks elektrik motoru tork uzayı oluşturulur, Şekil 3.1. Burada daireler tork seviyelerini temsil eder. Tork seviyeleri arasındaki olası durum geçişlerinde, DP algoritması, enerji geri kazanımını maksimize etmek amacıyla optimum geçişi belirler.



Şekil 3.1 Ön aks elektrik motoru tork uzayı

Frenleme senaryosunun her anında EM için, olası durum geçişlerini belirlemek üzere üç kısıt dikkate alınır:

Kısıt 1) Şekil 2.5'te, EM'ye ait tork grafiği verilmişti. Frenleme senaryosunun her

anında, üretilebilecek maksimum EM tork değeri bu grafikteki sınırlar üzerinden interpolasyonla belirlenir.

Kısıt 2) Bölüm 3.1'de verilen UN/ECE regülasyonlarına binaen, ön aks için izin verilen tork değerlerini belirlemek amacıyla $3.8-3.11$ numaralı denklemler dikkate alınarak aşağıdaki sınırlamalar elde edilir:

$$\mathcal{T}_{EM,\, n,\, min} = \gamma_{min} \mathcal{T}_{fren}^{toplam} i_t \tag{3.13}$$

$$\mathcal{T}_{EM,\, n,\, maks} = \gamma_{maks} \mathcal{T}_{fren}^{toplam} i_t \tag{3.14}$$

Burada; $\mathcal{T}_{EM,\, n,\, min}$ ve $\mathcal{T}_{EM,\, n,\, maks}$, sırasıyla ön aks elektrik motorunda izin verilen minimum ve maksimum tork değerleri, i_t transmisyon oranı ve $\mathcal{T}_{\text{fren}}^{toplam}$ bölüm 2.4'te açıklandığı gibi frenleme esnasında talep edilen toplam fren torku değeridir.

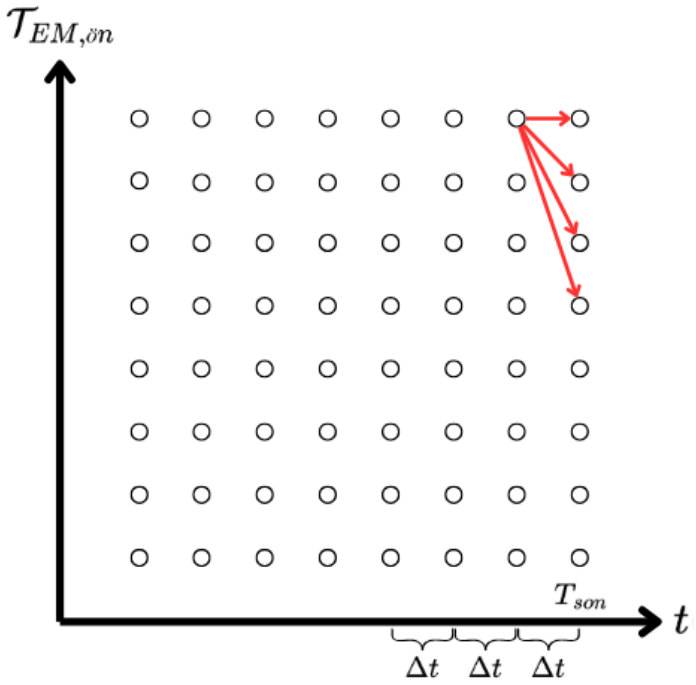
Kısıt 3) Elektrik motorunun tepki süresi nedeniyle, Şekil 3.1'de gösterilen tork seviyeleri arasında, belirli bir andaki tork seviyesinden Δt zaman sonraki tork seviyesine olan geçişler, yalnızca belirli bir seviye farkına kadar mümkün olacaktır. Elektrik motorunun Δt zaman içindeki tork artış veya azalış miktarı, motorun tepki süresi nedeniyle sınırlı olduğundan, bu zaman içinde en fazla 3 seviye yukarı veya aşağı olacak şekilde sınırlandırılabilir, Pratikte bu kısıtın gerçek değeri, kullanılan elektrik motorunun özelliklerine göre belirlenir.

Böylece, yukarıda bahsedilen üç kısıt dikkate alınarak, frenlemenin herhangi bir anında, ön aks üzerindeki EM tarafından üretilebilecek tüm olası tork değerleri kümesi belirlenir. DP, bu tork seviyeleri arasında, belirlenen kısıtları aynı anda sağlayan optimum kararlar alacaktır. Toplam fren torklarının ön ve arka akslara paylaştırılması sırasında, EM'lerin torkları yetersiz kalırsa, kalan fren torkları hidrolik fren sistemleri tarafından sağlanır.

DP algoritmasında, hesaplamalar sondan bir önceki adımdan başlayarak geriye doğru yapılır. Ön EM tork geçişleri, $T_{son} - \Delta t$ anındaki en yüksek tork değerinden Δt zaman sonraki tork değerlerine doğru Şekil 3.2'de kırmızı oklarla gösterilmiştir.

Bu 4 olası tork geçişi arasından optimum olanı şu şekilde belirlenir: T ve $T - \Delta t$ anları için ayrı ayrı;

1. Ön elektrik motorunun verimliliği, motor torku ve hızına bağlı olarak interpolasyon yoluyla hesaplanır, Şekil 2.5.



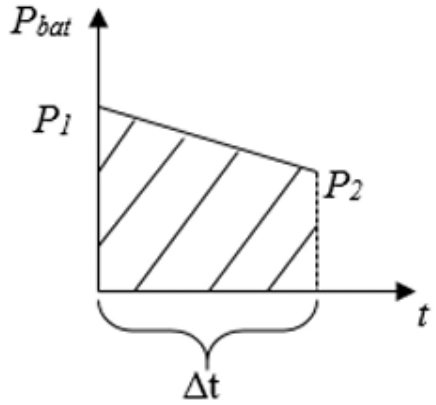
Şekil 3.2 $T_{son} - \Delta t$ anındaki en yüksek seviye torktan durum geçişleri

2. Ön elektrik motorunun gücü hesaplanır, denklem 2.22 .
3. Aynı işlemler arka aks elektrik motoru için uygulanır.
4. Ön ve arka akstaki elektrik motorlarının toplam gücü hesaplanır.
5. Bataryanın açık devre gerilimi (E_m) ve iç direnci (R_i), batarya sıcaklığı ve şarj durumu (SOC) değerlerine bağlı olarak interpolasyon yoluyla hesaplanır, Şekil 2.6.
6. Bataryanın gücü ve şarj akımı, batarya parametrelerine bağlı olarak hesaplanır, sırasıyla denklem 2.26 - 2.28.
7. Her bir tork geçişi için batarya şarj güçleri kullanılarak maliyet fonksiyonu (batarya enerjisindeki artış miktarı) hesaplanır.

Şekil 3.3'te gösterildiği gibi, bataryanın şarj gücü Δt süresi boyunca P_1'den P_2'ye değiştiğinde, güç eğrisinin altında kalan alan batarya enerjisindeki artış miktarını verecektir.

Eğrinin altında kalan alan, yamuk formülü kullanılarak aşağıdaki şekilde hesaplanır:

$$\Delta E = \frac{(P_1 + P_2)\Delta t}{2} \tag{3.15}$$



Şekil 3.3 Batarya gücünün P_1'den P_2'ye Δt zamanındaki değişimi

Burada; ΔE batarya enerjisindeki artış miktarıdır.

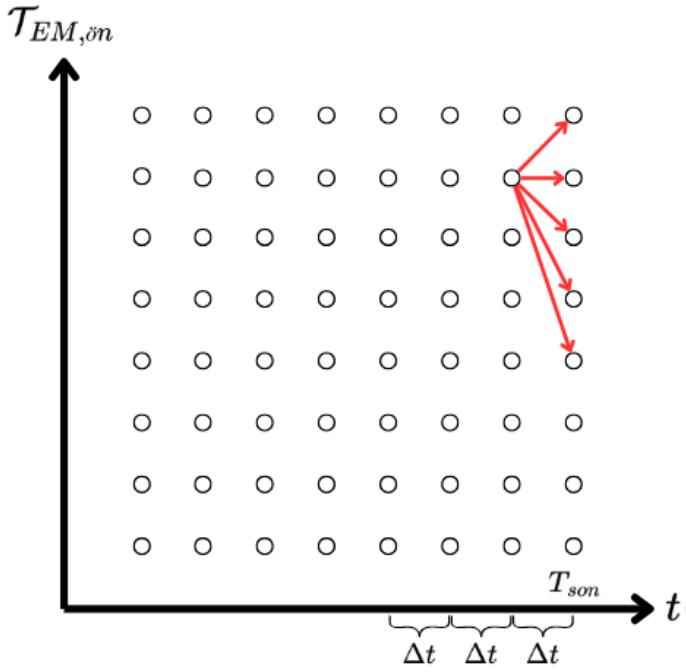
Şekil 3.2'de gösterilen tüm olası tork geçiş alternatifleri için batarya şarj performansları hesaplanır. Bu dört tork geçiş alternatifi arasında, batarya enerjisini en çok durum bize optimum geçişi verecektir. Seçim aşağıdaki fonksiyon aracılığıyla yapılır:

$$J^*_{T_{son}-\Delta t}(1) = \max \begin{cases} J^{T_{son}}_{T_{son}-\Delta t}(1,1), \\ J^{T_{son}}_{T_{son}-\Delta t}(1,2), \\ J^{T_{son}}_{T_{son}-\Delta t}(1,3), \\ J^{T_{son}}_{T_{son}-\Delta t}(1,4). \end{cases} \tag{3.16}$$

Burada; $J^{T_{son}}_{T_{son}-\Delta t}(1,1)$, $T_{\text{son}} - \Delta t$ anında en üst ok yönündeki $\mathcal{T}_{\text{EM,ön}}$ seviyesi değiştiğinde batarya enerjisindeki artış miktarını temsil eder. Diğer alternatif tork değişimleri için, batarya enerjisindeki artış miktarları denklem 3.16 kullanılarak karşılaştırılır ve böylece $T_{\text{son}} - \Delta t$ anındaki en üst tork seviyesinden, Δt zaman sonra ulaşılması gereken bir sonraki tork seviyesi belirlenir. $T_{\text{son}} - \Delta t$ anındaki en üst seviyeden ulaşılacak bir sonraki seviyeye ulaşıldığındaki batarya enerjisindeki artış miktarı $J^*_{T_{son}-\Delta t}(1)$ olarak ifade edilir.

Ardından, $T_{\text{son}} - \Delta t$ anındaki en üst $\mathcal{T}_{\text{EM,ön}}$ seviyesinin bir altındaki seviyeden takip edilecek bir sonraki yolu belirlemek için, ikinci tork seviyesinden tüm olası geçişler (Şekil 3.4) için batarya şarj değerleri hesaplanır ve denklem 3.17'de verilen fonksiyon ile bataryanın en çok şarj edilmesini sağlayan optimum durum geçişi belirlenir:

$$J^*_{T_{son}-\Delta t}(2) = \max \begin{cases} J^{T_{son}}_{T_{son}-\Delta t}(2,1), \\ J^{T_{son}}_{T_{son}-\Delta t}(2,2), \\ J^{T_{son}}_{T_{son}-\Delta t}(2,3), \\ J^{T_{son}}_{T_{son}-\Delta t}(2,4), \\ J^{T_{son}}_{T_{son}-\Delta t}(2,5). \end{cases} \tag{3.17}$$

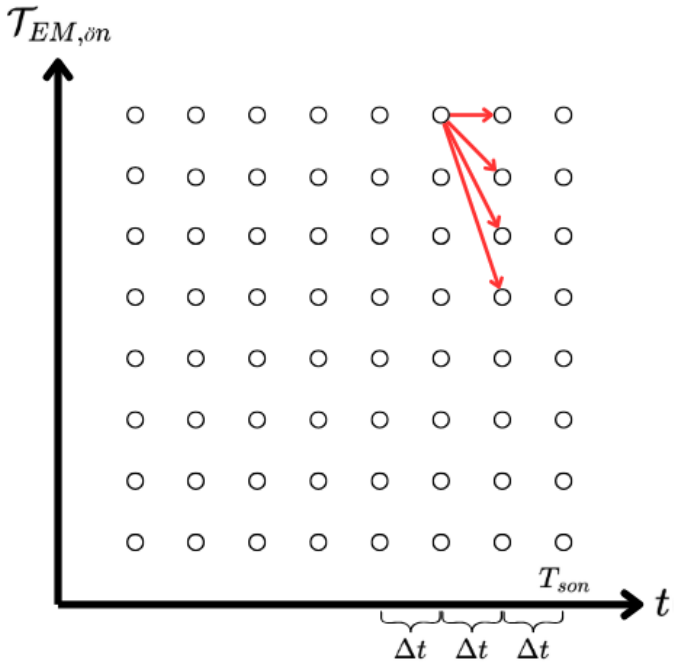


Şekil 3.4 $T_{son} - \Delta t$ anındaki en üst seviye torkun bir altındaki aşamadan durum geçişleri

Böylece, $T_{\text{son}} - \Delta t$ anındaki ikinci en yüksek $\mathcal{T}_{\text{EM,ön}}$ seviyesinden, ulaşılması gereken seviye belirlenir ve bu optimum durum geçişi için batarya enerjisindeki artış miktarı $J^*_{T_{son}-\Delta t}(2)$ olarak ifade edilir. Benzer şekilde, $T_{\text{son}} - \Delta t$ anındaki her bir $\mathcal{T}_{\text{EM,ön}}$ seviyesinden bir sonraki adımda ulaşılacak optimum seviyeler belirlenir ve bu optimum durum geçişleri hafızada saklanır. Bu şekilde, $T_{\text{son}} - \Delta t$ anındaki tüm olası tork seviyelerinden, Δt zaman sonra gidilmesi gereken tork seviyeleri teker teker belirlenir ve optimum yollar hafızada saklanır.

Daha sonra, Şekil 3.5'te gösterildiği gibi $T_{son} - 2\Delta t$ anındaki durum geçişleri için hesaplamalar yapılır. $T_{son} - 2\Delta t$ anında, en üst seviyeden ulaşılacak bir sonraki seviye, aşağıdaki fonksiyonla hesaplanır:

$$J^*_{T_{\text{son}-2\Delta t}}(1) = \max \begin{cases} J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(1,1) + J^*_{T_{\text{son}-\Delta t}}(1), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(1,2) + J^*_{T_{\text{son}-\Delta t}}(2), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(1,3) + J^*_{T_{\text{son}-\Delta t}}(3), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(1,4) + J^*_{T_{\text{son}-\Delta t}}(4). \end{cases} \tag{3.18}$$



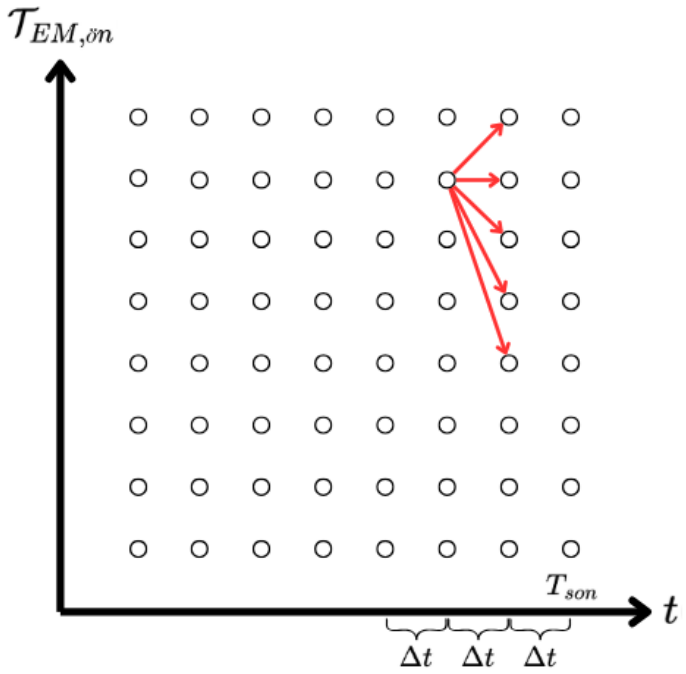
Şekil 3.5 $T_{son} - 2\Delta t$ anındaki en yüksek seviye torktan durum geçişleri

Şekil 3.6'da görüldüğü gibi, $T_{son} - 2\Delta t$ anındaki ikinci tork seviyesinden ulaşılacak bir sonraki seviye bir öncekine benzer şekilde aşağıdaki gibi hesaplanır:

$$J^*_{T_{\text{son}-2\Delta t}}(2) = \max \begin{cases} J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(2,1) + J^*_{T_{\text{son}-\Delta t}}(1), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(2,2) + J^*_{T_{\text{son}-\Delta t}}(2), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(2,3) + J^*_{T_{\text{son}-\Delta t}}(3), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(2,4) + J^*_{T_{\text{son}-\Delta t}}(4), \\ J^{T_{\text{son}-\Delta t}}_{T_{\text{son}-2\Delta t}}(2,5) + J^*_{T_{\text{son}-\Delta t}}(5). \end{cases} \tag{3.19}$$

Burada; $J^*_{T_{\text{son}-2\Delta t}}(2)$, $T_{\text{son}} - 2\Delta t$ anındaki ikinci tork seviyesinden Δt zaman sonraki tork seviyesine yapılan optimum enerji artışını ifade eder. Benzer şekilde, $T_{\text{son}} - 2\Delta t$ anındaki tüm olası tork seviyelerinden Δt zaman sonra ulaşılması gereken tork seviyeleri belirlenir ve optimum yollar hafızada saklanır.

Aynı şekilde, süreç geriye doğru $T_{\text{son}} - 3\Delta t$, $T_{\text{son}} - 4\Delta t$, ... anları için devam eder ve

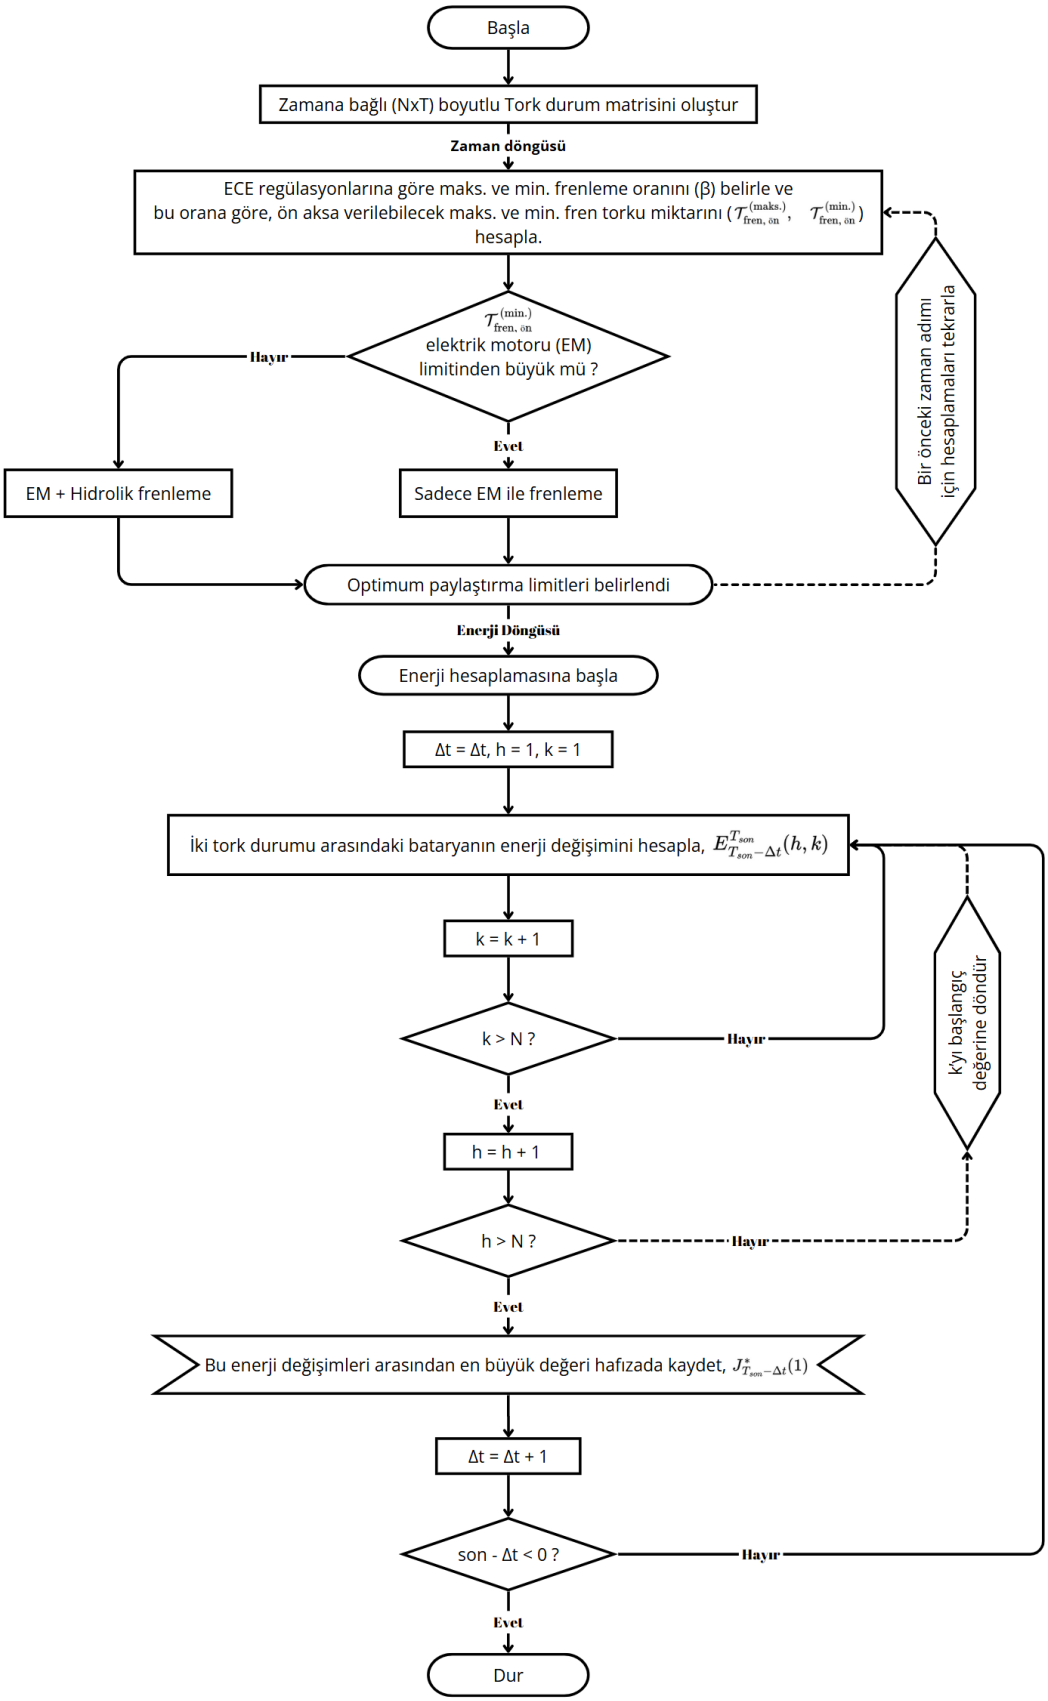


Şekil 3.6 $T_{son} - 2\Delta t$ anındaki en üst seviye torkun bir altındaki aşamadan durum geçişleri

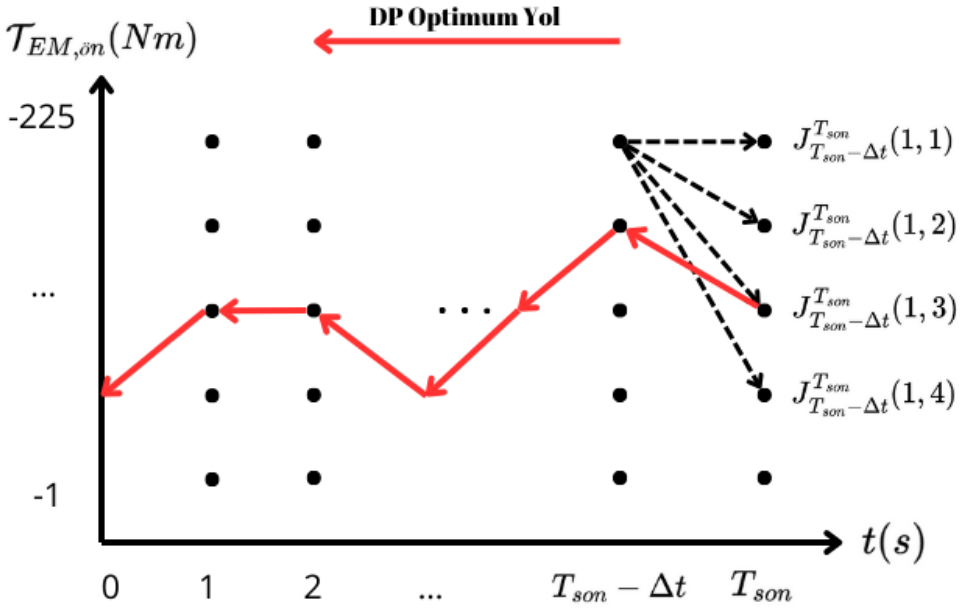
nihayetinde, frenleme senaryosunun başlangıç aşaması için hesaplamalar yapılarak DP algoritmasının iterasyonu tamamlanır. Algoritmanın akış şeması Şekil 3.7'de verilmiştir.

Hesaplamalar tamamlandığında, frenleme senaryosunun her anında ön ve arka akslardaki elektrik motoru torklarının nasıl değişmesi gerektiği belirlenir. Başka bir deyişle, düşünülen frenleme senaryosu için toplam rejeneratif frenleme enerjisini maksimize eden optimum tork dağılımları belirlenir. DP prosedürü tamamlandıktan sonra, frenleme bu optimum torklar kullanılarak gerçekleştirilir. Örneğin, bir frenleme senaryosu sırasında ön aks için optimum EM tork seviyelerinin şematik değişimi Şekil 3.8'de gösterilmiştir.

Dinamik programlama ile elde edilen optimum çözümler (γ, EMö, EMa) ve bunlara karşılık gelen 7 giriş değişkeni), 4. Bölüm'de geliştirilecek Yapay Sinir Ağı - Karar Ağacı hibrit modelinin eğitim verisi olarak kullanılacaktır. Bu veri seti, hem optimizasyonun çıktılarını hem de sistemin fiziksel kısıtlarını (örn. γ'nın regülasyon sınırları, motor tork kapasiteleri vb.) içerecek şekilde tasarlanmıştır. Hibrit modelin eğitiminde kullanılacak girdi-çıktı çiftleri, DP'nin çok-değişkenli optimizasyon sürecinde ürettiği çeşitli senaryolardan oluşmaktadır.



Şekil 3.7 Algoritmanın akış şeması



Şekil 3.8 Ön aks elektrik motoru için şematik optimum tork geçişleri

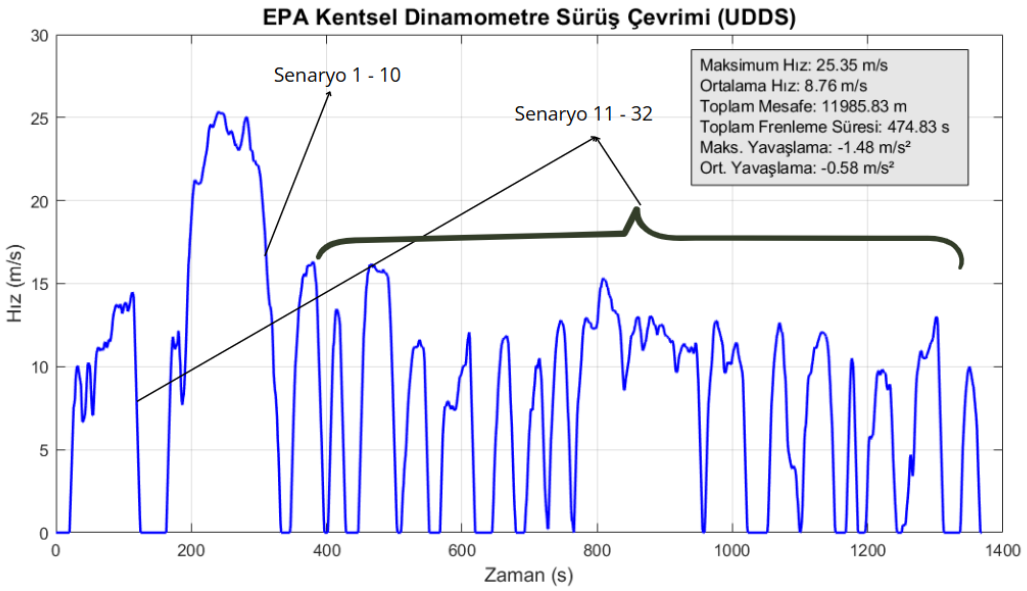
4
YSA VE KARAR AĞACI TABANLI HİBRİT KONTROL SİSTEMİ TASARIMI

Bu bölümde, elektrikli araçlarda (EA) rejeneratif frenleme performansının iyileştirilmesi amacıyla geliştirilen hibrit kontrol stratejisi sunulmaktadır. Önerilen yaklaşım, yapay sinir ağlarının (YSA) karmaşık örüntüleri modelleme yeteneği ile karar ağaçlarının (KA) yorumlanabilirlik avantajlarını birleştiren bir yaklaşımdır. Modelin geliştirilmesinde, hiperparametre optimizasyon tekniklerinden faydalanılmış ve eğitim süreci için dinamik programlamadan (DP) elde edilen optimal kontrol verileri kullanılmıştır. Geliştirilen hibrit model, hem dahili veri setleri hem de bağımsız test senaryoları üzerinde kapsamlı performans analizleri ile doğrulanmıştır. Modelin temel çıktısı, frenleme anında ön ve arka akslardaki elektrik motorlarına (sırasıyla EMö ve EMa) iletilmesi gereken optimal rejeneratif tork değerleridir.

4.1 Veri Hazırlama ve Ön İşleme

Hibrit kontrol modelinin eğitimi ve doğrulanması için gerekli veri seti, standartlaştırılmış bir şehir içi sürüş döngüsü olan EPA Kentsel Dinamometre Sürüş Çevrimi (Environmental Protection Agency Urban Dynamometer Driving Schedule - UDDS) temel alınarak oluşturulmuştur. UDDS, değişken hızlanma, yavaşlama ve sabit hız periyotları içeren yapısıyla, şehir içi sürüş koşullarını temsil eden ve rejeneratif frenleme potansiyelinin değerlendirilmesi için yaygın olarak kullanılan bir protokoldür [30]. Şekil 4.1, kullanılan UDDS hız profilini ve temel karakteristiklerini göstermektedir.

UDDS çevrimindeki yavaşlama segmentleri temel alınarak, farklı operasyonel ve çevresel koşulları simüle etmek amacıyla 32 adet senaryo türetilmiştir. Bu senaryolar; yol eğimi (%), yol yüzeyi sürtünme katsayısı (μ), toplam araç kütlesi (kg) ve batarya şarj durumu (State of Charge - SOC, %) gibi önemli parametrelerin farklı kombinasyonlarını içermektedir. Senaryolara ait parametre



Şekil 4.1 EPA Kentsel Dinamometre Sürüş Çevrimi (UDDS) hız profili.

değerleri Tablo 4.1'de özetlenmiştir. Modelin genelleme yeteneğini objektif bir şekilde değerlendirebilmek amacıyla, 4, 9, 24, 25, 29 ve 30 numaralı senaryolar tamamen bağımsız test verisi olarak ayrılmış, geri kalan senaryolar ise modelin eğitim (%70), validasyon (%15) ve dahili test (%15) aşamaları için kullanılmıştır.

Tablo 4.1 Hibrit model geliştirme sürecinde kullanılan senaryo koşulları.

	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_10	S_11-32
Yol Eğimi (%)	0	0	0	-10	0	0	0	0	-10	-10	0
Sürt. Kats. (μ)	0.9	0.6	0.3	0.9	0.9	0.9	0.9	0.9	0.3	0.3	0.9
Toplam Kütle (kg)	2000	2000	2000	2000	2200	2400	2000	2400	2200	2400	2400
SOC (%)	60	60	60	60	60	60	20	20	20	60	60

Oluşturulan veri seti, aşağıdaki giriş değişkenlerini (model girdilerini) içermektedir:

- Toplam fren torku talebi (Nm),
- Batarya şarj durumu (SOC, %),
- Yol yüzeyi sürtünme katsayısı (μ),
- Yol eğimi (%),
- Boylamsal frenleme oranı (Braking Rate = Araç İvmesi / Yerçekimi İvmesi, boyutsuz),
- Anlık araç hızı (m/s),
- Toplam araç kütlesi (kg).

Modelin tahmin etmesi hedeflenen çıkış değişkenleri ise, optimal rejeneratif frenleme stratejisine karşılık gelen ön elektrik motoru torku (EMö, Nm) ve arka elektrik motoru torku (EMa, Nm) değerleridir. Bu değerler, DP yöntemi ile belirlenen ve enerji geri kazanımını maksimize eden referans torklardır.

Veri setinin ayrılmasında tekrarlanabilirliği sağlamak amacıyla rastgele sayı üreteci (random seed) 42 olarak sabitlenmiştir. Modelin eğitim performansını artırmak ve farklı ölçeklerdeki giriş değişkenlerinin etkisini dengelemek amacıyla da, giriş değişkenleri `minmax` normalizasyon yöntemi kullanılarak [0,1] aralığına ölçeklendirilmiştir:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{4.1}$$

Bu denklemde X, orijinal giriş değişkenini; X_{norm}, normalize edilmiş değeri; X_{min} ve X_{max} ise ilgili değişkenin eğitim setindeki minimum ve maksimum değerlerini temsil etmektedir. Çıkış değişkenleri olan EMö ve EMa tork değerleri ise, tahminlerin doğrudan fiziksel anlamını koruması amacıyla normalizasyona tabi tutulmamıştır.

4.2 Hibrit Sistem Yaklaşımı ve Mimarisi

Rejeneratif frenleme kontrolü için önerilen bu model, YSA ve KA algoritmalarının güçlü yönlerini birleştiren hibrit bir mimariye sahiptir. YSA'lar, giriş değişkenleri arasındaki karmaşık, doğrusal olmayan ilişkileri yüksek doğrulukla modelleyebilme kapasitesine sahipken [31], KA'lar özellikle belirli koşul kümeleri altında bölgesel davranışları yakalama ve yorumlanabilir kurallar üretme konusunda avantajlıdır [32]. Bu iki yaklaşımın hibrit bir yapıda entegre edilmesiyle, hem tahmin doğruluğunun artırılması hem de modelin farklı sürüş koşulları altında daha sağlam ve genelleştirilebilir bir performans sergilemesi hedeflenmektedir.

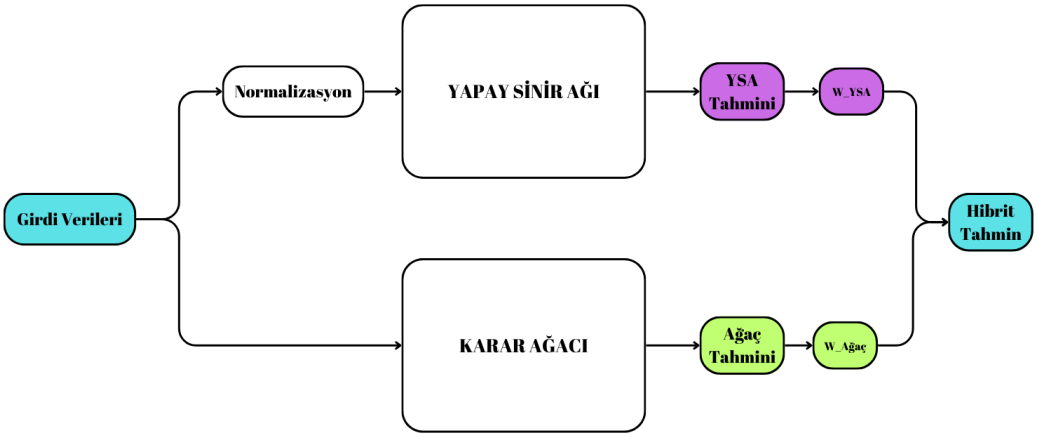
Geliştirilen hibrit modelin kavramsal yapısı Şekil 4.2'de sunulmuştur. Sistem, girdi verilerini iki ayrı yola yönlendirir: Veriler, YSA alt modeline beslenmeden önce Denklem 4.1 kullanılarak normalize edilirken, KA bileşenine **orijinal (normalize edilmemiş)** haliyle iletilir. Normalize edilmiş verilerle çalışan YSA, tek bir ağ yapısı içinde hem EMö hem de EMa torklarını tahmin eder. Normalize edilmemiş verileri alan KA bileşeni ise, her bir çıkış (EMö ve EMa) için ayrı ayrı optimize edilmiş iki bağımsız karar ağacından oluşmaktadır. Her iki yoldan elde edilen tahminler (YSA'dan $\hat{y}_{nn,\mathrm{EM}}$, $\hat{y}_{nn,\mathrm{EMa}}$ ve ilgili KA'lardan $\hat{y}_{tree,\mathrm{EM}}$, $\hat{y}_{tree,\mathrm{EMa}}$), optimize edilmiş ağırlık katsayıları (w_{nn} ve w_{tree}) kullanılarak Denklem 4.2 ve

4.3 gereğince birleştirilerek hibrit modelin nihai EMö ve EMa tork tahminleri oluşturulur.

$$\hat{y}_{\text{EMö}} = w_{nn} \cdot \hat{y}_{nn,\text{EMö}} + w_{tree} \cdot \hat{y}_{tree,\text{EMö}} \tag{4.2}$$

$$\hat{y}_{\text{EMa}} = w_{nn} \cdot \hat{y}_{nn,\text{EMa}} + w_{tree} \cdot \hat{y}_{tree,\text{EMa}} \tag{4.3}$$

Burada; $\hat{y}_{\text{EMö}}$ ve $\hat{y}_{EMa}$, hibrit modelin nihai EMö ve EMa tork tahminlerini; $\hat{y}_{nn,\text{EMö}}$ ve $\hat{y}_{nn,EMa}$, YSA'nın ürettiği tork tahminlerini; $\hat{y}_{tree,\text{EMö}}$ ve $\hat{y}_{tree,EMa}$, sırasıyla EMö ve EMa için eğitilmiş karar ağaçlarının tahminlerini ifade etmektedir. Ağırlık katsayıları w_{nn} (YSA ağırlığı) ve w_{tree} (karar ağacı ağırlığı) için $w_{nn} + w_{tree} = 1$ koşulu geçerlidir ve bu ağırlıklar optimizasyon sürecinde belirlenerek her iki tork tahmini için de aynı şekilde kullanılır.



Şekil 4.2 Önerilen hibrit Yapay Sinir Ağı - Karar Ağacı model mimarisi.

4.3 Hiperparametre Optimizasyonu Süreci

Hibrit modelin potansiyel performansını en üst düzeye çıkarmak ve aşırı uyum (overfitting) riskini en aza indirmek amacıyla, kapsamlı bir hiperparametre optimizasyon süreci yürütülmüştür. Bu süreç, hem YSA hem de KA alt modellerinin yapısal ve eğitim parametrelerini, ayrıca bu modellerin hibrit yapıdaki ağırlıklarını (w_{nn}, w_{tree}) optimize etmeyi içermektedir. Optimizasyonun temel amacı, validasyon veri seti üzerindeki tahmin hatasını (örneğin, EMö ve EMa için ortalama kök ortalama karesel hata - Root Mean Square Error, RMSE) minimize eden en uygun hiperparametre kombinasyonunu bulmaktır.

4.3.1 Optimizasyon Yaklaşımı ve Parametre Aralıkları

Bu çalışmada, özellikle yüksek boyutlu ve değerlendirmesi maliyetli (zaman alan) parametre uzaylarında etkinliği, kanıtlanmış bir yöntem olan Bayesian Optimizasyon yaklaşımı kullanılmıştır [33]. Bayesian optimizasyon, önceki denemelerden elde edilen bilgileri kullanarak bir sonraki optimum hiperparametre kombinasyonunu olasılıksal bir model aracılığıyla seçer, böylece rastgele veya grid arama yöntemlerine göre daha az sayıda deneme ile optimuma yakın sonuçlar elde edebilmeyi sağlar. Optimizasyon süreci, toplam 50 deneme (farklı hiperparametre seti) üzerinden gerçekleştirilmiştir.

Optimizasyon kapsamında incelenen temel hiperparametreler ve aralıkları aşağıda listelenmiştir:

YSA Parametreleri:

- Gizli katman sayısı: [1, 4]
- Katman başına nöron sayısı: [16, 256]
- Öğrenme oranı (α): [10^{-5}, 10^{-1}] (Logaritmik ölçekte)
- Mini-batch boyutu: [16, 256] (Genellikle 2'nin kuvvetleri)
- L2 düzenlileştirme katsayısı (λ): [10^{-10}, 10^{-3}] (Logaritmik ölçekte)
- Dropout oranı: [0, 0.7]

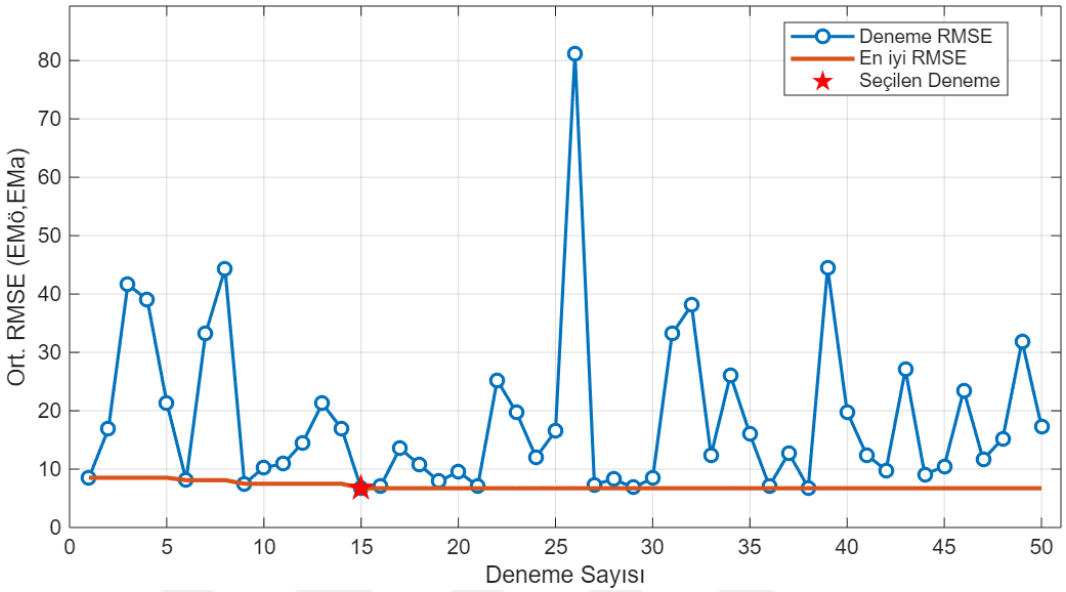
Karar Ağacı Parametreleri (EMö ve EMa ağaçları için ortak):

- Maksimum ağaç derinliği: [3, 25]
- Minimum dal bölünme örneklemi (min_samples_split): [2, 30]
- Minimum yaprak örneklemi (min_samples_leaf): [1, 15]
- Maksimum özellik oranı (max_features): [0.1, 1.0] (Bölünme için rastgele seçilecek özelliklerin oranı)

Hibrit Model Parametreleri:

- YSA ağırlığı (w_{nn}): [0.3, 0.95]
- Karar ağacı ağırlığı (w_{tree}): $1 - w_{nn}$

Her bir hiperparametre kombinasyonu için hibrit model eğitilmiş ve validasyon seti üzerindeki performansı (ortalama RMSE) kaydedilmiştir. Optimizasyon sürecinin ilerleyişi Şekil 4.3'de gösterilmektedir.



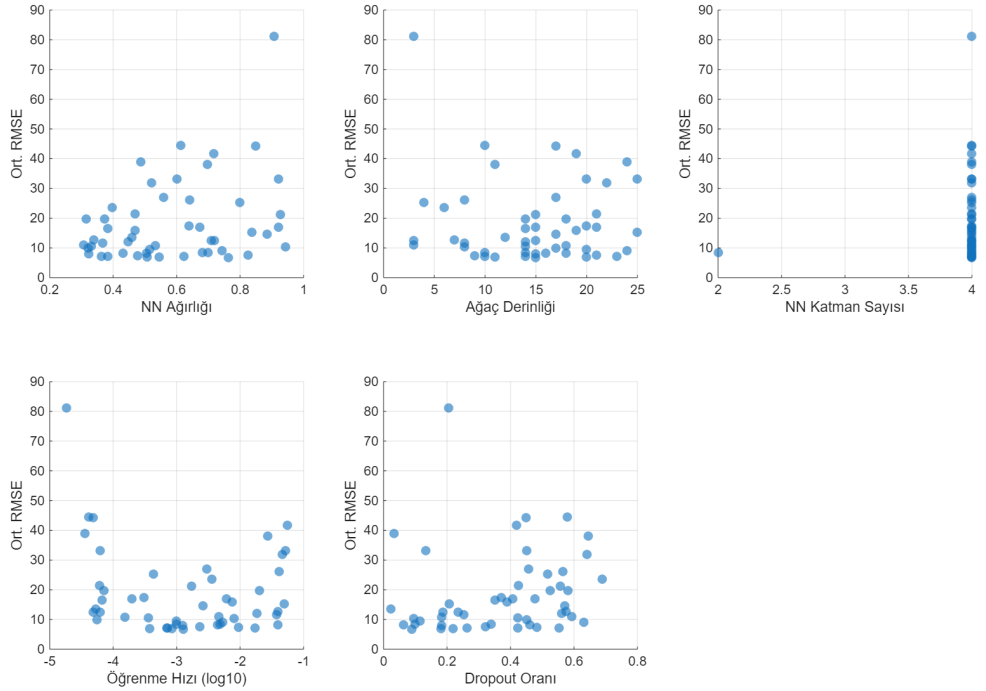
Şekil 4.3 Bayesian optimizasyon sürecinin ilerleyişi: Her denemedeki validasyon hatası (Ort. RMSE) ve o ana kadar bulunan en iyi hata değeri.

Şekil 4.3 incelendiğinde, 50 deneme boyunca validasyon hatasının genel bir düşüş eğilimi gösterdiği ve optimizasyonun giderek daha iyi performans gösteren hiperparametre bölgelerini keşfettiği görülmektedir. Kırmızı çizgi, her adımdaki en iyi (minimum) hatayı temsil ederken, mavi noktalar her bir denemenin sonucunu göstermektedir. Belirli bir deneme (yıldız ile işaretli) en düşük validasyon hatasını vererek optimum konfigürasyon olarak seçilmiştir.

Çeşitli hiperparametrelerin model performansı (Ort. RMSE) üzerindeki bireysel etkileri Şekil 4.4'de görselleştirilmiştir.

Bu grafiklerden elde edilen temel gözlemler şunlardır:

- **NN Ağırlığı (w_{nn}):** Hibrit modeldeki YSA bileşeninin ağırlığı arttıkça validasyon hatasında belirgin bir örüntü olmamakla birlikte, en düşük hatalar genellikle 0.3-0.6 aralığında gözlenmiştir. Bu, karar ağacı bileşeninin de model performansına önemli katkı sağladığı izlenimini vermektedir. (Not: Optimize edilen nihai değer 0.7631 çıkmıştır, bu durum grafik ile bir miktar çelişiyor gibi görünse de, diğer parametrelerle etkileşim sonucu bu değerin optimum olması imkan dahilindedir.)
- **Ağaç Derinliği:** Karar ağaçlarının optimum derinliğinin 5 ile 25 arasında



Şekil 4.4 Seçili hiperparametrelerin validasyon hatası (Ort. RMSE) üzerindeki etkileri.

olduğu görülmektedir. Daha sığ ağaçlar yetersiz öğrenmeye (underfitting), çok derin ağaçlar ise aşırı uyuma (overfitting) yol açabilmektedir.

- **NN Katman Sayısı:** 4 gizli katmana sahip YSA mimarilerinin genellikle daha düşük hata verdiği gözlemlenmiştir. Bu, problemin karmaşıklığının daha derin ağ yapıları gerektirdiğini işaret etmektedir.
- **Öğrenme Hızı:** Logaritmik ölçekte, 10^{-3} ile 10^{-2} (yani -3 ile -2 arası) arasındaki öğrenme hızlarının genellikle daha iyi sonuçlar verdiği görülmektedir. Bu aralığın dışındaki değerler, ya çok yavaş yakınsamaya ya da optimizasyon sürecinin kararsızlaşmasına neden olabilmektedir.
- **Dropout Oranı:** Aşırı uyumu engellemek için kullanılan dropout oranının 0.2-0.6 aralığında optimal olduğu gözlenmiştir. (Not: Optimize edilen nihai değer 0.0887'dir, bu da düşük bir dropout oranının yeterli olduğunu veya diğer düzenlileştirme yöntemleriyle (L2) dengelendiğini göstermektedir.)

4.3.2 Optimize Edilmiş Hiperparametreler

Bayesian optimizasyon süreci sonucunda, validasyon seti üzerinde en düşük hatayı veren hiperparametre konfigürasyonu belirlenmiş ve Tablo 4.2'de sunulmuştur.

Tablo 4.2 Bayesian optimizasyonu ile belirlenen optimum hiperparametre değerleri.

Parametre	Değer
YSA Parametreleri	
Gizli katman boyutları	[150, 151, 122, 85]
Öğrenme oranı	0.0013
L2 düzenlileştirme (λ)	6.9085e-10
Mini-batch boyutu	49
Dropout oranı	0.0887
Karar Ağacı Parametreleri (Ortak)	
Maksimum ağaç derinliği	15
Min. dal bölünme örneklemi	24
Min. yaprak örneklemi	1
Maksimum özellik oranı	0.5184
Hibrit Model Parametreleri	
YSA ağırlığı (w_{nn})	0.7631
Karar ağacı ağırlığı (w_{tree})	0.2369

Optimizasyon sonucunda elde edilen yapıya göre; YSA modeli, sırasıyla 150, 151, 122 ve 85 nöron içeren dört gizli katmandan oluşmaktadır. Karar ağaçları için ise maksimum derinlik, dallanma ve yaprak düğüm koşulları Tablo 4.2'deki gibi optimize edilmiştir. Hibrit modelde YSA'nın katkısı %76.31, karar ağaçlarının katkısı ise %23.69 olarak belirlenmiştir.

4.4 Hibrit Modelin Yapısal Detayları

4.4.1 YSA Bileşeni: Mimari ve Aktivasyon Fonksiyonları

Optimize edilmiş hiperparametreler doğrultusunda tasarlanan YSA bileşeni, derin ileri beslemeli (feedforward) bir sinir ağı mimarisine sahiptir ve aşağıdaki katmanlardan oluşur:

- **Giriş Katmanı ('FeatureInputLayer'):** 7 adet nörondan oluşur ve normalize edilmiş 7 giriş değişkenine karşılık gelir.
- **Gizli Katmanlar:** Toplam **dört** adet gizli katman bulunmaktadır. Her gizli katman bloğu, öğrenilen özellik temsillerini bir sonraki katmana aktarmadan önce doğrusal olmayan dönüşümler ve düzenlileştirme uygular:
  - **1. Gizli Blok:** Tam Bağlantılı Katman (150 nöron) + ReLU Aktivasyon Katmanı + Dropout Katmanı (0.0887 oranında).
  - **2. Gizli Blok:** Tam Bağlantılı Katman (151 nöron) + ReLU Aktivasyon Katmanı + Dropout Katmanı (0.0887 oranında).

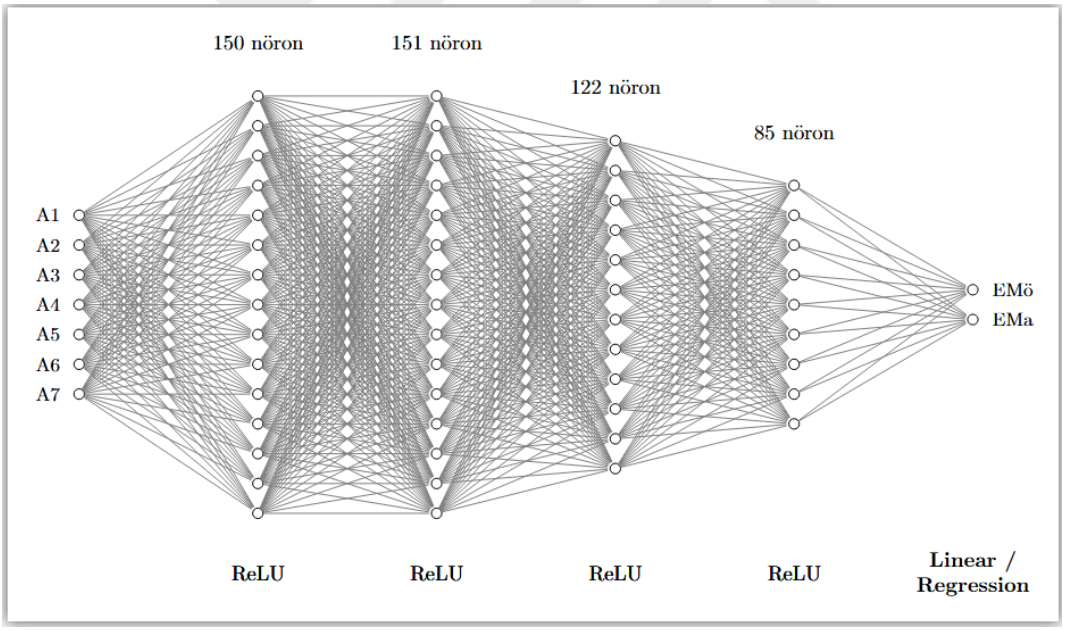
– **3. Gizli Blok:** Tam Bağlantılı Katman (122 nöron) + ReLU Aktivasyon Katmanı + Dropout Katmanı (0.0887 oranında).

– **4. Gizli Blok:** Tam Bağlantılı Katman (85 nöron) + ReLU Aktivasyon Katmanı + Dropout Katmanı (0.0887 oranında).

Bu katmanlar, giriş verilerinden hiyerarşik olarak giderek daha karmaşık özellikler çıkarmayı hedefler.

- **Çıkış Katmanı:** Ağın son bölümü olup iki ardışık bileşenden oluşur: Önce, son gizli katmandan gelen özellikleri 2 hedef çıktıya (EMö, EMa) eşleyen 2 nöronlu bir **Tam Bağlantılı Katman ('FullyConnectedLayer')** lineer dönüşüm uygular. Ardından, **Regresyon Katmanı ('RegressionOutputLayer')**, bu 2 değeri alarak regresyon görevi için standart olan Ortalama Karesel Hata (MSE) gibi bir kayıp fonksiyonu ile model hatasını hesaplar.

YSA modelinin katmanlı yapısı Şekil 4.5'de şematik olarak gösterilmiştir.



Şekil 4.5 Optimize edilmiş YSA modelinin mimarisi.

Gizli katmanlarda yaygın olarak kullanılan ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, $f(x) = \max(0, x)$ şeklinde tanımlanır ve gradyanların sönümlenmesi (vanishing gradients) sorununu hafifletme, hesaplama verimliliği artırma gibi faydalar sunar [34]. Çıkış katmanı olarak kullanılan 'RegressionOutputLayer', regresyon problemlerinde doğrudan sürekli değerleri tahmin etmek ve genellikle Ortalama Karesel Hata (MSE) gibi bir kayıp fonksiyonu ile çalışmak üzere tasarlanmıştır. Çıkıştan hemen önceki tam bağlantılı katman ise

(2 nöronlu olan), özellik temsillerini çıkış boyutuna uygun hale getiren bir lineer eşleme sağlar.

4.4.2 Karar Ağacı Bileşeni: Yapı ve Parametreler

Hibrit modelin KA bileşeni, her bir çıkış değişkeni (EMö ve EMa) için bağımsız olarak eğitilmiş iki adet regresyon ağacından meydana gelir. Bu ağaçlar, Tablo 4.2'de belirtilen optimize edilmiş ortak hiperparametreleri kullanır:

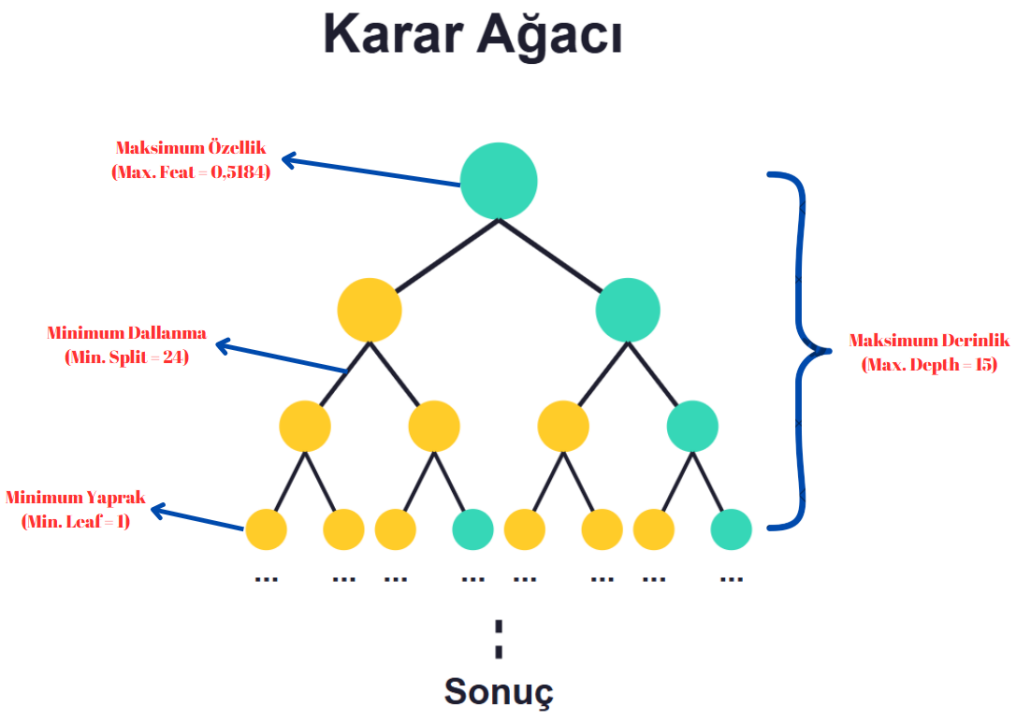
- Maksimum derinlik: 15 seviye.
- Minimum dallanma örneklemi: Bir düğümün bölünebilmesi için en az 24 veri noktası gereklidir.
- Minimum yaprak örneklemi: Bir yaprak düğümün oluşabilmesi için en az 1 veri noktası bulunmalıdır.
- Maksimum özellik oranı: Her bir bölünme noktasında, en iyi bölünmeyi aramak için kullanılacak giriş özelliklerinin oranı %51.84'tür.

Karar ağaçları, veri setini ardışık olarak bölerek, belirli koşulları sağlayan alt bölgeler oluşturur ve her bölge için sabit bir tahmin değeri (o bölgedeki örneklerin ortalaması) atar. Bu yapı, özellikle belirli giriş aralıklarında farklı davranışlar sergileyen veya eşik değerlerine duyarlı sistemleri modellemede etkilidir. Şekil 4.6, karar ağacı modelinin genel hiyerarşik yapısını temsil etmektedir.

4.4.3 Eğitim Parametreleri ve Algoritmaları

Hibrit modelin YSA ve KA bileşenleri, optimize edilmiş hiperparametreler ışığında, MATLAB ortamında eğitilmiştir. Eğitim süreci için belirlenen temel parametreler ve algoritmalar şunlardır:

- **Optimizasyon Algoritması (YSA için):** Adam (Adaptive Moment Estimation) [35]. Adam, birinci ve ikinci moment tahminlerini kullanarak her bir parametre için adaptif öğrenme oranları hesaplayan, gradyan tabanlı verimli bir optimizasyon algoritmasıdır.
- **Maksimum Epoch Sayısı:** 500. Modelin eğitim verisi üzerinden geçiş sayısı üst sınırı.



Şekil 4.6 Karar ağacı modelinin genel yapısı (EMö ve EMa için ayrı ağaçlar).

- **Mini-batch Boyutu:** 49. Her bir iterasyonda gradyan hesaplaması için kullanılan örnek sayısı.
- **Başlangıç Öğrenme Oranı:** 0.0013. Adam algoritmasının başlangıç öğrenme oranı.
- **Ağırlık Çürümesi (L2 Düzenlileştirme):** 6.9085e-10. Aşırı uyumu engellemek için YSA ağırlıklarına uygulanan L2 ceza terimi katsayısı.
- **Validasyon Sabır Parametresi (Erken Durdurma):** 20 epoch. Validasyon seti üzerindeki performans (kayıp fonksiyonu değeri) 20 ardışık epoch boyunca iyileşme göstermezse, aşırı uyumu önlemek amacıyla eğitimin otomatik olarak sonlandırılmasını sağlayan kriter [36].
- **Kayıp Fonksiyonu:** Ortalama Karesel Hata (Mean Squared Error - MSE). Hem EMö hem de EMa tahmin hatalarının karelerinin ortalaması alınarak hesaplanır ve minimize edilmeye çalışılır.

Karar ağaçları ise standart regresyon ağacı algoritmaları (örneğin, CART) kullanılarak, ilgili hiperparametre kısıtları altında, MSE'yi minimize edecek şekilde eğitilmiştir.

4.5 Performans Değerlendirmesi ve Sonuçlar

Geliştirilen ve optimize edilen hibrit modelin performansı, hem eğitim sürecinde kullanılmayan dahili test verileri hem de tamamen bağımsız sürüş senaryoları üzerinde çeşitli metrikler üzerinden detaylı bir şekilde değerlendirilmiştir.

4.5.1 Dahili Test Performansı

Eğitim verisinden ayrılan dahili test seti (%15), modelin eğitim sırasında görmediği ancak aynı veri dağılımından gelen örnekler üzerindeki performansını yansıtır. Bu aşamadaki değerlendirmeler, modelin eğitim verisine ne ölçüde uyum sağladığını ve aşırı uyum durumunu kontrol etmek için önemlidir. Dahili test seti üzerinde elde edilen performans metrikleri Tablo 4.3'da özetlenmiştir.

Tablo 4.3 Hibrit modelin dahili test seti üzerindeki performans metrikleri.

Metrik	EMö Değeri	EMa Değeri
MSE	57.8213	40.3823
RMSE	6.6008	5.0987
MAE	5.2924	2.8369
R^2	0.9720	0.9722

Tablo 4.3'da görüldüğü üzere, model dahili test setinde her iki çıkış (EMö ve EMa) için de oldukça yüksek R^2 değerleri (0.97'nin üzerinde) ve düşük hata metrikleri (RMSE < 7) sergilemektedir. Bu sonuçlar, modelin eğitim verisindeki örüntüleri başarıyla öğrendiğini ve eğitim setine iyi uyum sağladığını göstermektedir. Modelin genelleme kabiliyetinin asıl testi ise bağımsız senaryolar üzerinde yapılan değerlendirmelerdir. Dahili test sonuçları, modelin optimizasyon sürecinin başarısını teyit etmiş ancak daha kritik olan genelleme performansının değerlendirilmesi için bağımsız test sonuçlarına odaklanılmıştır.

4.5.2 Bağımsız Test Senaryoları Üzerindeki Performans

Modelin genelleme kabiliyetini ve eğitim verisi dışında karşılaşabileceği koşullardaki etkinliğini ölçmek amacıyla, eğitim ve validasyon süreçlerinde hiç kullanılmamış olan 6 adet bağımsız test senaryosu (Senaryo 4, 9, 24, 25, 29, 30) kullanılmıştır. Bu senaryolar üzerindeki nicel performans değerlendirmesi Tablo 4.4'de sunulan metriklerle yapılmıştır.

Tablo 4.4'deki sonuçlar, hibrit modelin tüm bağımsız senaryolarda genel olarak çok yüksek bir performans sergilediğini ortaya koymaktadır. Ortalama RMSE değerleri EMö için 6.6 Nm, EMa için ise 5 Nm mertebesindedir. Determinasyon katsayısı (R^2) değerlerinin her iki tork tahmini için de ortalama 0.97'nin üzerinde olması,

Tablo 4.4 Bağımsız test senaryolarına ait hibrit modelin performans metrikleri.

Senaryo	**Çıktı**	**Performans Metrikleri**			
		MSE	**RMSE**	**MAE**	**R^2**
Senaryo 4	EMö	87.3868	9.3481	6.6158	0.9597
	EMa	131.2672	11.4572	5.9372	0.9119
Senaryo 9	EMö	181.4025	13.8348	12.3659	0.9318
	EMa	83.2858	9.1261	5.1275	0.9434
Senaryo 24	EMö	17.9908	4.2416	3.7260	0.9977
	EMa	6.8053	2.6087	1.6139	0.9985
Senaryo 25	EMö	19.0283	4.3621	3.0739	0.9937
	EMa	14.4299	3.7987	1.7736	0.9930
Senaryo 29	EMö	19.6800	4.4362	3.9827	0.9601
	EMa	2.8988	1.7026	1.1539	0.9909
Senaryo 30	EMö	11.4395	3.3822	1.9901	0.9887
	EMa	3.6066	1.8991	1.4153	0.9958
Ortalama	**EMö**	**57.8213**	**6.6008**	**5.2924**	**0.97195**
	EMa	**40.3823**	**5.0987**	**2.8369**	**0.97224**

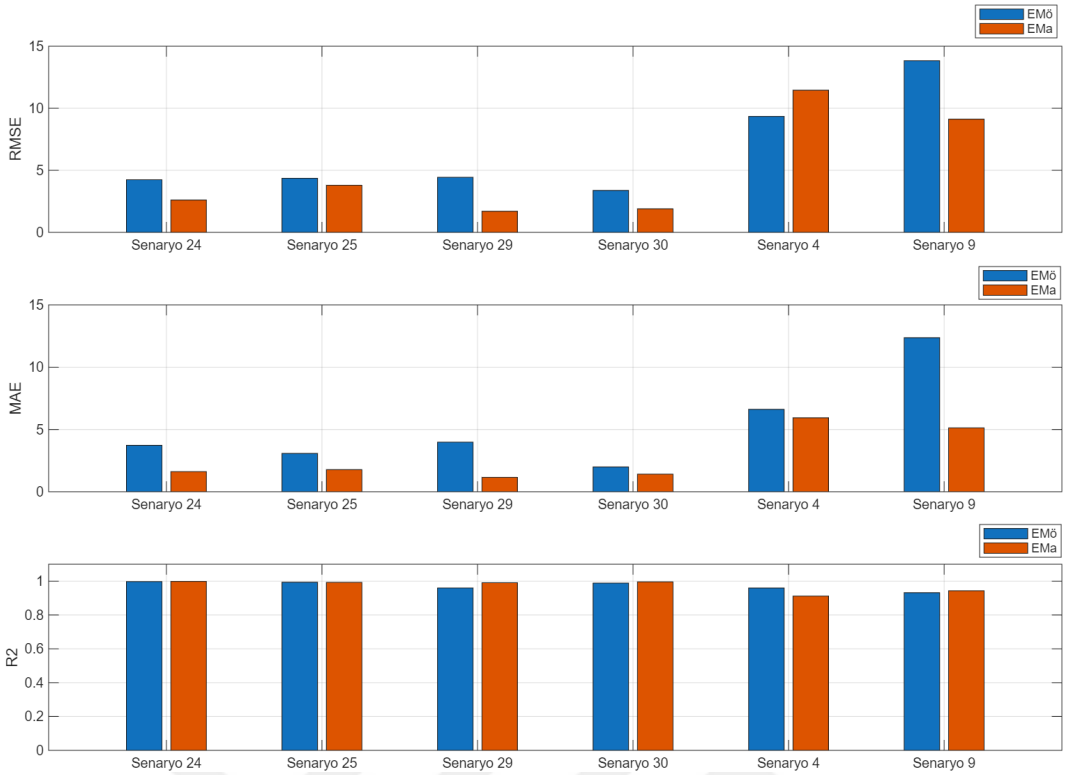
modelin hedef torklardaki değişimin çok büyük bir kısmını başarıyla açıkladığını göstermektedir. Senaryo bazında incelendiğinde, modelin çoğu senaryoda R^2 değerlerinin 0.99 civarında veya üzerinde olmasıyla mükemmele yakın bir uyum sergilediği; buna karşın özellikle Senaryo 9'da hata oranlarının (RMSE ve MAE) diğerlerine göre belirgin şekilde daha yüksek olduğu gözlemlenmektedir. Senaryo 4'ün EMa tahmini de nispeten daha yüksek bir RMSE değerine sahiptir. Bu durum, muhtemelen bu senaryoların içerdiği zorlayıcı koşullar (düşük sürtünme, yüksek eğim, düşük SOC vb.) nedeniyle olabilir.

Bağımsız test senaryolarındaki **performans metriklerinin senaryo bazında görsel bir özetini sunmak** ve karşılaştırmayı kolaylaştırmak amacıyla hata metrikleri (RMSE, MAE) ve R^2 değerleri Şekil 4.7'de çubuk grafiklerle gösterilmiştir.

Bu şekil, Tablo 4.4'deki sayısal bulguları görsel olarak desteklemektedir. Üstteki grafikler, her senaryo için hesaplanan RMSE ve MAE değerlerini sergileyerek Senaryo 4 ve 9'daki görece yüksek hataları belirginleştirirken, diğer senaryolardaki düşük hata seviyelerini göstermektedir.

Modelin bu bağımsız senaryolardaki **dinamik davranışını ve zaman içindeki tahmin doğruluğunu** görmek amacıyla, DP referans tork değerleri ile model tahminleri Şekil 4.8'de karşılaştırılmıştır.

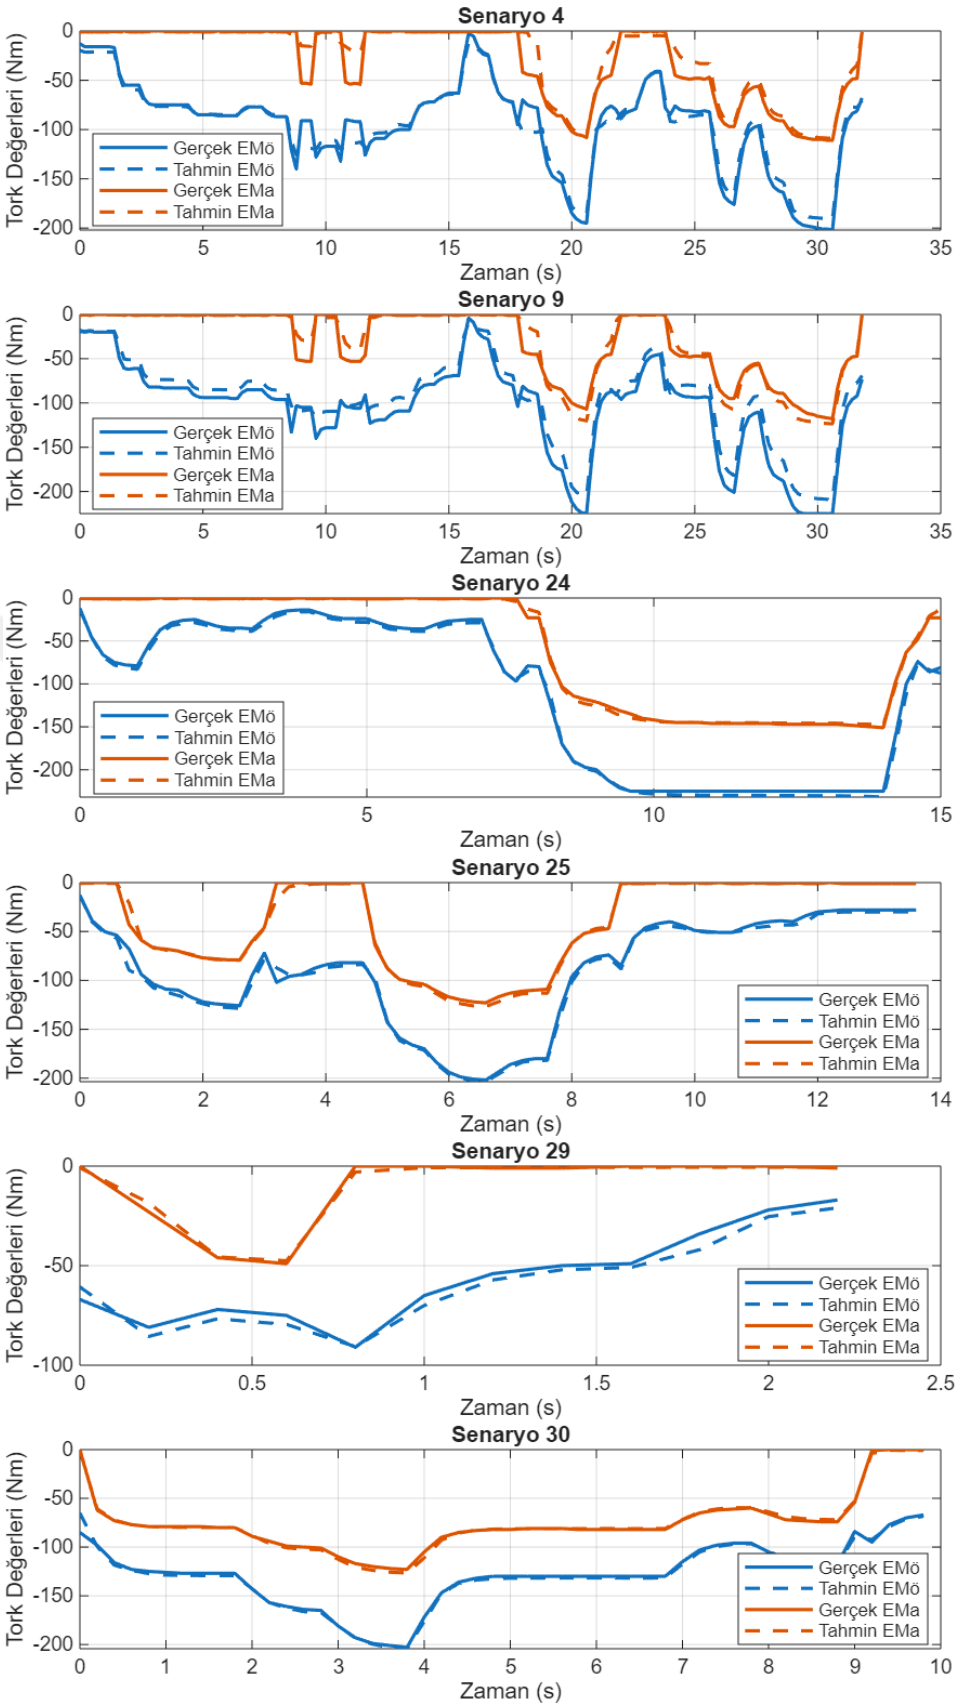
Şekil 4.8'deki grafikler, model tahminlerinin (kırmızı kesikli çizgi) DP referans tork değerlerini (mavi sürekli çizgi) yakından takip ettiğini doğrulamaktadır. Tablo 4.4 ve Şekil 4.7 ile uyumlu olarak, Senaryo 30'daki tahminlerin gerçek değerlere



Şekil 4.7 Bağımsız test senaryolarında hata metrikleri (RMSE, MAE) ve determinasyon katsayısı (R^2) değerlerinin karşılaştırmalı gösterimi.

olan yakınlığı dikkat çekerken, Senaryo 9 gibi daha yüksek hatalı senaryolarda, özellikle ani tork değişimlerinde veya pik noktalarda tahminlerde küçük sapmalar veya gecikmelerin meydana geldiği görülmektedir. Ancak, genel uyumun yüksek olması modelin dinamik koşullara adapte olabildiğini göstermektedir.

Sonuç olarak, bağımsız test senaryoları üzerinde yapılan bu kapsamlı değerlendirmeler, geliştirilen hibrit YSA-Karar Ağacı modelinin, eğitim verisi dışında kalan farklı sürüş koşulları ve araç parametreleri altında dahi, ön ve arka elektrik motorları için optimal rejeneratif frenleme torklarını yüksek doğruluk, güvenilirlik ve iyi bir genelleme kabiliyeti ile tahmin edebildiğini güçlü bir şekilde ortaya koymaktadır.



Şekil 4.8 Bağımsız test senaryoları: DP referans (Gerçek) ve hibrit model tahminleri (Tahmin edilen) EMö ve EMa tork değerlerinin zaman içindeki değişimi.

5
HİBRİT KONTROL MODELİNİN SİMULASYON TABANLI PERFORMANS ANALİZİ VE KARŞILAŞTIRILMASI

Bu bölümde, Bölüm 4'te geliştirilen ve çevrimdışı olarak performansı doğrulanan hibrit YSA - KA modelinin, tam bir elektrikli araç modeline entegre edilmiş halinin performansı kapsamlı bir şekilde değerlendirilmektedir. Bölümün temel amacı, önerilen hibrit kontrol stratejisinin farklı sürüş koşulları ve parametreler altında enerji geri kazanım verimliliğini ölçmek, modelin sağlamlığını test etmek ve bunu iki farklı referans kontrol yöntemiyle karşılaştırmaktır.

Karşılaştırılacak kontrol stratejileri şunlardır:

1. **Hibrit Model Kontrolü:** Bölüm 4'te geliştirilen, anlık koşullara (hız, fren talebi, SOC, araç ağırlığı, yol eğimi vb.) göre EMö ve EMa torklarını dinamik olarak belirleyen optimize edilmiş model.
2. **Sabit Oranlı Tork Paylaşımı:** Frenleme tork talebinin ön ve arka akslar arasında önceden belirlenmiş sabit bir oranla (%70 Ön - %30 Arka) paylaştırıldığı kural tabanlı bir yöntem.
3. **Baseline Kontrol (Simulink Varsayılan):** Karşılaştırma için temel alınan bu yöntem, kullanılan Simulink araç modelinin kendi içerisindeki varsayılan rejeneratif frenleme tork dağıtım stratejisidir. Bu stratejiye göre, toplam fren torku talebi öncelikle ön elektrik motorunun anlık maksimum rejeneratif frenleme kapasitesine kadar bu motora yönlendirilir. Talep, ön motorun kapasitesini aştığında, aşan tork miktarı (kendi rejeneratif frenleme limiti dahilinde kalmak kaydıyla) arka elektrik motoru tarafından karşılanmaya çalışılır. Elektrik motorlarının üretebildiği toplam rejeneratif tork, sürücünün talebini karşılamaya yetmezse, aradaki fark mekanik fren sistemi tarafından tamamlanır.

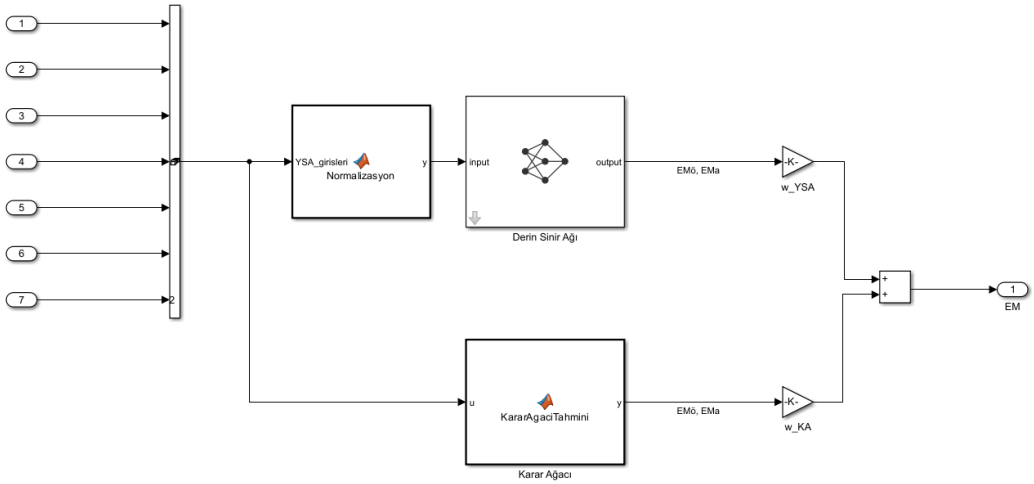
Performans karşılaştırmasında ana odak noktası, farklı senaryolar boyunca batarya şarj durumundaki (SOC) değişim ve dolayısıyla rejeneratif frenleme yoluyla geri kazanılan enerjinin maksimizasyonudur. Modelin performansını, tablo 4.1'de bulunan eğitim verilerine yakın koşullardan başlayarak giderek zorlaşan ve eğitim aralığının dışına çıkan durumlarda sistematik olarak değerlendirmek amacıyla dört farklı test senaryosu tasarlanmıştır. Bu senaryolarda UDDS, NYCC ve WLTP Class 3 gibi standart sürüş çevrimleri kullanılmıştır.

5.1 Simülasyon Ortamı ve Model Entegrasyonu

Tüm simülasyonlar MATLAB/Simulink ortamında gerçekleştirilmiştir. Kullanılan elektrikli araç modeli, Bölüm 2'de açıklanan temel bileşenleri içermektedir.

5.1.1 Hibrit Modelin Entegrasyonu

Geliştirilen hibrit kontrol modelinin simülasyon modeline entegrasyonu Şekil 5.1'de gösterilen yapı ile gerçekleştirilmiştir.

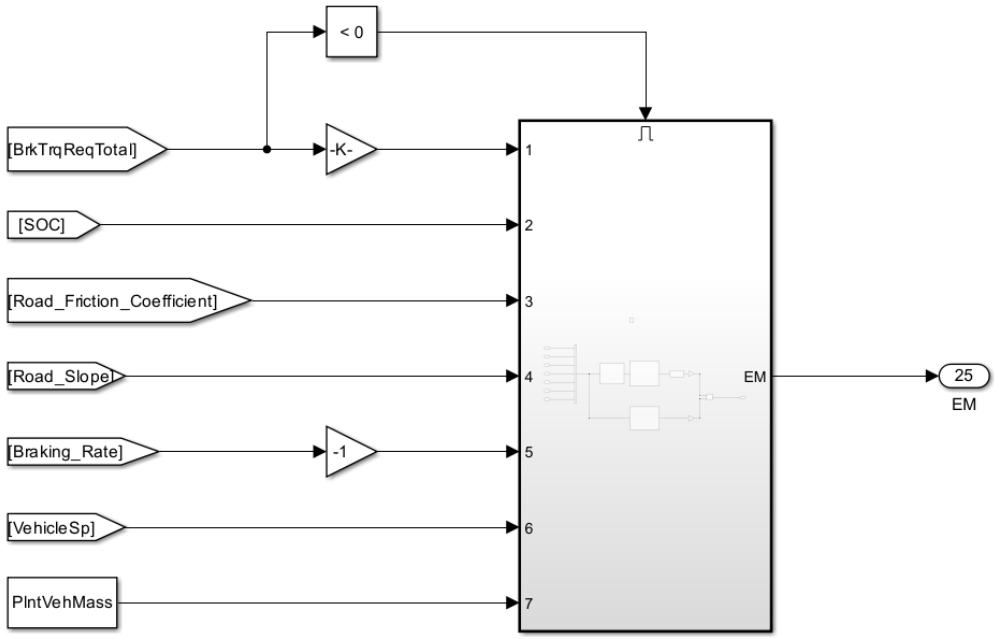


Şekil 5.1 Hibrit kontrol modelinin araç simülasyon modeline entegrasyon yapısı.

Entegrasyon sürecinde; simülasyon modeli tarafından sağlanan anlık giriş değişkenleri (toplam fren torku talebi, SOC, hız, araç ağırlığı, yol eğimi, sürtünme katsayısı vb.), hibrit modelin iki bileşenine farklı şekillerde iletilir. YSA alt modeline gönderilmeden önce bu girişler, eğitim aşamasında hesaplanan X_{min} ve X_{max} değerleri kullanılarak Denklem 4.1 uyarınca normalize edilir. Aynı anda, bu girişlerin **orijinal (normalize edilmemiş)** hali, doğrudan Karar Ağacı (KA) alt modellerine (biri EMö, diğeri EMa için) beslenir. YSA'dan elde edilen normalize edilmiş tahminler ($\hat{y}_{nn,\text{EMö}}$, $\hat{y}_{nn,EMa}$) ile Karar Ağaçlarından elde edilen tahminler ($\hat{y}_{tree,\text{EMö}}$, $\hat{y}_{tree,EMa}$), sırasıyla optimize edilmiş w_{nn} ve w_{tree} ağırlıkları ile çarpılıp

toplanarak nihai EMö ve EMa tork komutları üretilir. Bu komutlar, simülasyon modelindeki elektrik motoru alt modellerine gönderilir.

Modelin sadece frenleme durumlarında aktif olmasını ve gereksiz hesaplama yükünü önlemek amacıyla, Şekil 5.2'de gösterilen bir "enabled subsystem" (etkinleştirilmiş alt sistem) yapısı kullanılmıştır. Bu yapı, aracın frenleme yaptığı anlarda hibrit modeli etkinleştirmekte, diğer durumlarda ise pasif tutmaktadır. Modelin çıktıları olan EMö ve EMa torkları da benzer bir mantıkla, yalnızca frenleme aktifken ilgili motor kontrol ünitelerine iletilmektedir.



Şekil 5.2 Hibrit modelin sadece frenleme durumlarında aktive edilmesi için kullanılan etkinleştirilmiş alt sistem mantığı.

5.1.2 Referans Kontrol Stratejilerinin Uygulanması

Karşılaştırma amacıyla kullanılan diğer iki kontrol stratejisi şu şekilde uygulanmıştır:

- **Sabit Oranlı Tork Paylaşımı:** Toplam fren torku talebi, Simulink içinde basit bir kazanç bloğu ile ön ve arka motorlar için belirlenen sabit oranlara göre (%70 Ön, %30 Arka) dağıtılmıştır. Her motor için hesaplanan tork, motorun anlık maksimum rejeneratif frenleme tork limitini aşmayacak şekilde sınırlandırılmıştır.
- **Baseline Kontrol (Simulink Varsayılan):** Tanımı yukarıda yapıldığı gibidir.

5.2 Simülasyon Sonuçları ve Karşılaştırmalı Analiz

Bu bölümde, tanımlanan üç kontrol stratejisinin (Hibrit, Sabit Oran, Baseline) performansı, aşağıda detaylandırılan dört farklı senaryo altında SOC değişimleri üzerinden karşılaştırılacaktır. Senaryolar, hibrit modelin eğitim koşullarına uygunluktan başlayarak, parametre değişiklikleri ve eğitim aralığı dışı koşullara doğru ilerleyerek modelin adaptasyon ve genelleme yeteneğini test etmek üzere tasarlanmıştır.

5.2.1 Senaryo 1: Eğitim Koşullarında UDDS Çevrimi Performansı

Bu ilk senaryoda, hibrit modelin performansı, eğitiminde kullanılan parametre setine çok yakın koşullar altında değerlendirilmiştir. Şehir içi sürüşü temsil eden UDDS çevrimi kullanılmış ve simülasyon parametreleri aşağıdaki gibi belirlenmiştir:

- Sürüş Çevrimi: UDDS
- Araç Ağırlığı: 2400 kg
- Yol Eğimi: 0 derece (%0)
- Yol Sürtünme Katsayısı: 0.9
- Başlangıç SOC: %60

Bu testin amacı, modelin öğrenmiş olduğu "ideal" koşullar altında referans yöntemlere kıyasla ne kadar iyi performans gösterdiğini doğrulamaktır.

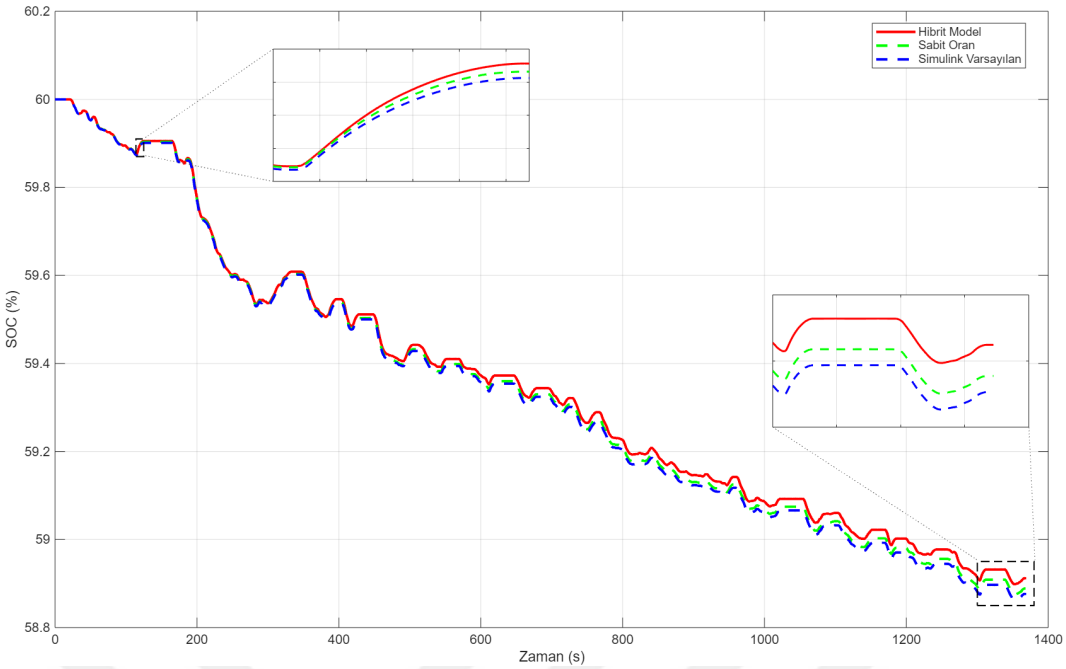
Şekil 5.3'de bu senaryo için üç kontrol stratejisinin SOC değişimleri karşılaştırılmaktadır.

Tablo 5.1, simulasyon sonundaki nicel SOC sonuçlarını ve referans alınan Simulink varsayılan stratejiye göre elde edilen iyileşme oranlarını özetlemektedir.

Tablo 5.1 Senaryo 1 (UDDS, Eğitim Koşulları) sonunda elde edilen SOC sonuçları.

Kontrol Stratejisi	Nihai SOC (%)	Kazanılan SOC (%)	İyileştirme (%)
Hibrit Model	58.9122	0.0357	3.18
Sabit Oran (%70-%30)	58.8887	0.0122	1.09
Baseline (Varsayılan)	58.8765	-	-

Şekil 5.3'den de görüleceği üzere, hibrit model (kırmızı çizgi) tüm çevrim boyunca diğer iki stratejiye kıyasla daha yüksek bir SOC seviyesini korumaktadır. Grafikteki



Şekil 5.3 Senaryo 1 (UDDS, Eğitim Koşulları): kontrol stratejilerinin SOC karşılaştırması

yakınlaştırılmış bölgeler (inset), özellikle rejeneratif frenleme anlarındaki farkı belirginleştirmektedir. Örneğin, yaklaşık 130. saniye civarındaki frenlemede, hibrit modelin SOC'deki artışı Sabit Oran (yeşil kesikli) ve Baseline (mavi kesikli) yöntemlerine göre daha fazladır. Bu görsel gözlem, Tablo 5.1'deki sayılarla da desteklenmektedir; hibrit model, çevrim sonunda Baseline'a göre %3.18'lik bir SOC iyileşmesi sağlamıştır. Sabit oranlı yöntem ise %1.09 ile daha mütevazı bir iyileşme göstermiştir. Bu sonuçlar, modelin eğitim verilerine uygun koşullarda beklendiği gibi çalıştığını ve enerji geri kazanımını optimize ettiğini göstermektedir.

5.2.2 Senaryo 2: Farklı Araç Ağırlığı ile NYCC Çevrimi Performansı

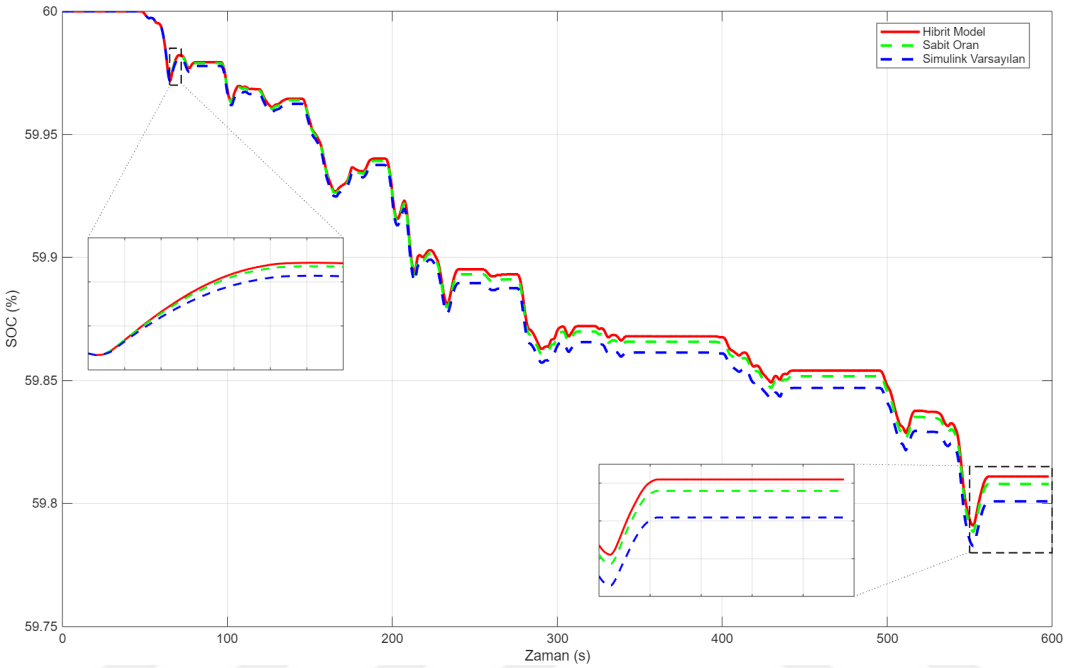
İkinci senaryo ise, modelin farklı bir sürüş çevrimi (daha yoğun dur-kalk içeren NYCC) ve eğitimde kullanılan UDDS senaryosundan farklı bir araç hızı ve ivme profilleri altındaki performansını inceler. Diğer parametreler eğitim koşullarına benzer tutulmuştur.

- Sürüş Çevrimi: NYCC
- Araç Ağırlığı: 2000 kg
- Yol Eğimi: 0 derece (%0)
- Yol Sürtünme Katsayısı: 0.9

- Başlangıç SOC: %60

Bu senaryo, modelin farklı bir sürüş dinamiğine ne kadar iyi adapte olduğunu göstermeyi amaçlamaktadır.

Şekil 5.4'da bu senaryoya ait SOC karşılaştırmaları sunulmuştur.



Şekil 5.4 Senaryo 2 (NYCC, Farklı Ağırlık): Kontrol stratejilerinin SOC karşılaştırması.

Nicel sonuçlar Tablo 5.2'de verilmiştir.

Tablo 5.2 Senaryo 2 (NYCC, Farklı Ağırlık) sonunda elde edilen SOC sonuçları.

Kontrol Stratejisi	Nihai SOC (%)	Kazanılan SOC (%)	İyileştirme (%)
Hibrit Model	59.8110	0.0101	5.06
Sabit Oran (%70-%30)	59.8079	0.0070	3.54
Baseline (Varsayılan)	59.8009	-	-

NYCC çevrimi, UDDS'ye göre daha sık ve düşük hızlı frenlemeler içermektedir. Şekil 5.4'de görüldüğü gibi, hibrit model bu yoğun dur-kalk koşullarında da üstünlüğünü korumaktadır. Özellikle 70. saniye civarındaki ve çevrim sonundaki yakınlaştırılmış bölgeler, hibrit modelin rejeneratif frenleme ile SOC'yi diğer yöntemlere göre daha etkin bir şekilde artırdığını göstermektedir. Tablo 5.2'deki sonuçlar bu durumu teyit etmekte ve hibrit modelin Baseline'a göre %5.06 gibi dikkate değer bir iyileşme sağladığını ortaya koymaktadır. Bu oran, Senaryo 1'deki iyileşmeden daha yüksektir, bu da geliştirlen modelin özellikle sık frenleme içeren şehir içi çevrimlerde avantajının daha fazla olabileceği izlenimini vermektedir.

Modelin farklı araç hızı ve ivme profiline sahip bir sürüş çevrimine adaptasyon yeteneği bu senaryoda açıkça görülmektedir.

5.2.3 Senaryo 3: Eğitim Aralığında Farklı Parametrelerle NYCC Çevrimi (İnterpolasyon Testi)

Üçüncü senaryo, hibrit modelin *interpolasyon* yeteneğini, yani eğitim veri setinde doğrudan bulunmayan ancak parametrelerin, eğitimde kullanılan minimum ve maksimum değerler arasında olduğu durumdaki performansını test eder. Bunun için yine NYCC çevrimi kullanılmış ve başlangıç SOC değeri %50 olarak ayarlanmıştır.

- Sürüş Çevrimi: NYCC
- Araç Ağırlığı: 2300 kg
- Yol Eğimi: -5 derece (% -8.75 civarı)
- Yol Sürtünme Katsayısı: 0.7
- Başlangıç SOC: %50

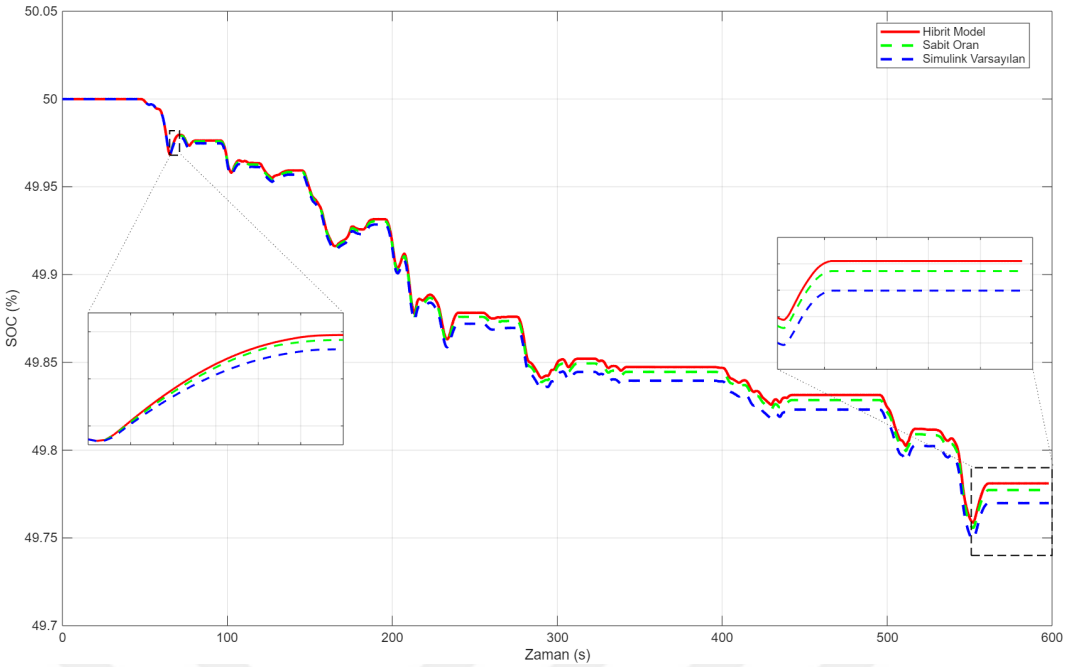
Bu test, modelin eğitim verisindeki boşlukları doldurma ve daha önce görmediği parametre kombinasyonlarına ne kadar başarılı yanıt verdiğini ölçer. Şekil 5.5'de bu interpolasyon senaryosu için SOC sonuçları gösterilmektedir.

Tablo 5.3, bu simulasyona ait sayısal sonuçları göstermektedir.

Tablo 5.3 Senaryo 3 (NYCC, İnterpolasyon) sonunda elde edilen SOC sonuçları.

Kontrol Stratejisi	Nihai SOC (%)	Kazanılan SOC (%)	İyileştirme (%)
Hibrit Model	49.7811	0.0112	4.88
Sabit Oran (%70-%30)	49.7773	0.0074	3.22
Baseline (Varsayılan)	49.7698	-	-

Bu senaryoda, araç ağırlığı, yol eğimi ve sürtünme katsayısı gibi birden fazla parametre, eğitim setinde doğrudan bulunmayan ancak aralık dahilindeki değerlere ayarlanmıştır. Şekil 5.5'daki grafik, hibrit modelin bu yeni koşullara rağmen performans üstünlüğünü sürdürdüğünü göstermektedir. Yakınlaştırılmış kesitler, hibrit modelin frenleme anlarında SOC'yi diğerlerine göre daha fazla artırdığını yine doğrulamaktadır. Tablo 5.3'deki %4.88'lik iyileşme oranı, Senaryo 2'ye yakın ve hala oldukça yüksektir. Bu, modelin eğitim verilerindeki farklı noktalar arasında başarılı bir şekilde interpolasyon yapabildiğini ve öğrenilen kontrol mantığını eğitim setinde bulunmayan ancak makul olan yeni durumlara genelleyebildiğini göstermektedir.



Şekil 5.5 Senaryo 3 (NYCC, İnterpolasyon): Kontrol stratejilerinin SOC karşılaştırması.

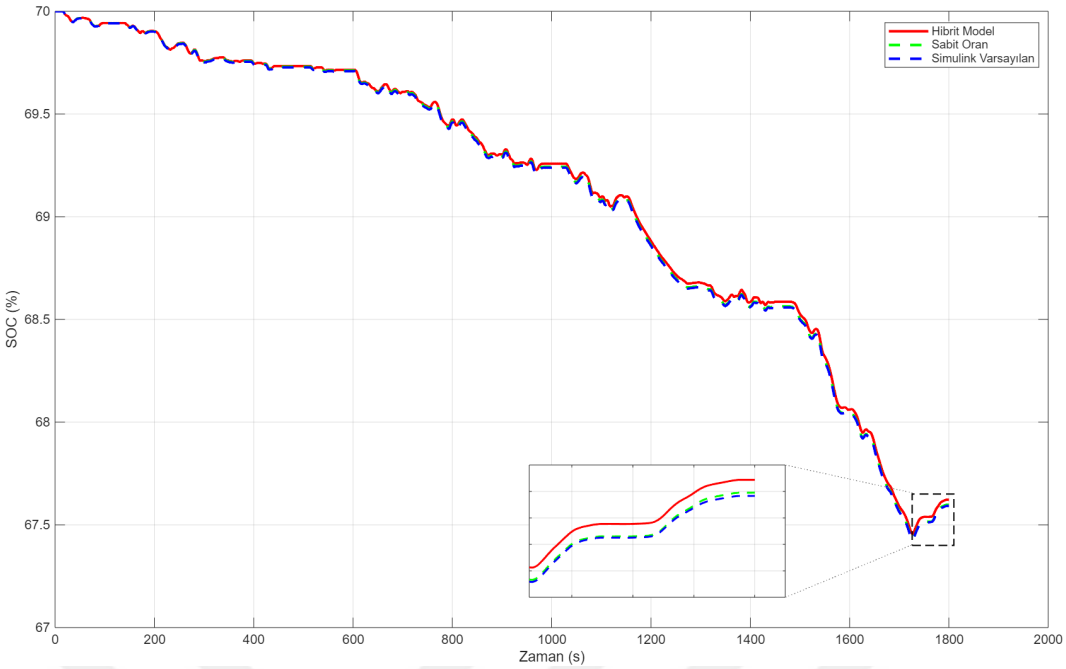
5.2.4 Senaryo 4: Eğitim Sınırları Dışında WLTP Class 3 Çevrimi (Ekstrapolasyon Testi)

Dördüncü ve son senaryo, modelin en zorlu koşullar altındaki performansını, yani *ekstrapolasyon* yeteneğini test eder. Bu senaryoda hem sürüş çevrimi (WLTP Class 3) tamamen farklıdır hem de kritik parametreler (araç ağırlığı, yol eğimi, sürtünme katsayısı) modelin eğitiminde kullanılan değer aralıklarının dışındadır. Ayrıca başlangıç SOC değeri %70 olarak ayarlanmıştır.

- Sürüş Çevrimi: WLTP Class 3
- Araç Ağırlığı: 2500 kg
- Yol Eğimi: -15 derece (% -26.8 civarı)
- Yol Sürtünme Katsayısı: 1.0
- Başlangıç SOC: %70

Bu test, modelin beklenmedik veya aşırı koşullarla karşılaştığında ne kadar sağlam kaldığını ve hâlâ bir miktar fayda sağlayıp sağlamadığını anlamak açısından önemlidir.

Şekil 5.6'da bu zorlu ekstrapolasyon senaryosuna ait SOC karşılaştırmaları yer almaktadır.



Şekil 5.6 Senaryo 4 (WLTP, Ekstrapolasyon): Kontrol stratejilerinin SOC karşılaştırması.

Simulasyona ait sayısal sonuçlar Tablo 5.4'de özetlenmiştir.

Tablo 5.4 Senaryo 4 (WLTP, Ekstrapolasyon) sonunda elde edilen SOC sonuçları.

Kontrol Stratejisi	Nihai SOC (%)	Kazanılan SOC (%)	İyileştirme (%)
Hibrit Model	67.6220	0.0303	1.26
Sabit Oran (%70-%30)	67.5977	0.0061	0.25
Baseline (Varsayılan)	67.5916	-	-

Bu senaryo, modelin eğitim verisi sınırlarının dışına çıkıldığında nasıl davrandığını göstermektedir. Aşırı dik negatif eğim (-15 derece) ve yüksek sürtünme katsayısı (1.0) gibi parametreler modelin daha önce karşılaşmadığı koşullardır. Şekil 5.6'a bakıldığında, üç strateji arasındaki farkın önceki senaryolara göre gözle görülür şekilde azaldığı fark edilmektedir. Ancak, özellikle çevrimin sonundaki (yaklaşık 1700-1800 saniye) yakınlaştırılmış bölgede, hibrit modelin hala diğer iki yönteme göre hafif bir SOC avantajı sağladığı görülebilmektedir. Tablo 5.4'deki sonuçlar bunu doğrulamaktadır: Hibrit model, Baseline'a göre %1.26'lık bir iyileşme sağlamıştır. Bu oran önceki senaryolara göre düşük olsa da, modelin eğitim sınırlarının tamamen dışındaki bu zorlu koşullarda bile hâlâ pozitif bir katkı yapabildiğini göstermesi açısından önemlidir. Bu, modelin tamamen başarısız olmadığını, ancak ekstrapolasyon performansının beklendiği gibi interpolasyon performansından daha düşük olduğunu ve sınırlılıkları olduğunu göstermektedir. Sabit Oran yönteminin iyileşmesi ise bu senaryoda oldukça düşerek (%0.25) Baseline'a çok yaklaşmıştır.

6
BULGULAR VE DEĞERLERNDİRME

Bu bölümde, önceki bölümlerde detaylı bir şekilde sunulan bu tez çalışmasının temelini oluşturan YSA - KA hibrit kontrol modelinin geliştirilmesi, optimizasyonu ve simülasyon tabanlı performans analizlerinden elde edilen temel bulgular sunulmaktadır. Elde edilen bu bulgular, referans kontrol yöntemleri ve literatürdeki yaklaşımlar çerçevesinde değerlendirilmekte, geliştirilen modelin güçlü ve zayıf yönleri ile çalışmanın özgün katkısı tartışılmaktadır.

6.1 Temel Bulguların Özeti

Bölüm 3'te detaylandırılan Dinamik Programlama (DP) tabanlı optimizasyon süreci, çeşitli sürüş senaryoları altında çift motorlu (ön ve arka aksta bağımsız tahrikli - IDA) bir elektrikli araç için teorik olarak elde edilebilecek maksimum enerji geri kazanımını ve buna karşılık gelen optimal rejeneratif fren torku dağılımını belirlemiştir. Bu optimal çözümler, Bölüm 4'te geliştirilen hibrit YSA-Karar Ağacı kontrol modelinin eğitimi için referans veri seti olarak kullanılmıştır. Hibrit modelin, DP tarafından üretilen optimal tork komutlarını ne kadar başarılı bir şekilde takip edebildiği, çeşitli hata metrikleri (RMSE, MAE) ve determinasyon katsayısı (R^2) kullanılarak değerlendirilmiş ve modelin dahili (eğitim verisinden ayrılan) ve bağımsız test senaryolarında yüksek doğrulukla performans gösterdiği (ortalama $R^2 > 0.97$) tespit edilmiştir (Bkz. Tablo 4.3 ve Tablo 4.4, Şekil 4.7, Şekil 4.8).

Bölüm 5'te ise, bu doğrulanmış hibrit kontrol modelinin tam bir elektrikli araç modeline entegre edilmiş halinin performansı, iki farklı referans kontrol stratejisi (Sabit Oranlı Tork Paylaşımı ve Baseline/Simulink Varsayılan Kontrol) ile dört farklı test senaryosu altında karşılaştırılmıştır. Ana bulgular şu şekilde özetlenebilir:

- **Hibrit Modelin Tutarlı Üstünlüğü:** Geliştirilen hibrit kontrol modeli, test edilen tüm senaryolarda – eğitim koşullarına uygun UDDS çevriminden

(Senaryo 1), farklı araç ağırlığı ile NYCC çevrimine (Senaryo 2), eğitim aralığındaki interpolasyon koşullarına (Senaryo 3) ve eğitim sınırları dışındaki zorlu ekstrapolasyon koşullarına (Senaryo 4) kadar – referans yöntemlere kıyasla batarya şarj durumunu (SOC) koruma ve enerji geri kazanımı açısından tutarlı bir şekilde daha iyi performans sergilemiştir.

- **SOC İyileşme Oranları:** Hibrit modelin Baseline stratejisine göre sağladığı net SOC iyileşmesi, senaryo koşullarına bağlı olarak %1.26 (WLTP, Ekstrapolasyon) ile %5.06 (NYCC, 2000kg) arasında değişkenlik göstermiştir. Bu iyileşmeler, tüm bir sürüş çevrimi boyunca elde edilen kümülatif kazançları temsil etmektedir.

- **Adaptasyon ve İnterpolasyon Başarısı:** Model, özellikle Senaryo 3'te (NYCC, interpolasyon) görüldüğü üzere, eğitim setinde doğrudan karşılaşmadığı ancak parametre (araç ağırlığı, yol eğimi, yol sürtünme katsayısı, başlangıç SOC) aralıkları içinde kalan farklı kombinasyonlara başarılı bir şekilde adapte olmuş ve yüksek performansını (%4.88 iyileşme) sürdürmüştür.

- **Ekstrapolasyon Performansı ve Sınırlılıklar:** En zorlu test olan Senaryo 4 (WLTP, ekstrapolasyon), modelin eğitim verisi kapsamının dışına çıkıldığında performans avantajının azaldığını, ancak tamamen ortadan kalkmayarak hala pozitif bir katkı (%1.26 iyileşme) sağlayabildiğini göstermiştir. Bu, modelin belirli bir sağlamlığa sahip olduğunu ancak ekstrapolasyon yeteneğinin sınırlı olduğunu ortaya koymuştur.

6.2 Bulguların Değerlendirilmesi ve Tartışma

Bu çalışmada elde edilen simülasyon sonuçları bir arada değerlendirildiğinde, geliştirilen hibrit YSA-Karar Ağacı kontrol stratejisinin, incelenen referans yöntemlere (Sabit Oranlı Paylaşım ve Baseline Kontrol) kıyasla genellikle daha iyi enerji geri kazanımı sağladığı ve çift motorlu elektrikli araçlarda rejeneratif frenleme verimliliğini artırma potansiyelini güçlü bir şekilde ortaya koyduğu görülmektedir.

6.2.1 Hibrit Modelin Performansının Mekanizması ve Sağlamlığı

Hibrit modelin referans yöntemlere kıyasla sergilediği üstün performansın temelinde, Bölüm 3'te DP ile elde edilen optimal kontrol politikalarını etkin bir şekilde öğrenmesi ve uygulaması yatmaktadır. DP, tanımlanan kısıtlar (UN/ECE regülasyonları, aktüatör limitleri, batarya limitleri) dahilinde ve 7 farklı

karakteristik değişkeni (yol eğimi, sürtünme katsayısı, araç yük dağılımı, hız, ivme/frenleme oranı, SOC, toplam fren torku) göz önünde bulundurarak, her bir zaman adımında ön ve arka akslar arasındaki rejeneratif fren torku dağılımını enerji geri kazanımını maksimize edecek şekilde belirlemiştir. Hibrit model, bu karmaşık ve çok boyutlu ilişkileri öğrenerek, anlık sürüş koşullarına dinamik olarak adapte olabilen bir kontrol stratejisi sunmaktadır. Bu dinamik adaptasyon, özellikle aracın ve çevrenin değişken koşullarında, Sabit Oranlı Paylaşım gibi statik veya Baseline gibi basit kural tabanlı yöntemlere göre önemli bir avantaj sağlamaktadır.

Bölüm 5'te sunulan senaryo bazlı analizler, bu genel bulguyu detaylandırmaktadır: Senaryo 1 (UDDS, eğitim koşulları), hibrit modelin eğitim verilerine uygun koşullar altında beklendiği gibi referans yöntemlerden daha üstün (%3.18 iyileşme) bir SOC koruması sağladığını doğrulamıştır. Senaryo 2 (NYCC, 2000kg), modelin farklı bir sürüş çevrimine ve araç ağırlığına adapte olabildiğini ve hatta daha sık frenleme içeren bu çevrimde daha yüksek (%5.06) bir iyileşme sağladığını göstermiştir. Bu, modelin farklı sürüş dinamiklerine karşı esnekliğini ve optimizasyon potansiyelini etkin kullanabildiğini işaret etmektedir. Senaryo 3 (NYCC, interpolasyon koşulları), modelin eğitim setinde doğrudan bulunmayan ancak parametre aralıkları içinde kalan farklı parametre kombinasyonlarına başarılı bir şekilde adapte olduğunu (%4.88 iyileşme) ve güçlü bir interpolasyon yeteneği sergilediğini kanıtlamıştır. Bu, modelin öğrenilen bilgiyi benzer ancak yeni durumlara genelleyebildiğini ve pratik uygulamalarda karşılaşılabilecek parametre değişimlerine karşı belirli bir dayanıklılık sergileyebileceğini göstermektedir.

En zorlu test olan Senaryo 4 (WLTP, ekstrapolasyon koşulları), modelin genelleme yeteneğinin sınırlarını ortaya koymuştur. Eğitim aralığının dışındaki parametreler ve tamamen farklı bir sürüş çevrimi ile karşılaşıldığında, hibrit modelin sağladığı avantaj (%1.26 iyileşme) önceki senaryolara göre belirgin şekilde azalmıştır. Ancak, bu aşırı ve daha önce karşılaşılmamış koşullarda dahi modelin tamamen işlevsiz hale gelmemesi ve hala Baseline yöntemine göre pozitif bir iyileşme sağlaması, belirli bir düzeyde temel sağlamlığa sahip olduğunu ve kontrol mantığının temel prensiplerinin aşırı durumlarda bile bir miktar fayda sağlayabildiğini işaret etmektedir. Bu durum, modelin performansının eğitim verisinin kapsamına ve çeşitliliğine duyarlı olduğunu, ancak tamamen başarısız olmadığını göstermektedir.

6.2.2 Referans Yöntemlerle Karşılaştırmalı Değerlendirme

Sabit oranlı paylaşım yaklaşımı, basitliğine rağmen değişen sürüş koşullarına ve araç parametrelerine adapte olamaması nedeniyle, özellikle eğitim koşullarından

uzaklaşılan veya farklı dinamiklere sahip olan Senaryo 2, 3 ve 4 gibi durumlarda optimumdan uzaklaşmaktadır. Ekstrapolasyon senaryosunda (Senaryo 4) performansı Baseline yöntemine oldukça yaklaşmıştır. Bu, statik bir kuralın değişken ve karmaşık gerçek dünya koşullarında yetersiz kalabileceğini göstermektedir. Baseline kontrol mantığı ise, genellikle ön elektrik motorunun kapasitesini önceliklendirmesi ve arka motorun rejeneratif potansiyelini her zaman tam olarak kullanamaması nedeniyle (hibrit modelin dinamik optimizasyonu sayesinde aşılan bir durum) tüm senaryolarda hibrit modele göre daha düşük enerji geri kazanımı sağlamıştır. Hibrit model, DP ile öğrenilen optimal veya optimale yakın stratejiyi taklit ederek, her iki motorun verimliliğini, bataryanın şarj kabul limitlerini ve anlık sürüş taleplerini daha etkin bir şekilde dengeleyerek enerji geri kazanımını maksimize etmeye çalışmaktadır.

6.2.3 Literatürdeki Çalışmalarla Karşılaştırma

Bu tezde sunulan hibrit kontrol stratejisinin performansını literatürdeki benzer çalışmalarla doğrudan karşılaştırmak, kullanılan metodolojiler, araç modelleri, test koşulları ve referans (baseline) tanımlarındaki farklılıklar nedeniyle zorluklar içerir. Ancak, bazı önemli ayrımlar ve çalışmanın özgün katkıları vurgulanabilir:

- **Karşılaştırma Referansı:** Literatürdeki bazı çalışmalar, önerdikleri kontrol stratejisinin performansını rejeneratif frenlemenin hiç olmadığı durumlarla kıyaslayarak çok yüksek iyileşme oranları rapor edebilmektedir. Bu tezde ise karşılaştırma, zaten belirli bir düzeyde rejeneratif frenleme yapan (Simulink varsayılanı) ve pratik uygulamalarda temel bir strateji olarak kabul edilebilecek bir Baseline kontrolcü ile ve ayrıca yaygın bir yaklaşım olan Sabit Oranlı Paylaşım yöntemi ile yapılmıştır. Dolayısıyla, elde edilen %5 civarındaki SOC iyileşmeleri, zaten bir miktar optimize edilmiş bir sisteme göre elde edilen net kazançlardır ve bu bağlamda oldukça anlamlıdır.
- **Araç Konfigürasyonu ve Kontrol Hedefi:** Bu çalışma, ön ve arka aksta bağımsız tahrik motorları bulunan (IDA) çift motorlu bir elektrikli araca odaklanmıştır. Bu konfigürasyon, tork dağıtımında daha fazla esneklik ve dolayısıyla optimizasyon potansiyeli sunmaktadır. Kontrol hedefi, UN/ECE frenleme regülasyonlarına uyumu gözeterek enerji geri kazanımını maksimize etmektir.
- **Test Koşullarının Kapsamı:** Bazı çalışmalar, performans değerlendirmesini sınırlı sayıda kısa süreli frenleme manevrası üzerinden yapmaktadır. Bu tezde ise, farklı standart sürüş çevrimleri (UDDS, NYCC, WLTP) kullanılmış

ve bu çevrimler üzerinde, Bölüm 5'te detaylandırıldığı gibi, araç ağırlığı, yol eğimi, yol sürtünme katsayısı ve başlangıç SOC değeri gibi çok sayıda parametrenin farklı kombinasyonlarını içeren dört kapsamlı senaryo (eğitim koşulları, farklı parametrelerle adaptasyon, interpolasyon ve ekstrapolasyon) üzerinden değerlendirme yapılmıştır.

- **Çok Boyutlu Değişkenlerin Entegrasyonu:** Geliştirilen hibrit model, anlık SOC değeri, yol eğimi, yol sürtünme katsayısı, araç ağırlığı, hız, frenleme oranı ve toplam fren torku gibi 7 farklı dinamik ve çevresel değişkeni girdi olarak kullanarak kontrol kararları üretmektedir. Literatürdeki birçok öğrenme tabanlı model, daha az sayıda girdi değişkeni ile çalışmaktadır. Bu çok boyutlu girdi seti, modelin daha karmaşık ve gerçekçi sürüş koşullarını daha iyi temsil etmesini ve bu koşullara daha hassas tepkiler vermesini sağlamayı amaçlamaktadır.

Bu farklılıklar göz önüne alındığında, bu tezde elde edilen sonuçların, özellikle kapsamlı senaryo analizleri ve çok boyutlu değişkenlerin dikkate alınması açısından literatüre önemli bir katkı sunduğu değerlendirilmektedir.

6.2.4 Çalışmanın Özgün Katkıları

Bu tezin literatüre sunduğu temel özgün katkılar şu şekilde özetlenebilir:

1. Dinamik Programlama ile elde edilen optimal kontrol politikalarını temel alarak, YSA ve Karar Ağacı algoritmalarını birleştiren hibrit modelin çift motorlu elektrikli araçlarda rejeneratif frenleme kontrolü için tasarlanması ve uygulanması.

2. Kontrol modelinin, araç dinamiği ve çevresel koşulları temsil eden çok boyutlu bir karakteristik değişken setini (7 farklı girdi) dikkate alarak geliştirilmesi.

3. Modelin performansının, sadece ideal koşullarda değil, aynı zamanda eğitim verisi aralığındaki farklı parametre kombinasyonlarında (interpolasyon) ve eğitim verisi sınırlarının dışındaki zorlu koşullarda (ekstrapolasyon) sistematik olarak test edilerek sağlamlığının ve genelleme yeteneğinin kapsamlı bir şekilde değerlendirilmesi.

4. Elde edilen SOC iyileşmelerinin, pratik uygulamalarda temel kabul edilebilecek ve zaten bir miktar rejenerasyon içeren referans yöntemlere kıyasla değerlendirilmesi.

6.3 Gelecek Çalışma Önerileri

Bu tezde elde edilen bulgular ışığında, gelecekte bu alanda yapılabilecek çalışmalara yönelik şu öneriler sunulabilir:

- **Eğitim Veri Setinin Genişletilmesi ve Çeşitlendirilmesi:** Farklı standart sürüş çevrimlerinden (WLTP, NEDC vb.) ve özellikle çeşitli sürüş stillerini ve yol koşullarını yansıtan daha geniş ve çeşitli senaryolar içeren bir eğitim veri seti kullanılarak modelin yeniden eğitilmesi ve genelleme yeteneğinin artırılması.
- **Ekstrapolasyon Yeteneğinin Geliştirilmesi:** Modelin eğitim verisi dışındaki koşullara daha iyi genelleme yapabilmesi için Transfer Öğrenme, Alan Adaptasyonu (Domain Adaptation) veya Fizik Bilgili Sinir Ağları (PINN'ler) gibi ileri makine öğrenmesi tekniklerinin araştırılması. Bu, karar ağaçlarının çeşitliliğini artırarak genelleme performansına katkıda bulunabilir (özellikle rastgele orman gibi topluluk modellerinde kullanılan bir tekniktir).
- **Optimize Edilmiş Sürüş ve Frenleme Stratejilerinin Birleştirilmesi:** Bu çalışmada odaklanılan optimize edilmiş frenleme stratejisinin yanına optimize edilmiş sürüş (tahrik) stratejilerinin de eklenerek tek bir çalışma çatısı altında birleştirilerek elektrikli araçların genel enerji yönetimi performansının daha da iyileştirilmesi.
- **Farklı Araç Konfigürasyonlarına Uyarlanabilirlik:** Geliştirilen modelin ve metodolojinin, dört tekerlek içi motorlu veya farklı batarya/aktarma organı teknolojilerine sahip diğer elektrikli araç konfigürasyonlarına uyarlanabilirliğinin ve bu farklı platformlardaki performansının araştırılması.
- **Deneysel Doğrulama ve Gerçek Zamanlı Performans Analizi:** Simülasyon bulgularının, kontrollü laboratuvar koşullarında bir test düzeneği (dinamometre) üzerinde veya mümkünse bir prototip araç üzerinde yapılacak deneysel çalışmalarla doğrulanması. Bu aşamada, modelin gerçek zamanlı hesaplama performansı ve ECU üzerindeki uygulanabilirliği de detaylı olarak incelenmelidir.
- **Sürücü Davranışlarının ve Geri Bildiriminin Entegrasyonu:** Sürücülerin bireysel frenleme alışkanlıklarını veya sürüş stillerini algılayabilen ve buna göre rejeneratif frenleme stratejisini adapte edebilen sistemlerin geliştirilmesi.

7
SONUÇ

Bu tez çalışmasında, çift motorlu (ön ve arka aksta bağımsız tahrikli - IDA) elektrikli araçlarda rejeneratif frenleme performansının artırılması amacıyla, Dinamik Programlama (DP) ile elde edilen optimal kontrol girdilerini temel alan Yapay Sinir Ağı (YSA) - Karar Ağacı (KA) hibrit kontrol stratejisi geliştirilmiş ve performansı kapsamlı bir şekilde analiz edilmiştir. Geliştirilen kontrol modeli, aracın anlık dinamiklerini ve çevresel koşulları temsil eden yedi farklı karakteristik değişkeni (yol eğimi, yol sürtünme katsayısı, araç yük dağılımı, hız, ivme/frenleme oranı, batarya şarj durumu ve toplam fren torku) dikkate alarak ön ve arka akslar arasındaki rejeneratif fren torku dağılımını optimize etmeyi hedeflemiştir.

DP ile üretilen optimal referans verilerle eğitilen hibrit modelin, bu referans torkları yüksek bir doğrulukla ($R^2 > 0.97$) takip edebildiği bağımsız test senaryoları ile doğrulanmıştır. Ardından, hibrit modelin tam bir elektrikli araç modeline (MATLAB Virtual Vehicle Composer tabanlı, 14 serbestlik dereceli) entegre edilmiş halinin performansı, Sabit Oranlı Tork Paylaşımı ve Baseline (Simulink Varsayılan) olmak üzere iki farklı referans kontrol stratejisi ile dört farklı ve giderek zorlaşan test senaryosu (eğitim koşulları, farklı parametrelerle adaptasyon, interpolasyon ve ekstrapolasyon) altında karşılaştırılmıştır.

Simülasyon sonuçları, geliştirilen hibrit kontrol modelinin, test edilen tüm senaryolarda referans yöntemlere kıyasla batarya şarj durumunu (SOC) koruma ve enerji geri kazanımı açısından tutarlı bir şekilde daha üstün performans sergilediğini göstermiştir. Hibrit modelin Baseline stratejisine göre sağladığı net SOC iyileşmesi, senaryo koşullarına bağlı olarak %1.26 ile %5.06 arasında değişmiştir. Modelin, eğitim verisi aralığındaki farklı parametre kombinasyonlarına (interpolasyon) başarılı bir şekilde adapte olduğu ve eğitim verisi kapsamı dışındaki zorlu koşullarda (ekstrapolasyon) dahi performans avantajını tamamen kaybetmeyerek belirli bir sağlamlık sergilediği gözlemlenmiştir.

Bu bulgular, önerilen hibrit YSA - Karar Ağacı tabanlı kontrol stratejisinin,

özellikle aracın ve çevrenin değişken koşullarında, rejeneratif frenlemeden elde edilen enerjiyi maksimize etme potansiyeline sahip olduğunu ve mevcut kural tabanlı veya statik paylaşımlı yöntemlere göre önemli bir iyileştirme sunabileceğini ortaya koymaktadır. Çalışmada ayrıca, modelin performansının eğitim verisinin kapsamına ve çeşitliliğine duyarlılığı vurgulanmış ve gelecekteki araştırmalar için çeşitli öneriler sunulmuştur. Sonuç olarak, bu tez çalışması, hibrit kontrol tekniklerinin elektrikli araçlarda enerji verimliliğini artırmaya yönelik karmaşık kontrol problemlerinin çözümünde etkin bir şekilde kullanılabileceğini göstermiştir.

KAYNAKÇA

[1] Q. Yuan, W. Hao, H. Su, G. Bing, X. Gui A. Safikhani, "Investigation on range anxiety and safety buffer of battery electric vehicle drivers," *Journal of Advanced Transportation*, c. 2018, no. 1, s. 8 301 209, 2018.

[2] C. Vidal, O. Gross, R. Gu, P. Kollmeyer A. Emadi, "xEV Li-ion battery low-temperature effects," *IEEE transactions on vehicular technology*, c. 68, no. 5, ss. 4560–4572, 2019.

[3] J. Ruan, P. D. Walker, P. A. Watterson N. Zhang, "The dynamic performance and economic benefit of a blended braking system in a multi-speed battery electric vehicle," *Applied energy*, c. 183, ss. 1240–1258, 2016.

[4] J. Liu, Q. Duan, L. Feng, M. Ma, J. Sun Q. Wang, "Capacity fading and thermal stability of LiNixCoyMnzO2/graphite battery after overcharging," *Journal of Energy Storage*, c. 29, s. 101 397, 2020.

[5] C. Luo, Y. Yang Z. Zhong, "Optimal braking torque distribution of dual-motor front-rear individually driven electric-hydraulic hybrid powertrain based on minimal energy loss," *IEEE Access*, c. 10, ss. 134 404–134 416, 2022.

[6] J. Huang, D. Qin Z. Peng, "Effect of energy-regenerative braking on electric vehicle battery thermal management and control method based on simulation investigation," *Energy Conversion and Management*, c. 105, ss. 1157–1165, 2015.

[7] P. Fajri, S. Lee, V. A. K. Prabhala M. Ferdowsi, "Modeling and integration of electric vehicle regenerative and friction braking for motor/dynamometer test bench emulation," *IEEE Transactions on Vehicular Technology*, c. 65, no. 6, ss. 4264–4273, 2015.

[8] X. Li, X. Zhang Y. Wang, "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*, c. 23, no. 3, ss. 667–681, 2022.

[9] S. Zhou, J. Liu, Z. Wang S. Sun, "Research on Design Optimization and Simulation of Regenerative Braking Control Strategy for Pure Electric Vehicle Based on EMB Systems," *Transactions of FAMENA*, c. 47, no. 4, ss. 33–49, 2023.

[10] Z. Chen, R. Xiong, X. Cai, Z. Wang R. Yang, "Regenerative braking control strategy for distributed drive electric vehicles based on slope and mass co-estimation," *IEEE Transactions on Intelligent Transportation Systems*, 2023.

[11] M. Tang X. Zhang, "Optimal Regenerative Braking Control Strategy for Electric Vehicles Based on Braking Intention Recognition and Load Estimation," *IEEE Transactions on Vehicular Technology*, c. 73, no. 3, ss. 3378–3392, 2023.

[12] C. Li, L. Zhang, S. Lian M. Liu, "Research on regenerative braking control of electric vehicles based on game theory optimization," *Science Progress*, c. 107, no. 2, s. 00 368 504 241 247 404, 2024.

[13] Q. Tang, Y. Yang, C. Luo, Z. Yang C. Fu, "A novel electro-hydraulic compound braking system coordinated control strategy for a four-wheel-drive pure electric vehicle driven by dual motors," *Energy*, c. 241, s. 122 750, 2022.

[14] W. Xu, H. Chen, H. Zhao B. Ren, "Torque optimization control for electric vehicles with four in-wheel motors equipped with regenerative braking system," *Mechatronics*, c. 57, ss. 95–108, 2019.

[15] J. Zhang, Y. Yang, D. Qin, C. Fu Z. Cong, "Regenerative braking control method based on predictive optimization for four-wheel drive pure electric vehicle," *IEEE Access*, c. 9, ss. 1394–1406, 2020.

[16] K. Kiddee W. Khan-Ngern, "Performance evaluation of regenerative braking system based on a HESS in extended range BEV," *Journal of Electrical Engineering and Technology*, c. 13, no. 5, ss. 1965–1977, 2018.

[17] H. A. Yavasoglu, Y. E. Tetik H. G. Ozcan, "Neural network-based energy management of multi-source (battery/UC/FC) powered electric vehicle," *International Journal of Energy Research*, c. 44, no. 15, ss. 12 416–12 429, 2020.

[18] H. He, C. Wang, H. Jia X. Cui, "An intelligent braking system composed single-pedal and multi-objective optimization neural network braking control strategies for electric vehicle," *Applied Energy*, c. 259, s. 114 172, 2020.

[19] H. Tian, Z. Lu, X. Wang, X. Zhang, Y. Huang G. Tian, "A length ratio based neural network energy management strategy for online control of plug-in hybrid electric city bus," *Applied Energy*, c. 177, ss. 71–80, 2016.

[20] B. Prasanth ve diğ., "Maximizing regenerative braking energy harnessing in electric vehicles using machine learning techniques," *Electronics*, c. 12, no. 5, s. 1119, 2023.

[21] X. Zeng, L. Liu T. Yuan, "Train Regenerative Braking Strategy Optimization Based on Reinforcement Learning," *International Symposium for Intelligent Transportation and Smart City*, Springer, 2022, ss. 55–66.

[22] W. YANG, D. LUO W. ZHANG, "Regenerative braking strategy based on deep reinforcement learning for an electric mining truck," *Chinese Journal of Engineering*, c. 46, no. 3, ss. 503–513, 2024.

[23] T. Gillespie, *Fundamentals of vehicle dynamics*. SAE international, 2021.

[24] I. J. Besselink, A. J. Schmeitz H. B. Pacejka, "An improved Magic Formula/Swift tyre model that can handle inflation pressure changes," *Vehicle System Dynamics*, c. 48, no. S1, ss. 337–352, 2010.

[25] C. C. MacAdam, "An optimal preview control for linear systems," 1980.

[26] C. C. MacAdam, “Application of an optimal preview control for simulation of closed-loop automobile driving,” *IEEE Transactions on systems, man, and cybernetics*, c. 11, no. 6, ss. 393–399, 1981.

[27] C. C. MacAdam, “Development of driver/vehicle steering interaction models for dynamic analysis. Final technical report,” tek. rap., 1988.

[28] *UN Regulation No 13-H – Uniform provisions concerning the approval of passenger cars with regard to braking [2023/401]*, Şub. 2023.

[29] *Road vehicles – Determination of centre of gravity*, Accessed from official ISO standards, 2011.

[30] T. J. Barlow, S. Latham, I. McCrae P. Boulter, “A reference book of driving cycles for use in the measurement of road vehicle emissions,” *TRL Published Project Report*, 2009.

[31] S. Haykin, *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1994.

[32] L. Breiman, J. Friedman, R. A. Olshen C. J. Stone, *Classification and regression trees*. Routledge, 2017.

[33] J. Snoek, H. Larochelle R. P. Adams, “Practical bayesian optimization of machine learning algorithms,” *Advances in neural information processing systems*, c. 25, 2012.

[34] V. Nair G. E. Hinton, “Rectified linear units improve restricted boltzmann machines,” *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010, ss. 807–814.

[35] D. P. Kingma J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.

[36] Y. Yao, L. Rosasco A. Caponnetto, “On early stopping in gradient descent learning,” *Constructive approximation*, c. 26, no. 2, ss. 289–315, 2007.

EK-A

.1 Lastik Modeli Denklemleri

Boyuna kuvvet (F_x) için Pacejka Magic Formula parametreleri ve ara hesaplamalar:

$$\kappa_x = \kappa + S_{Hx}, \tag{1}$$
$$C_x = p_{Cx1}\lambda_{Cx}, \tag{2}$$
$$D_x = \mu_x F_z, \tag{3}$$
$$\mu_x = (p_{Dx1} + p_{Dx2}\mathrm{df}_z)\left(1 - p_{Dx3}\gamma^2\right)\left(1 + p_{px3}\mathrm{dp}_i + p_{px4}\mathrm{dp}_i^2\right)\lambda_{\mu x}, \tag{4}$$
$$E_x = \left(p_{Ex1} + p_{Ex2}\mathrm{df}_z + p_{Ex3}\mathrm{df}_z^2\right)\left(1 - p_{Ex4}\,\mathrm{sgn}\left(\kappa_x\right)\right)\lambda_{Ex}, \tag{5}$$
$$K_{x\kappa} = (p_{Kx1} + p_{Kx2}\mathrm{df}_z)\exp\left(p_{Kx3}\mathrm{df}_z\right)\left(1 + p_{px1}\mathrm{dp}_i + p_{px2}\mathrm{dp}_i^2\right)F_z\lambda_{Kx\kappa}, \tag{6}$$
$$B_x = \frac{K_{x\kappa}}{C_x D_x}, \tag{7}$$
$$S_{Hx} = (p_{Hx1} + p_{Hx2}\mathrm{df}_z)\,\lambda_{Hx}, \tag{8}$$
$$S_{Vx} = (p_{Vx1} + p_{Vx2}\mathrm{df}_z)\,F_z\lambda_{Vx}\lambda_{\mu x}. \tag{9}$$

Yanal kayma açısının boyuna kuvvete etkisi için birleşik kayma faktörü ($G_{x\alpha}$):

$$G_{x\alpha} = \frac{\cos\left[C_{x\alpha}\arctan(B_{x\alpha}\alpha_s - E_{x\alpha}(B_{x\alpha}\alpha_s - \arctan(B_{x\alpha}\alpha_s)))\right]}{\cos\left[C_{x\alpha}\arctan(B_{x\alpha}S_{Hx\alpha} - E_{x\alpha}(B_{x\alpha}S_{H\alpha} - \arctan(B_{x\alpha}S_{Hx\alpha})))\right]}, \tag{10}$$
$$\alpha_s = \alpha_{\mathrm{F}} + S_{Hx\alpha}, \tag{11}$$
$$B_{x\alpha} = (r_{Bx1} + r_{Bx3}\gamma^2)\cos(\arctan[r_{Bx2}\kappa])\cdot\lambda_{x\alpha}, \tag{12}$$
$$C_{x\alpha} = r_{Cx1}, \tag{13}$$
$$E_{x\alpha} = r_{Ex1} + r_{Ex2}\mathrm{df}_z, \tag{14}$$
$$S_{Hx\alpha} = r_{Hx1}. \tag{15}$$

Birleşik kayma oranı kullanılmadığında $G_{x\alpha} = 1$.

Yanal kuvvet (F_y) için Pacejka Magic Formula parametreleri ve ara hesaplamalar:

$$F_{yp} = D_y \sin\left[C_y \arctan\left\{B_y\alpha_y - E_y\left(B_y\alpha_y - \arctan\left(B_y\alpha_y\right)\right)\right\}\right] + S_{V_y}, \tag{16}$$
$$\alpha_y = \alpha_{\mathrm{F}} + S_{H_y}, \tag{17}$$
$$C_y = p_{C_{y1}}\lambda_{C_y}, \tag{18}$$
$$D_y = \mu_y F_z, \tag{19}$$
$$\mu_y = \left(p_{D_{y1}} + p_{D_{y2}}\mathrm{df}_z\right)\left(1 - p_{D_{y3}}\gamma^2\right)\left(1 + p_{py3}\mathrm{dp}_i + p_{py4}\mathrm{dp}_i^2\right)\lambda_{\mu_y}, \tag{20}$$
$$E_y = \left(p_{E_{y1}} + p_{E_{y2}}\mathrm{df}_z\right)\left(1 + p_{E_{y5}}\gamma^2 - \left(p_{E_{y3}} + p_{E_{y4}}\gamma\right)\mathrm{sgn}\left(\alpha_y\right)\right)\lambda_{E_y}. \tag{21}$$

Boyuna ve yanal kuvvetler arasındaki etkileşim terimleri:

$$K_{y\alpha} = p_{Ky1}F_{z0}(1 + p_{py1}dp_i)\sin\left[p_{Ky4}\arctan\left(\frac{F_z}{(p_{Ky2} + p_{Ky5}\gamma^2)(1 + p_{py2}dp_i)F_{z0}}\right)\right] \times (1 - p_{Ky3}|\gamma|)\lambda_{Ky\alpha}, \tag{22}$$
$$K_{y\gamma} = \left(p_{Ky6} + p_{Ky7}\,\mathrm{df}_z\right)\left(1 + p_{py5}\,\mathrm{dp}_i\right)\,F_z\lambda_{Ky\gamma}, \tag{23}$$
$$B_y = \frac{K_{y\alpha}}{C_y D_y}, \tag{24}$$
$$S_{Hy} = S_{Hy0} + S_{Hy\gamma}, \tag{25}$$
$$S_{Hy0} = (p_{Hy1} + p_{Hy2}\,\mathrm{df}_z)\lambda_{Hy}, \tag{26}$$
$$S_{Hy\gamma} = \frac{K_{y\gamma}\gamma - S_{V_{y\gamma}}}{K_{y\alpha}}, \tag{27}$$
$$S_{Vy} = S_{Vy0} + S_{Vy\gamma}, \tag{28}$$
$$S_{Vy0} = F_z\left(p_{Vy1} + p_{Vy2}\,\mathrm{df}_z\right)\lambda_{Vy}\lambda_{\mu y}, \tag{29}$$
$$S_{Vy\gamma} = F_z\left(p_{Vy3} + p_{Vy4}\,\mathrm{df}_z\right)\gamma\,\lambda_{Ky\gamma}\lambda_{\mu y}. \tag{30}$$

Birleşik kayma faktörü ($G_{y\kappa}$) yanal kuvvet için:

$$S_{Vy\kappa} = D_{Vy\kappa}\sin\left(r_{Vy5}\arctan\left(r_{Vy6K}\right)\right)\lambda_{Vy\kappa}, \tag{31}$$
$$D_{Vy\kappa} = \mu_y F_z\left(r_{Vy1} + r_{Vy2}\mathrm{df}_z + r_{Vy3}\gamma\right)\cos\left(\arctan\left(r_{Vy4}\alpha_F\right)\right), \tag{32}$$
$$G_{y\kappa} = \frac{\cos\left[C_{y\kappa}\arctan\left\{B_{y\kappa}\kappa_{\mathrm{s}} - E_{y\kappa}\left(B_{y\kappa}\kappa_{\mathrm{s}} - \arctan\left(B_{y\kappa}\kappa_{\mathrm{s}}\right)\right)\right\}\right]}{\cos\left[C_{y\kappa}\arctan\left\{B_{y\kappa}S_{Hy\kappa} - E_{y\kappa}\left(B_{y\kappa}S_{Hy\kappa} - \arctan\left(B_{y\kappa}S_{Hy\kappa}\right)\right)\right\}\right]}, \tag{33}$$
$$\kappa_{\mathrm{s}} = \kappa + S_{Hy\kappa}, \tag{34}$$
$$B_{y\kappa} = \left(r_{By1} + r_{By4}\gamma^2\right)\cos\left\{\arctan\left[r_{By2}\left(\alpha_f - r_{By3}\right)\right]\right\}\lambda_{y\kappa}, \tag{35}$$
$$C_{y\kappa} = r_{Cy1}, \tag{36}$$
$$E_{y\kappa} = r_{Ey1} + r_{Ey2}\mathrm{df}_z, \tag{37}$$
$$S_{Hy\kappa} = r_{Hy1} + r_{Hy2}\mathrm{df}_z. \tag{38}$$

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. O. Ergun, N. O. Cayci, E. Dincmen and I. Istif, "Optimum Torque Distribution During Regenerative Braking in a Fully Electrical Vehicle via Dynamic Programming," 2023 7th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Ankara, Turkiye, 2023, pp. 1-6, doi: 10.1109/ISMSIT58785.2023.10304931.

Proje

1. "Sürücü davranışı, çevresel koşullar ve araç koşullarını göz önüne alarak rejeneratif frenleme performansını en iyileyen derin öğrenme kontrol algoritmasının geliştirilmesi", Tübitak 1001, proje no: 122M994, 2023-2025.