
GAZİ ÜNİVERSİTESİ
Gazi
1926

ÖZGÜN VERİ SETİ KULLANARAK MAKİNE ÖĞRENMESİ TABANLI ARAÇTAN ŞEBEKEYE ENERJİ AKIŞ YÖNETİMİ

Sadık YILDIZ

DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EKİM 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Sadık YILDIZ

21/10/2024

ÖZGÜN VERİ SETİ KULLANARAK MAKİNE ÖĞRENMESİ TABANLI ARAÇTAN ŞEBEKEYE ENERJİ AKIŞ YÖNETİMİ

(Doktora Tezi)

Sadık YILDIZ

GAZİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Ekim 2024

ÖZET

Bu tez çalışmasında bir yerleşim yerindeki elektrikli araçların enerji akış yönetimi için makine öğrenmesi tabanlı bir çözüm önerisi modeli sunulmuştur. Bu çözüm önerisindeki modelde araçtan-şebekeye enerji akış topolojisi işletilmektedir. Bu amaçla bir yerleşim yerinde oturan 20 araç kullanıcısının bir yıllık kayıtları ile kullanıcı davranışlarını modelleyen özgün bir veri seti oluşturulmuştur. Yakın gelecekte bu yirmi aracın bağlı olduğu şebekede güç problemleri meydana gelmeye başlayacaktır. Bu 20 aracın bağlı olduğu şebekede bir güç problemi meydana geldiğinde yerleşim yerinin otoparkında bulunan araçlardan bir kısmının bataryaları ile şebeke desteklenerek güç problemi giderilene kadar şebekenin güç kalitesinin korunması amaçlanmıştır. Hangi araçların şebekeye enerji aktarması gerektiği bir sınıflandırma problemi haline getirilmiştir. Sınıflandırma probleminin çözümünde literatürde en sık kullanılan 22 adet makine öğrenmesi yöntemi kullanılmıştır. Bu sınıflandırma problemi ile araçtan-şebekeye enerji akış topolojisi işetildiğinde şebekedeki problem giderilene kadar şebekeye bağlı kalma ihtimali en yüksek aracın tahmini gerçekleştirilmiştir. Makine öğrenmesi ile tahmin sonuçları tablosu oluşturulmuştur. Ardından kullanıcıların araçlarının otoparkta bulunma sıklığı hesaplanmıştır. Kullanıcıların kullandıkları araçlar elektrikli araç olmadığından her bir aracın kullanım yoğunluğu hesaplanarak bu değere göre 20 araç için yıl boyunca tesadüfi şarj durum değeri belirlenmiştir. Makine öğrenmesindeki tahmin sonuçları, otoparkta bulunma sıklığı ve şarj durum değerlerini kullanan bir matematik model ile araçtan şebekeye enerji akış topolojisinde şebekeye bağlanacak araçların tespiti gerçekleştirilmiştir. Bu önerilen modelin uygulanabilirliğini gösterebilmek için içerisinde şebeke bağlantılı eviricinin bulunduğu araçtan-şebekeye enerji akış deney düzeneği tasarlanmıştır. Bu deney düzeneği ile mevcut şebekeye enerji akışı gerçekleştirilerek uygulanabilirliği gösterilmiştir. Bu tez çalışması makine öğrenmesi tabanlı yeni ve gerçek zamanlı uygulanabilir bir araçtan-şebekeye enerji akış topolojisi sunmaktadır.

Bilim Kodu	:	93437
Anahtar Kelimeler	:	Mikro şebeke, V2G, G2V, makine öğrenmesi, sınıflandırma, torbalama ağaçları
Sayfa Adedi	:	190
Danışman	:	Prof. Dr. Hasan Hüseyin SAYAN

MACHINE LEARNING BASED VEHICLE TO GRID ENERGY FLOW MANAGEMENT USING A NOVEL DATA SET

(Ph. D. Thesis)

Sadık YILDIZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

October 2024

ABSTRACT

This thesis presents a machine learning based solution proposal model for energy flow management of electric vehicles in a residential area. The model in this proposed solution operates on a vehicle-to-grid energy flow topology. For this purpose, a novel dataset that models user behaviour has been created by keeping the records of 20 vehicle users living in a residential area for one year. When the number of electric vehicles reaches the current number of fossil fuel vehicles, grid integration of electric vehicles will become an important issue. In the near future, power problems will occur in the grid to which these 20 vehicles are connected. When a power problem occurs in the grid to which these 20 vehicles are connected, the goal is to maintain the power quality of the grid until the power problem is resolved by supporting the grid with the batteries of some of the vehicles in the parking lot of the residential area. A classification problem has been created to determine which vehicles should transfer energy to the grid. The 22 most commonly used machine learning methods in the literature have been used to solve the classification problem. This classification problem has been used to predict which vehicles that are most likely to remain connected to the grid until the problem is solved when the vehicle-to-grid energy flow topology is operated. A prediction result table has been created using machine learning. Then, the frequency of users' vehicles in the parking lot has been calculated. Since the vehicles used by the users are not electric vehicles, the usage intensity of each vehicle has been calculated, and the random charging status value for 20 vehicles throughout the year has been determined according to this value. A mathematical model using machine learning prediction results, parking lot frequency and charging status values has been used to identify the vehicles to be connected to the grid in a vehicle-to-grid energy flow topology. In order to demonstrate the applicability of the proposed model, a vehicle-to-grid energy flow experimental setup with a grid-connected inverter has been designed. With this experimental setup, energy flow to the existing grid has been realized and its applicability has been demonstrated. This thesis presents a new machine learning based vehicle-to-grid energy flow topology that can be implemented in real time.

Science Code : 93437
Key Words : Microgrid, V2G, G2V, machine learning, classification, bagged trees
Page Number : 190
Supervisor : Prof. Dr. Hasan Hüseyin SAYAN

TEŞEKKÜR

Tez çalışmam için beni teşvik eden, görüşleri ile beni yönlendiren ve çalışmamın her aşamasında benden hiçbir desteğini esirgemeyen danışman hocam Sayın Prof. Dr. Hasan Hüseyin SAYAN' a teşekkürlerimi sunarım. Doktora eğitimi sürecinde beni destekleyen, her konuda yüreklendiren değerli aileme şükranlarımı sunarım. Çalışmalarımda kıymetli görüşleri ile destek veren değerli arkadaşım Furkan ÜSTÜNSOY'a ve doktora eğitimi sürecinde yaşanan zorluklarda desteğini esirgemeyen Sayın Prof. Dr. Ercan Nurcan YILMAZ'a teşekkürlerimi sunarım. Bu tez çalışması Gazi Üniversitesi Bilimsel Araştırma Projeleri Birimi (BAP Proje Kodu: FDK-2023-8335) tarafından desteklenmiştir.

İÇİNDEKİLER

Sayfa

ÖZET iv

ABSTRACT v

TEŞEKKÜR vi

İÇİNDEKİLER vii

ÇİZELGELERİN LİSTESİ xi

ŞEKİLLERİN LİSTESİ xiii

SİMGELER VE KISALTMALAR xix

1. GİRİŞ 1

2. ELEKTRİKLİ ARAÇLAR 5

2.1. Elektrikli Araç Gelişim Evreleri 5

2.2. Araç Türleri 6

2.3. EV'lerin Temel Bileşenleri 12

2.3.1. EV bataryaları 12

2.3.2. Batarya parametreleri 13

2.3.3. EV motorları 16

3. ELEKTRİKLİ ARAÇ ŞARJ CİHAZLARI VE STANDARTLARI 19

3.1. Elektrikli Araç Şarj Cihazının Sınıflandırılması 19

3.1.1. Güç seviyesine göre şarj işlemi 19

3.1.2. Konumuna göre şarj işlemi 20

3.1.3. Fiziksel bağlantıya göre şarj işlemi 21

3.1.4. Akım türüne göre şarj işlemi 21

3.1.5. Akım yönüne göre şarj işlemleri 22

3.1.6. Koruma durumuna göre şarj işlemleri 22

Sayfa

3.2. Şarj Seviyeleri ve Standartları 23

3.3. Şarj Modları ve Özellikleri 25

3.4. Şarj Arayüzü ve Teknik Özellikleri..... 27

3.5. Elektrikli Araç Batarya Şarj Teknikleri 29

3.5.1. Sabit gerilim (CV) şarj tekniği 29

3.5.2. Sabit akım (CC) şarj tekniği..... 31

3.5.3. Darbe ve negatif darbe şarj teknikleri 31

3.5.4. Sabit akım/sabit voltaj (CC/CV) şarj teknikleri 32

4. ELEKTRİKLİ ARAÇ ŞARJ TOPOLOJİLERİ VE ŞARJ İSTASYONU MİMARİLERİ..... 33

4.1. EV Şarj İstasyonu Mimarileri 34

4.1.1. Geleneksel şarj istasyonu mimarisi 34

4.1.2. AC-DC hibrit bara tabanlı şarj istasyonu mimarisi..... 36

4.1.3. Yenilenebilir enerji kaynağı bağlantılı şarj istasyonu mimarisi..... 37

4.2. EV Şarj İstasyonu Mimarileri Kontrol Yöntemleri 38

4.2.1. Birincil kontrol aşaması 39

4.2.2. İkincil kontrol aşaması 40

4.2.3. Üçüncül kontrol aşaması 40

4.3. Şarj Kontrol Stratejileri 41

4.3.1. Merkezi şarj kontrol stratejisi 41

4.3.2. Merkezi olmayan şarj kontrol stratejisi..... 42

4.4. EV ve Şebeke Arasındaki Çift Yönlü Dönüştürücü Topolojileri 43

4.5. Ticari Elektrikli Araç Batarya Şarj Sistem Mimarileri 50

4.5.1. Dahili batarya şarj cihazlarının sistem mimarileri 50

4.5.2. Harici batarya şarj cihazlarının sistem mimarileri 57

Sayfa

4.6. Çift Yönlü Eviricilerde Kullanılan Anahtarlama Teknikleri 61
4.6.1. SPWM tekniği 62
4.6.2. SVPWM tekniği 64
4.7. Evirici İçin Filtre Tasarımı 68
5. MAKİNE ÖĞRENMESİ YÖNTEMLERİ 73
5.1. Veri Türleri 74
5.1.1. Sayısal veri 74
5.1.2. Kategorik veriler 75
5.2. Öğrenme Modeline Göre Makine Öğrenmesi Türleri 75
5.2.1. Denetimli öğrenme 75
5.2.2. Denetimsiz öğrenme 77
5.2.3. Yarı denetimli öğrenme 79
5.2.4. Takviyeli öğrenme 80
5.3. Makine Öğrenmesi İle Uygulama Geliştirme Süreçleri 81
5.3.1. Problemin tanımlanması 81
5.3.2. Ham verinin elde edilmesi 82
5.3.3. Veri ön işleme süreci 83
5.4. Makine Öğrenmesi Sınıflandırma Türleri 86
5.4.1. Karar ağacı 87
5.4.2. Lojistik regresyon 91
5.4.3. Naive Bayes 94
5.4.4. Destek vektör makineleri 98
5.4.5. Topluluk (Kolektif) öğrenme 107
5.4.6. K-En yakın komşu 115

Sayfa

5.4.7. K-katlı çapraz doğrulama 121
5.4.8. Yapay sinir ağları 122
5.5. Sınıflandırma Yöntemlerinde Performans Değerlendirme Ölçütleri 131
5.5.1. Doğruluk 132
5.5.2. Kesinlik 133
5.5.3. Duyarlılık 133
5.5.4. Özgüllük 133
5.5.5. F1 skoru 133
5.5.6. ROC eğrisi ve AUC değeri 134
5.5.7. Cohen'in Kappa Katsayısı (κ) 134
5.5.8. Eğitim süresi 134
6. UYGULAMA ÇALIŞMALARI VE SONUÇLAR 135
6.1. Makine Öğrenmesi Uygulama Çalışmaları 135
6.1.1. Araç sürücü bilgileri ve ham verinin toplanması 136
6.1.2. Veri setinin oluşturulması 138
6.1.3. Veri setinin makine öğrenmesi yöntemleri ile analizi 140
6.1.4. V2G topolojisinde EV seçimi 145
6.2. V2G topolojisinin simülasyonları ve uygulaması 151
6.2.1. V2G topolojisinde tek fazlı enerji akış yönetimi simülasyonu 152
6.2.2. V2G topolojisinde üç fazlı enerji akış yönetimi simülasyonu 160
6.2.2. Tek fazlı şebeke bağlantılı evirici uygulaması 165
7. SONUÇ VE ÖNERİLER 173
KAYNAKLAR 177
ÖZGEÇMİŞ 189

ÇİZELGELERİN LİSTESİ

Çizelge **Sayfa**

Çizelge 2.1. Farklı marka, model EV'ler ve özellikleri 11

Çizelge 2.2 Yakıt türüne göre araçların sınıflandırılması 11

Çizelge 2.3. Batarya türlerine ait parametre değerleri 14

Çizelge 2.4. Farklı marka ve model EV'lerde kullanılan motor türleri 18

Çizelge 3.1. EV şarj seviyeleri ile uluslararası standartlar arasındaki karşılaştırma 24

Çizelge 3.2. Farklı şarj modlarının karşılaştırılması 26

Çizelge 3.3. Arayüz bağlantı ucu açıklamaları 28

Çizelge 3.4. Marka/modeline göre EV motor ve batarya özellikleri 30

Çizelge 4.1. Şarj istasyonlarında AC ve DC bara mimarilerinin karşılaştırması..... 36

Çizelge 4.2. EV şarj kontrol modunu belirleyen parametreler..... 41

Çizelge 4.3. Piyasada dahili şarj cihazına sahip EV'lerin özellikleri 57

Çizelge 4.4. Marka/modele göre harici ultra hızlı ve hızlı şarj cihazlarının özellikleri.. 61

Çizelge 4.5. SVPWM anahtar konumuna göre faz-nötr ve faz-faz gerilimleri..... 66

Çizelge 5.1. Tez çalışmasında kullanılan makine öğrenmesi sınıflandırma yöntemleri. 87

Çizelge 6.1. Araç sürücü meslek, cinsiyet ve hanedeki araç sayısı dağılımları..... 138

Çizelge 6.2. Veri seti öznitelikleri ve sınıf etiketleri 138

Çizelge 6.3. Gün tipi değişkenine ait değerler 139

Çizelge 6.4. ML yöntemlerinin performans değerleri..... 140

Çizelge 6.5. Bagged Trees Ac değeri ölçüm sonuçları 141

Çizelge 6.6. Bagged Trees hata matrisi..... 141

Çizelge 6.7. ML yöntemlerinin alt veri setlerindeki doğruluk değerleri (1)..... 144

Çizelge 6.8. ML yöntemlerinin alt veri setlerindeki doğruluk değerleri (2)..... 145

Çizelge 6.9. EV'lerin F_i ve D_i değerleri ile veri tabanı sınıf etiketleri sayısı 151

Çizelge **Sayfa**

Çizelge 6.10. Tek faz enerji akış sisteminin bileşen değerleri 157

Çizelge 6.11. Üç faz enerji akış sisteminin bileşen değerleri 161

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 2.1. EV'lerin gelişim süreci 6

Şekil 2.2. İçten yanmalı motorlu araç (ICEV) 7

Şekil 2.3. Hibrit elektrikli araç (HEV) 7

Şekil 2.4. Prize takılabilir hibrit elektrikli araç (PHEV) 8

Şekil 2.5. Bataryalı elektrikli araç (BEV) 9

Şekil 2.6. Yakıt hücreli elektrikli araç (FCEV) 9

Şekil 2.7. Artırılmış mesafeli EV (ER-EV) 10

Şekil 2.8. Elektrikli araç türleri 11

Şekil 2.9. EV batarya paketi enerji depolama sınıflandırması 13

Şekil 2.10. Bataryaların hacimsel ve kütlesel güç yoğunluklarının dağılımı 15

Şekil 2.11. EV'lerde kullanılan temel elektrik motorlarının sınıflandırılması 17

Şekil 2.12. ICE motor ile elektrik motoru tork ve güç karşılaştırma grafiği 18

Şekil 3.1. EV şarj cihazının sınıflandırılması 19

Şekil 3.2. (a) Dahili şarj cihazı ile şarj işlemi (b) Harici şarj cihazı ile şarj işlemi 20

Şekil 3.3. Dahili ve harici EV şarj sistemi 23

Şekil 3.4. EV şarj modları a) Mod 1 b) Mod 2 c) Mod 3 d) Mod 4 26

Şekil 3.5. EV hızlı şarj arayüzleri (a) CCS Combo 1 (b) CCS Combo 2 (c) CHAdeMO (d) GB/T 20234.3 (e) Tesla Supercharger (f) CHAdeMO 27

Şekil 3.6. Farklı standartlarda EV şarj arayüz portu bağlantı noktalarının pin görünümü 28

Şekil 3.7. Farklı standartlarda EV şarj konektörleri 29

Şekil 3.8. Darbe ve negatif darbe şarj tekniklerinin işleyişi 32

Şekil 3.9. CC/CV şarj tekniği akım ve gerilim grafiği 32

Şekil 4.1. EV şarj topolojilerini gösteren mikro şebeke 34

Şekil **Sayfa**

Şekil 4.2. AC baralı geleneksel şarj istasyonu mimarisi 35

Şekil 4.3. DC baralı geleneksel şarj istasyonu mimarisi 35

Şekil 4.4. AC-DC hibrit bara tabanlı şarj istasyonu mimarisi 37

Şekil 4.5. YEK bağlantılı AC bara tabanlı EV şarj istasyonu mimarisi 38

Şekil 4.6. Hiyerarşik kontrol stratejisi 39

Şekil 4.7. Merkezi şarj kontrol stratejisi 42

Şekil 4.8. Merkezi olmayan şarj kontrol stratejisi 43

Şekil 4.9. Tek faz çift yönlü evirici ve çift yönlü artıran-azaltan DC/DC çeviriciden oluşan izolesiz dahili, şarj cihazı mimarisi 45

Şekil 4.10. Tek fazlı çift yönü evirici ve çift yönlü kaskat azaltan -artıran DC/DC çeviriciden oluşan dahili, şarj cihazı mimarisi 46

Şekil 4.11. Çift yönlü sekiz anahtarlı evirici ve çift yönlü faz kaymalı DC/DC çeviriciden oluşan izolesiz dahili, şarj cihazı mimarisi 47

Şekil 4.12. Çift yönlü tek fazlı evirici ve çift yönlü izoleli tam köprü DC/DC çeviriciden oluşan izoleli dahili, şarj cihazı mimarisi 48

Şekil 4.13. Çift yönlü rezonans dönüştürücünün çalışma prensibi 49

Şekil 4.14. Çift yönlü tek fazlı evirici ve çift yönlü LC rezonans devreli tam köprü DC/DC çeviriciden oluşan izoleli dahili, şarj cihazı mimarisi 49

Şekil 4.15. Dahili şarj cihazı mimarisi (a) Özel şarj cihazı (b) Entegre şarj cihazı 51

Şekil 4.16. İkinci nesil Volt dahili özel şarj cihazının mimarisi 52

Şekil 4.17. Tesla Model 3/Y dahili özel şarj cihazı mimarisi 53

Şekil 4.18. Hyundai V2D destekli dahili özel şarj cihazı mimarisi 53

Şekil 4.19. Hella Electronic dahili özel şarj cihazı mimarisi 54

Şekil 4.20. Renault Chameleon dahili entegre şarj cihazı mimarisi 55

Şekil 4.21. Valeo dahili entegre şarj cihazı mimarisi 55

Şekil 4.22. Continental dahili entegre şarj cihazı mimarisi 56

Şekil 4.23. Galvanik izoleli, çekiş eviricili dahili entegre şarj cihazı mimarisi 56

Şekil **Sayfa**

Şekil 4.24. Geleneksel harici şarj cihazı mimarisi 58

Şekil 4.25. Harici şarj cihazı (a) ABB Terra 53/54 50 kW hızlı şarj cihazı mimarisi (b) ABB Terra HP 150 kW yüksek güçlü şarj cihazı mimarisi 59

Şekil 4.26. Harici şarj cihazı (a) Porsche modüler hızlı şarj cihazı Park A mimarisi (b) Porsche modüler hızlı şarj cihazı Park B mimarisi 60

Şekil 4.27. Tesla Supercharger V2 harici şarj cihazı mimarisi 61

Şekil 4.28. Üç fazlı yarım köprü evirici anahtarlama elemanlarının bağlantı şeması 62

Şekil 4.29. SPWM üretimine ilişkin örnek dalga formları 62

Şekil 4.30. SPWM anahtarlama şeması 63

Şekil 4.31. SPWM anahtarlama sinyalinin elde edilmesine ait blok şema 63

Şekil 4.32. SVPWM anahtarlama vektörü 65

Şekil 4.33. Park (dq0) dönüşümü 65

Şekil 4.34. Sektör 1 vektörleri 67

Şekil 4.35. Temel Güç Filtreleri: (a) L Filtre (b) LC Filtre (c) LCL Filtre 69

Şekil 4.36. LCL filtreli üç faz şebeke bağlantılı evirici 69

Şekil 5.1. Veri türleri şeması 74

Şekil 5.2. Öğrenme modeline göre makine öğrenmesi türleri 75

Şekil 5.3. Regrasyon eğrisi (a) Doğrusal regrasyon (b) Doğrusal olmayan regrasyon ... 76

Şekil 5.4. Sınıflandırma eğrisi. (a) Doğrusal (b) Doğrusal olmayan 77

Şekil 5.5. Kümeleme yöntemi ile veri setinin gruplandırılması 77

Şekil 5.6. Bir veri setinde öznitelikler için boyut azaltma 78

Şekil 5.7. Takviyeli öğrenme süreci örneği 81

Şekil 5.8. Makine öğrenmesi ile uygulama geliştirme süreçleri 82

Şekil 5.9. Karar ağacı genel yapısı 88

Şekil 5.10. Karar ağacının çalışma süreci 88

Şekil **Sayfa**

Şekil 5.11. Lojistik regresyon sınıflandırma eğrisi 92

Şekil 5.12. Sigmoid fonksiyonun logaritma dönüşümü (y=0 için) 93

Şekil 5.13. Sigmoid fonksiyonun logaritma dönüşümü (y=1 için) 93

Şekil 5.14. Doğrusal SVM (a) 1 boyutlu (nokta) ayırıcı (b) 2 boyutlu (çizgi) ayırıcı (c) 3 boyutlu (düzlem) ayırıcı 99

Şekil 5.15. Doğrusal olmayan SVM (a) 1 boyutlu ayırıcı (b) 2 boyutlu ayırıcı (c) 3 boyutlu ayırıcı 99

Şekil 5.16. SVM'de destek vektörleri, hiper düzlem ve marj 100

Şekil 5.17. Marj (kenar payı) geometrik gösterimi 101

Şekil 5.18. Esnek marj gösterimi 104

Şekil 5.19. Torbalama yöntemi mimarisi 110

Şekil 5.20. Güçlendirme (Artırım) yöntemi mimarisi 111

Şekil 5.21. Yığınlama (İstifleme) yöntemi mimarisi 113

Şekil 5.22. KNN sınıflandırma modeli 115

Şekil 5.23. İki nokta arasındaki Öklid mesafesi 116

Şekil 5.24. İki nokta arasındaki Manhattan mesafesi 117

Şekil 5.25. İki nokta arasındaki Minkowski mesafesi 118

Şekil 5.26. İki nokta arasındaki Chebyshev mesafesi 118

Şekil 5.27. Kosinüs benzerliği modeli 119

Şekil 5.28. K-kat çapraz doğrulama 121

Şekil 5.29. Biyolojik nöronun şematik gösterimi 122

Şekil 5.30. YSA eşik değer modeli 123

Şekil 5.31. Perceptron YSA modeli 124

Şekil 5.32. YSA sınıflandırma modelleri için aktivasyon fonksiyonları ve türevleri 125

Şekil 5.33. Derin sinir ağı mimarisi 130

Şekil **Sayfa**

Şekil 5.34. Gerçekleştirilen YSA modeli 131

Şekil 5.35. Hata matrisi 132

Şekil 6.1. Araç plaka tanıma sistemi 136

Şekil 6.2. ML yöntemlerinin doğruluk grafiği 142

Şekil 6.3. ML yöntemlerinin kesinlik grafiği 142

Şekil 6.4. ML yöntemlerinin duyarlılık grafiği 142

Şekil 6.5. ML yöntemlerinin özgüllük grafiği 143

Şekil 6.6. ML yöntemlerinin F1 skoru grafiği 143

Şekil 6.7. ML yöntemlerinin AUC grafiği 143

Şekil 6.8. ML yöntemlerinin süre grafiği 144

Şekil 6.9. Veri setindeki EV'lere ait mikro şebeke 146

Şekil 6.10. Bagged Trees örneklem işlemi 146

Şekil 6.11. Tasarlanan sistemin akış diyagramı 149

Şekil 6.12. V2G topolojisinde enerji akışı için tek fazlı mikro şebeke tasarımı 152

Şekil 6.13. Çift yönlü DC/DC dönüştürücü 153

Şekil 6.14. Çift yönlü DC/DC dönüştürücü (a) Batarya şarj referans akımının (Iref) üretilmesi (b) Batarya deşarj referans akımının (Iref) üretilmesi (c) PWM kontrol sinyalinin üretilmesi 155

Şekil 6.15. Tek faz şebeke bağlantılı evirici 156

Şekil 6.16. Tek faz şebeke bağlantılı evirici blog diyagramı 156

Şekil 6.17. Şebeke ve EV batarya enerji akış grafiği 158

Şekil 6.18. Tasarlanan sistemde şebekenin akım gerilim grafiği 158

Şekil 6.19. EV bataryasının SOC, akım, gerilim ve güç grafiği 159

Şekil 6.20. Şebekenin FFT analizi ile THD değerinin belirlenmesi 160

Şekil 6.21. V2G topolojisinde kullanılan üç fazlı şebeke bağlantılı evirici modeli 161

Şekil **Sayfa**

Şekil 6.22. Üç faz şebeke bağlantılı evirici blog diyagramı 162

Şekil 6.23. 3 faz evirici çıkışının V-I grafiği a) LCL filtreli b) Filtresiz 162

Şekil 6.24. Şebekenin enerji akış grafiği 163

Şekil 6.25. Ev batarya grubunun enerji akış grafiği..... 164

Şekil 6.26. FFT analizi (a) L Filtre için (b) LC Filtre için (c) LCL Filtre için 164

Şekil 6.27. Tek fazlı şebeke bağlantılı evirici sistem mimarisi 165

Şekil 6.28. Tek fazlı şebeke bağlantılı evirici deney düzeneği..... 165

Şekil 6.29. AC ana şebeke akım ve gerilim ölçümü..... 166

Şekil 6.30. Evirici şebekeye bağlandıktan sonraki şebeke akım ve gerilim grafiği 166

Şekil 6.31. AC ana şebeke akım ve gerilim ölçümü..... 167

Şekil 6.32. Evirici akım ve gerilim ölçümü..... 167

Şekil 6.33. Evirici şebekeye bağlandığında evirici akım ve gerilim ölçümleri 168

Şekil 6.34. Eviricinin şebekeye bağlanma anı akım ve gerilim ölçümü..... 168

Şekil 6.35. Şebeke akım ve geriliminin csv dosyasından MATLAB ile çizdirilmesi 169

Şekil 6.36. Gerilimin FFT analizi 170

Şekil 6.37. Evirici bağlanmadan önce akımın FFT analizi..... 170

Şekil 6.38. Evirici bağlandıktan sonra akımın FFT analizi 171

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	**Açıklamalar**
A	Akım birimi amper
Ah	Amper saat
C	Yük birimi Coulomb
°C	Sıcaklık birimi santigrat derece
Km	Kilo metre
kW	Kilo watt
kWh	Kilo watt saat
Li-ion	Lityum iyon
NiCd	Nikel kadmiyum
NiMH	Nikel metal hidrit
Pb-acid	Kurşun acit
V	Gerilim birimi volt
W/kg	Watt/kilo gram
Wh	Watt saat
Wh/kg	Watt saat/kilo gram

Kısaltmalar	**Açıklamalar**
ACIM	AC indüksiyon motor
BEDS	Batarya enerji depolama sistemi
BEV	Bataryalı elektrikli araç (Battery electric vehicle)
BLDC	Fırçasız DC motor (Brushless DC motor)
BYS	Batarya yönetim sistemi
CC	Sabit akım (Constant current)
CCS	Volkswagen firmasının şarj soketi
CHAdeMO	Elektrikli araç şarj standartı

Kısaltmalar	Açıklamalar
CV	Sabit voltaj (Constant voltage)
DCM	DC motor (fırçalı)
DEK	Dağıtık enerji kaynakları
EMI	Elektromanyetik girişim filtresi
ER-EV	Artırılmış mesafeli EV (Extended range EV)
EV	Elektrikli araç (Electric vehicle)
EYS	Enerji yönetim sistemi
FCEV	Yakıt hücreli EV (Fuel cell EV)
G2V	Şebekeden araca enerji akışı (Grid to vehicle)
GB/T	Çin şarj soketi standarttı
GFD	Güç faktörü düzeltmesi
HEV	Hibrit eletrikli araç (Hybrid electric vehicle)
ICE	İçten yanmalı motor (Internal combustion engine)
ICEV	İçten yanmalı motorlu araç
IEC	Uluslararası Elektro-Teknik Komisyonu
KNN	K-En yakın komşu (K-Nearest Neighbour)
ML	Makine öğrenmesi (Machine learning)
OOB	Torba dışı veriler (Out of bag)
PEV	Prize takılabilir EV (Plug-in electric vehicle)
PHEV	Prize takılabilir hibrit elektrikli araç
PLL	Faz kilitli döngü (Phase locked loop)
PMSM	Kalıcı mıknatıslı senkron motor
PV	Fotovoltaik panel (Güneş paneli)
PWM	Darbe genişliği modülasyonu
SAE	Kuzey Amerika Otomotiv Mühendisleri Derneği
SC	Süper kapasitör (Super capacitor)
SOC	Şarj durum değeri (State of charge)
SOD	Deşarj durum değeri (State of decharge)
SOH	Batarya sağlık durum değeri (State of health)
SPWM	Sinüs PWM
SVPWM	Uzay vektör (Space vector) PWM
THD	Toplam harmonik bozunum değeri

Kısaltmalar	Açıklamalar
V2B	Araçtan binaya enerji akışı (Vehicle to building)
V2D	Araçtan cihaza enerji akışı (Vehicle to device)
V2G	Araçtan şebekeye enerji akışı (Vehicle to grid)
V2H	Araçtan eve enerji akışı (Vehicle to home)
V2L	Araçtan yüke enerji akışı (Vehicle to load)
V2V	Araçtan araca enerji akışı (Vehicle to vehicle)
YEK	Yenilenebilir enerji kaynakları
YSA	Yapay sinir ağları

1. GİRİŞ

Dünya genelinde teknolojinin hızla gelişmesi ve nüfusun artmasıyla birlikte insanoğlu çevresel problemler ve enerji kaynaklarının azalması ile yüz yüze gelmektedir. Çevresel problemlerin en başında gelen karbon gazı emisyonunun artması nedeniyle atmosferdeki sera gazı seviyesinin ciddi oranda artmasıdır. Bu durum ozon tabakasının incelmesi, dünyanın ortalama sıcaklığının yükselmesi ile iklim değişikliği/krizinin yaşanmasına ve fosil yakıtların giderek azalması gibi zararlı çevresel değişikliklere neden olmaktadır. Karbon emisyonunun azaltılarak sürdürülebilir bir enerji sisteminin oluşturulması için farklı alanlarda çalışmalar yapılmaktadır [1]. Bu alanlardan ulaşım sistemlerinde içten yanmalı motorla çalışan araçların yerini hızla çevre dostu, sürdürülebilir elektrikli araçlar (EV) almaktadır. Bu bağlamda, fosil yakıtlara olan bağımlılığın azalması ve yanıcı gaz emisyonunun sıfır olması nedeniyle elektrikli araçların popülaritesi çok hızlı artmaktadır. Uluslararası Enerji Ajansı'nın verilerine göre 2030 yılına kadar dünya genelinde elektrikli araç sayısının 145 milyonun üzerinde olacağı tahmin ediliyor [2]. Ülkemizde 2012 yılında 92 adet tamamen elektrikli araç satılmıştır. 2023 yılında ise prizle şarj edilebilir hibrit otomobil miktarı 4900 adet stokta ve 2700 adet satılmış toplam 7600 adet olmuştur. Tamamen elektrikli araç miktarı ise 66 000 adet satış miktarı ve 77 000 adet stok miktarı ile toplamda 143 000 adet olmuştur. 2012 yılında ülkemizde halka açık şarj istasyonu hiç yokken 2023 yılında ülkemizde hızlı şarj istasyonu sayısı 800'e, yavaş şarj istasyonu sayısı 7000'e ulaşmıştır [3]. Halka açık şarj istasyonlarının yanında EV sahipleri konutlarına kişisel şarj istasyonlarını da kurmaktadır.

Bu verilerden de görüldüğü gibi hem çevresel nedenlerden hem de fosil yakıtların azalmasından dolayı EV ulaşımda daha çok tercih edilir hale geldi. Bu nedenle dünya genelinde birçok hükümet EV kullanılması ve EV üretim teknolojileri konularında teşvik politikaları uygulamaktadır. EV teknolojisinin gelişimi ve EV kullanımını teşvik etmeye yönelik hükümet politikaları, EV'lerin pazara nüfuz etmesi üzerinde etkili oldu. Sonuç olarak son yıllarda EV sayısı önemli ölçüde artmaya başladı [4]. T.C. Enerji Piyasası Denetleme Kurulu Nisan 2024 Elektrikli Araç ve Şarj Altyapısı Projeksiyonu raporunda da belirttiği gibi Türkiye'de EV kullanılması, üretilmesi ve şarj altyapısı konusunda etkili teşvik programları ve politikalar geliştirilmektedir [5]. Böylece Türkiye'de de EV kullanımının arttırılması hedeflenmektedir.

Dünya genelinde EV kullanıcılarının sayısı arttıkça ana şebekeler üzerindeki arz talep dengesi bozulmaktadır. Bu nedenle EV'lerin şebekeye entegrasyonu mevcut şebekeye öngörülemeyen büyük yükler bindirecektir [6]. Bu öngörülemeyen yükler şebekede güç kalitesi problemlerine neden olacaktır [7, 8, 9]. Bu problemler nedeniyle dünya genelinde EV'lerin şebeke entegrasyonuna ilişkin çok sayıda çalışma yapılmıştır. Yapılan çalışmalarda EV'nin şebeke entegrasyonu için enerji akış topolojileri geliştirilmiştir. Geliştirilen bu topolojilerde araçtan şebekeye enerji aktarımı (V2G), araçtan eve enerji aktarımı (V2H), şebekeden araca enerji aktarımı (G2V), araçtan araca enerji aktarımı (V2V) gibi enerji akış topolojileri önerilmektedir [6, 10-13].

EV'ler şebeke entegrasyonunda, şebekeyi olumsuz etkileyebilecek dengesiz yükler olmalarına rağmen, dağıtım sistemindeki potansiyel aşırı yükleri azaltmak, şebeke frekansını dengelemek ve aynı süreçte şarj maliyetlerini en aza indirmek için de kullanılabilirler [13-15]. Başka bir deyişle EV'ler akıllı şebeke açısından kontrol edilebilir jeneratörler olarak değerlendirilebilir. Bu nedenle V2G topolojisi, şebeke entegrasyonu için geliştirilen topolojiler açısından kritik öneme sahiptir [6, 11].

Dünya genelinde EV'lerin şebeke entegrasyonuna ilişkin çok sayıda çalışma yapılmaktadır. Türkiye'de de sanayi ve tarımdaki gelişmeler ile büyüyen kentleşme, gelişmekte olan ülkelerde olduğu gibi ana şebeke üzerinde sürekli bir yük artışına neden olmaktadır. Bu yük artışına rağmen Türkiye'de EV'lerin şebeke entegrasyonuna ilişkin yeterli çalışma mevcut değildir. Bu nedenle Türkiye'de EV'lerin ana şebeke entegrasyonu için çalışmalar yapılarak çözüm önerileri sunulması gerekmektedir.

Bu amaçla ana şebekelerde elektrik altyapısının öngörülen yük artışlarını karşılayacak şekilde planlamalarının yapılması gerekmektedir. Ayrıca yenilenebilir enerji kaynaklarının (YEK) ve enerji depolama sistemlerinin teknolojilerinin gelişmesi ve maliyetlerinin düşmesi, abonelerin elektrik üretimine katılmasını sağlamaktadır. Elektriği üreten ve tüketen bu abonelere üreten tüketici adı verilmektedir [16, 17]. EV'nin elektrik sistemine entegrasyonunda V2G topolojisi sayesinde aboneler üreten tüketici özelliği kazanmaktadır. EV'ler uzun süreli park etme olanağına sahip olduklarından bataryaları V2G topolojisinde enerji depolama sistemi olarak kullanmaktadır [4, 17, 18].

Bu tez çalışmasında Türkiye'nin Başkenti Ankara'da bulunan bir yerleşim yerindeki EV'lerin şebeke entegrasyonu için makine öğrenmesi (ML) tabanlı bir çözüm önerisi modeli sunulmaktadır. Bu çözüm önerisinde sunulan modelde EV'nin şebeke entegrasyonunda V2G topolojisinde ML tabanlı enerji akış modeli işletilmektedir. Araç sürücülerinin araç kullanma davranışlarının aracın yakıt türüne göre değişmeyeceğinden bir yerleşim yerinde oturan fosil yakıt kullanan yirmi araç sürücüsünün kayıtları bir yıl süreyle tutularak sürücü davranışlarını modelleyen bir veri seti oluşturuldu. Yakın gelecekte EV'ler zamanla bu yirmi fosil yakıtlı araçların yerini aldığında EV'lerin şebeke entegrasyonu önemli bir konu haline gelecektir. Bu yirmi EV'nin bağlı olduğu şebekede arz talep dengesi bozulduğunda güç problemleri meydana gelmeye başlayacaktır. Bu yirmi EV'nin şebeke entegrasyonundan dolayı şebekede bir güç kalitesi problemi meydana geldiğinde yerleşim yerinin otoparkında bulunan EV'lerden bir kısmının bataryaları ile şebeke desteklenerek arz talep dengesi korunarak güç kalitesi probleminin giderilmesi amaçlanmaktadır.V2G topolojisi işletileceği esnada enerji akışının hangi araçların bataryaları ile sağlanması gerektiği bir ML sınıflandırma problemi haline getirildi. Sınıflandırma problemi ile enerji akış modeli için V2G topolojisi işletildiğinde şebekedeki güç kalitesi problemi giderilene kadar şebekeye bağlı kalma ihtimali en yüksek araç gurubunun tahmin işlemi gerçekleştirildi. Sınıflandırma probleminin çözümünde literatürde en sık kullanılan 22 adet ML yöntemi kullanıldı. ML yöntemi ile tahmin sonuçları tablosu oluşturuldu. Ardından sürücülerin araçlarının otoparkta bulunma sıklığı hesaplandı. Sürücülerin kullandıkları araçlar EV olmadığından her bir aracın kullanım yoğunluğu hesaplanarak bu değere göre 20 araç için yıl boyunca tesadüfi şarj durum değeri (SOC) belirlendi. ML tahmin sonuçları, otoparkta bulunma sıklığı ve şarj durum değerlerini kullanan bir matematik model ile V2G topolojisinde şebekeye bağlanacak araçların tespiti gerçekleştirildi. Bu önerilen modelin uygulanabilirliğini gösterebilmek için içerisinde şebeke bağlantılı eviricinin bulunduğu V2G topolojisi için enerji akış modeli tasarlandı. Bu enerji akış modeli ile mevcut şebekeye enerji akışı gerçekleştirilerek bu tez çalışmasında önerilen modelin uygulanabilirliği gösterildi. Bu tez çalışması ile ülkemizde ve dünyanın farklı yerlerinde EV'lerin şebeke entegrasyonu için V2G topolojisinde ML tabanlı yeni, gerçek zamanlı ve uygulanabilir enerji akış modeli sunulmaktadır.

Bu tez çalışması yedi bölümden oluşmaktadır. İkinci bölümde EV gelişim evreleri ile EV türlerine ve EV'lerde kullanılan temel bileşenler hakkında genel bir bakış sunulmuştur. Üçüncü bölümde ise EV şarj cihazının sınıflandırılması, şarj standartları ve EV batarya şarj teknikleri hakkında genel bir bakış sunulmuştur. Dördüncü bölümde EV şarj istasyonu mimarileri ile kontrol yöntemleri, dönüştürücü topolojileri ile anahtarlama teknikleri ve ticari EV batarya şarj sistem mimarileri konuları incelenmiştir. Beşinci bölümde ML temel kavramları, ML sınıflandırma yöntemleri ve ML performans ölçüm yöntemleri konuları incelenmiştir. Altıncı bölümde uygulama çalışmaları ve sonuçları verilmiştir. Yedinci bölümde ise sonuç ve önerilere yer verilmiştir.

2. ELEKTRİKLİ ARAÇLAR

Bu bölümde EV gelişim evreleri ile EV türlerine ve EV'lerde kullanılan temel bileşenler batarya ile elektrik motorları hakkında genel bir bakış sunulmuştur.

2.1. Elektrikli Araç Gelişim Evreleri

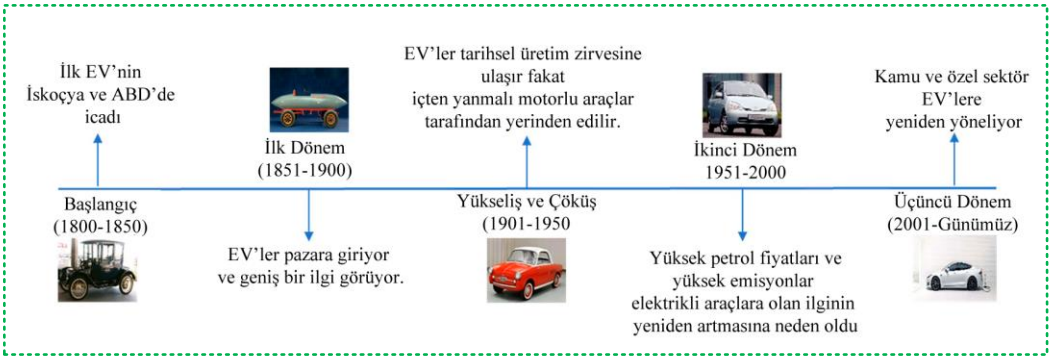
EV'lerin tarihi, ilk EV prototiplerinin Robert Anderson tarafından üretildiği 19. yüzyılın başlarına kadar uzanır. 19. yüzyılın son çeyreğinde aralarında elektrik motoruna sahip araçlarında olduğu önemli sayıda taşıt karayollarında görülmeye başlandı. Özellikle ABD'de elektrikli araçların menzilinin kısa mesafeli otoyollar için yeterli olması nedeniyle elektrikli araçlar yaygınlaştı. Elektrikli araçlar 1900-1912 yılları arasında altın çağını yaşasa da elektrikli araç kullanım maliyeti içten yanmalı motorlu araçlara (ICEV) göre üç kat daha pahalı hale geldi. Bununla birlikte, yeni yolların inşası ve desteklenen ICEV'lerin artan kullanımları ve gelişimleri, EV'lerin popülaritesinin azalmasına neden olmuştur. Böylece ABD'de 1912 yılında Ford Model-T'nin üretilmesiyle ICEV sayısı elektrikli araç sayısından fazla oldu. Bu gelişme, elektrikli araçların bulunabilirliğinin sona erdiğinin sinyalini vermiş ve 20. yüzyılın son çeyreğine kadar elektrikli araçlar karayolu taşımacılığında tercih edilmemeye başlanmıştır. EV'ler 20. yüzyılda uzun süre golf arabaları ve teslimat araçları gibi sınırlı amaçlarla kullanılmıştır. 20. yüzyılın sonuna kadar EV kavramı tramvaylar, metrolar, elektrikli arabalar, elektrikli trenler, troleybüsler vb. gibi en azından kısmen elektrikle çalıştırılan araçlar için kullanılmıştır [4, 19, 20].

Elektrikli araçlarda asıl gelişme 1990'lı yıllardan sonra yeni pil teknolojileri ile sağlanmıştır. Toyota, Hibrit Elektrikli Araç (HEV) olan Toyota Prius'u 1997 yılında Japonya'da piyasaya sürdü. Bu araç, konforu ve ekonomik dönüşümüyle müşterilerinin beklentilerine büyük oranda cevap verdiğinden elektrikli araçların ilk büyük ölçekli seri üretimi olmuştur. Renault, Peugeot ve Citroen de Toyota ile eş zamanlı olarak Avrupa'da üretime başladı. Özellikle son yirmi yılda EV'ler yukarıda bahsedilen üretimlerle yeniden pazara girmiş oldu [4].

Tesla şirketi, EV'nin üretim hareketliliğinde büyük bir kilometre taşı oldu. Superchargers ağı tarafından desteklenen bataryalı elektrikli araç (BEV) olan Roadster, 2006 yılında

Tesla Motors tarafından üretildi. Tesla, yüksek fiyatına rağmen tahmini rakamın üzerinde satış başarısı yakaladı [4,19]. Ardından 2010 yılında Nissan Leaf ve Chevrolet Volt piyasaya sürüldü. Diğer şirketlerde elektrikli araçların seri üretimine başladı. Günümüzde hemen hemen tüm araç markalarının elektrikli araç modeli bulunmaktadır [19-21].

Şekil 2.1'deki zaman çizelgesinde [22], EV'lerin gelişim süreci gösterilmektedir. Bugün, EV'lerin, sera gazı salınımını azaltması, edinim maliyetlerinin düşmesi, batarya teknolojisinin hızlı gelişmesi ve dünyanın dört bir yanındaki hükümetler tarafından çeşitli politikalar ile EV kullanımının teşvik edilmesi nedeniyle EV'ler geleneksel ICEV'lerden daha popüler bir alternatif haline gelmiştir [19, 20, 22].

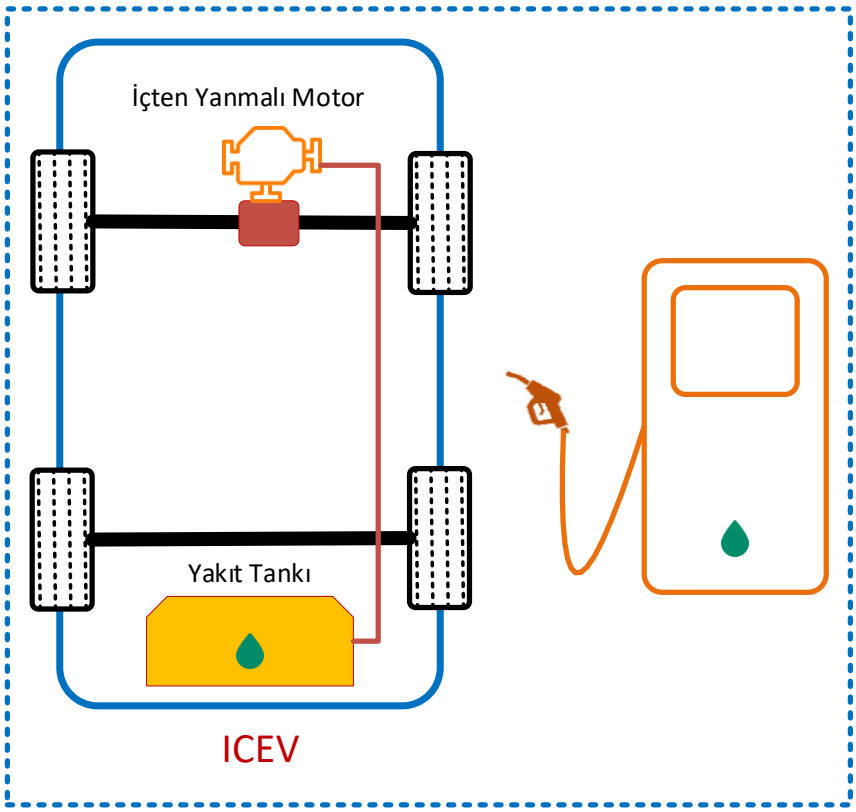


Şekil 2.1. EV'lerin gelişim süreci

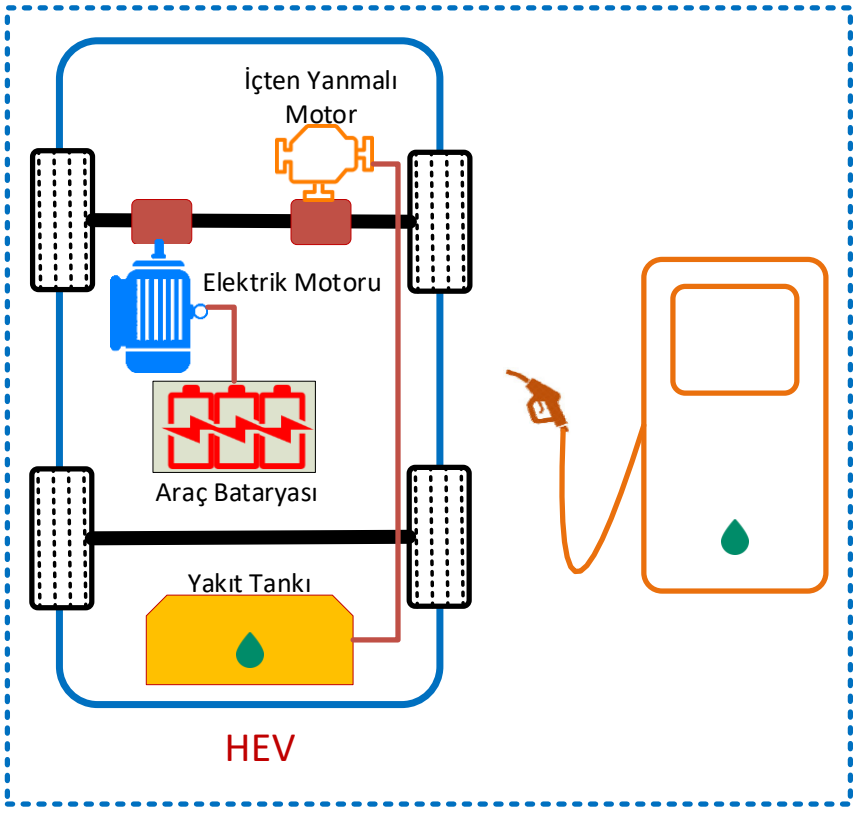
2.2. Araç Türleri

Günümüzde karayolundaki araçları kullandıkları enerji modeline göre sınıflandırabiliriz. Bu sınıflandırmada altı farklı teknoloji türüne sahip araçlar bulunmaktadır. Burada ilk araç türü ICEV'dir (Şekil 2.2). ICEV'ler geleneksel olarak fosil kaynaklı akaryakıtları kullanır. Araç üzerinde bulunan batarya (akü) ateşleme işlemi için kullanılır.

Sınıflandırmadaki ikinci araç türü hem içten yanmalı motora hem de elektrik motoruna sahip hibrit araçlardır. Bu araçlar hibrit EV (HEV) olarak isimlendirilir (Şekil 2.3). Bu araçlarda içten yanmalı motorun (ICE) çalışması için bir yakıt tankı bulunur. Elektrik motoru ise yakıt verimliliğini artırmak ve emisyonu azaltmak için içten yanmalı motora destek olur. Bu araçlar batarya bitene kadar veya ICE moduna geçene kadar elektrikle çalışır. Araç bataryası ICE modunda iken içten yanmalı motorun ürettiği enerjiyle veya rejeneratif frenleme teknolojisiyle aracın frenleme enerjisini geri kazanarak şarj olur [23].

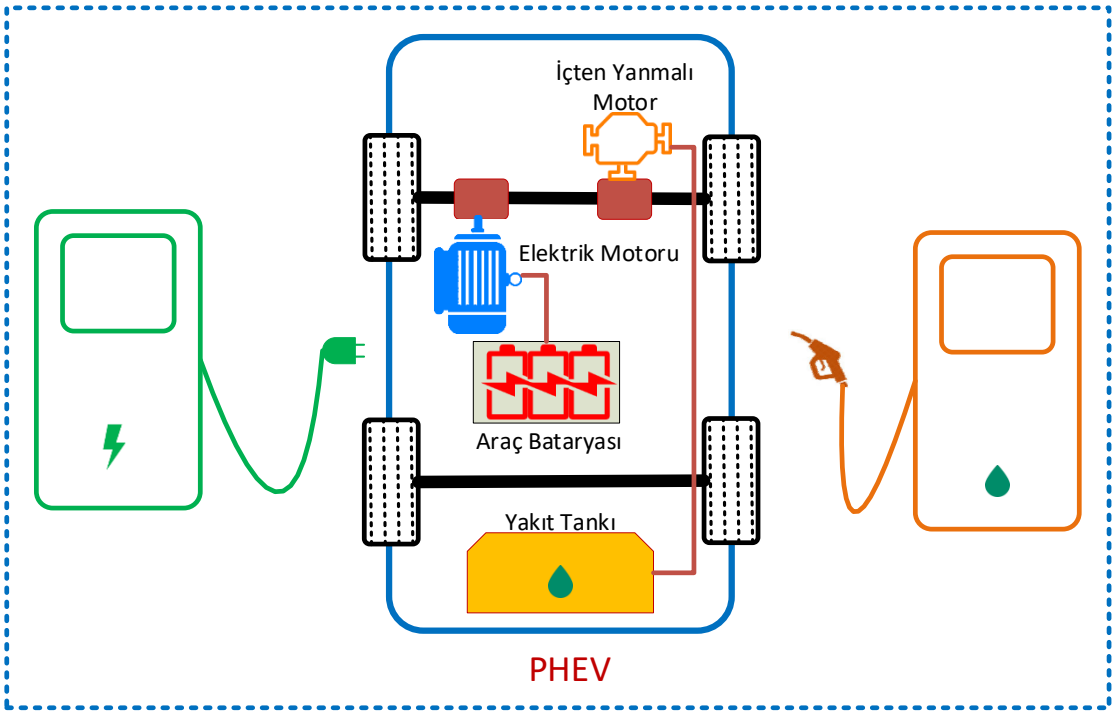


Şekil 2.2. İçten yanmalı motorlu araç (ICEV)



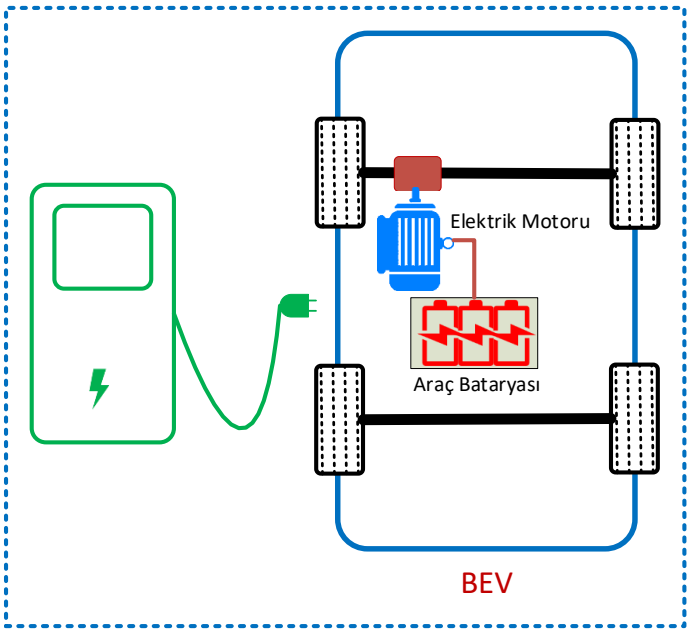
Şekil 2.3. Hibrit elektrikli araç (HEV)

Üçüncü araç ise Şekil 2.4'de gösterilen prize takılabilir hibrit EV'dir (PHEV). Bu araçların HEV'lerden farkı araç bataryası şarj noktasında prize takılarak elektrik şebekesinden de şarj edilebilir olmasıdır. Elektrik şebekesine bağlanmak için yerleşik bir adaptöre sahiptir. Elektrik motoru, ICE motor ağır bir yük altındayken hibrit aracın verimliliğine ve performansına katkıda bulunur. PHEV'in tahrik mekanizması HEV'ye benzerdir fakat ana şebekeden şarj olabilen büyük bir batarya paketine sahip olması nedeniyle HEV'den farklıdır. PHEV, HEV'den daha güçlü bir elektrik motoruna sahiptir ve ICE kapatılarak tamamen elektrik ile çalıştırılabilen EV türüdür. Tamamen elektrikli sürüş mesafesi, modele bağlı olarak PHEV'de yaklaşık 25 km ile 80 km arasındadır. PHEV, araçlarda araç bataryası bittiğinde yedek olarak ICE motor devreye girerek aracın menzil kaygısı sorununu ortadan kaldırır [24,25].



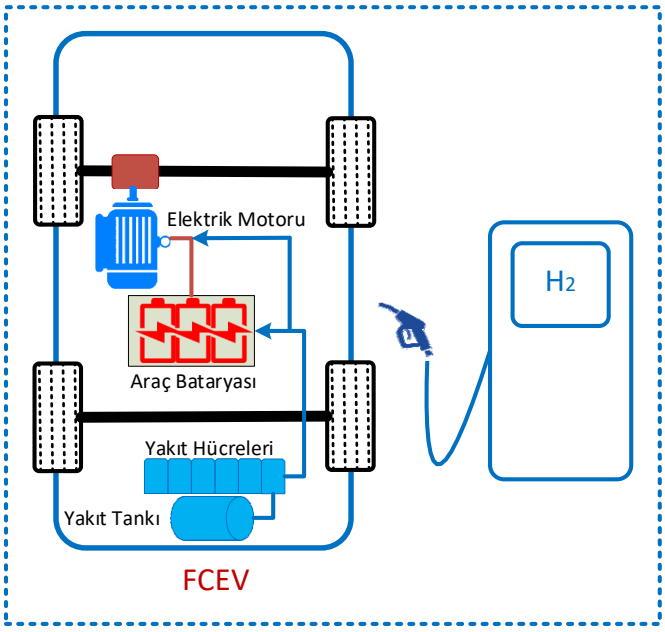
Şekil 2.4. Prize takılabilir hibrit elektrikli araç (PHEV)

Sınıflandırmadaki dördüncü araç türü ise Şekil 2.5'de gösterilen BEV'dir. Bu araçlar prize takılabilir EV (PEV) olarak da isimlendirilir. Bu araçlarda yakıt tankı ve ICE motor bulunmaz. Araçta elektrik motoru bulunur ve tahrik gücünü bu motordan alır. Araç tamamen elektrikli araçtır. Bu nedenle BEV'ler karbon salınımı yapmazlar ve şarj dolum işlemlerinde yenilenebilir enerji kaynakları kullanıldığında karbon ayak izi daha da küçülmektedir [23].



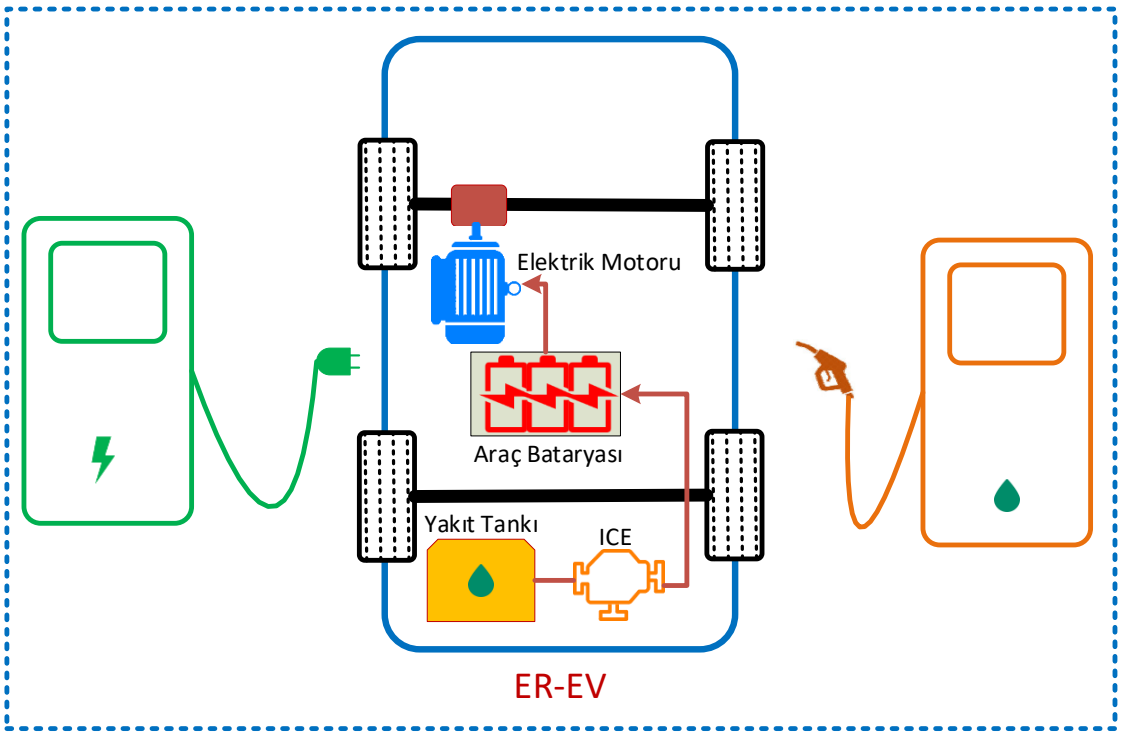
Şekil 2.5. Bataryalı elektrikli araç (BEV)

Beşinci araç türü ise Şekil 2.6'da gösterilen yakıt hücreli EV'dir (FCEV). FCEV'de hidrojen gazının kimyasal enerjisi, yakıt hücresi aracılığıyla elektrik enerjisine dönüştürülür. FCEV'lerde, elektrik motorunun çalışması veya bataryanın şarj edilmesi için gerekli elektrik enerjisi yakıt hücreleri tarafından üretilir. FCEV'lerin tahrik sistemi EV'ler ile aynı prensipte çalışır. FCEV'ler gürültüsüz, enerji açısından oldukça verimli ve atık olarak saf su üreten sıfır egzoz emisyonlu araçlardır [19, 23, 25].



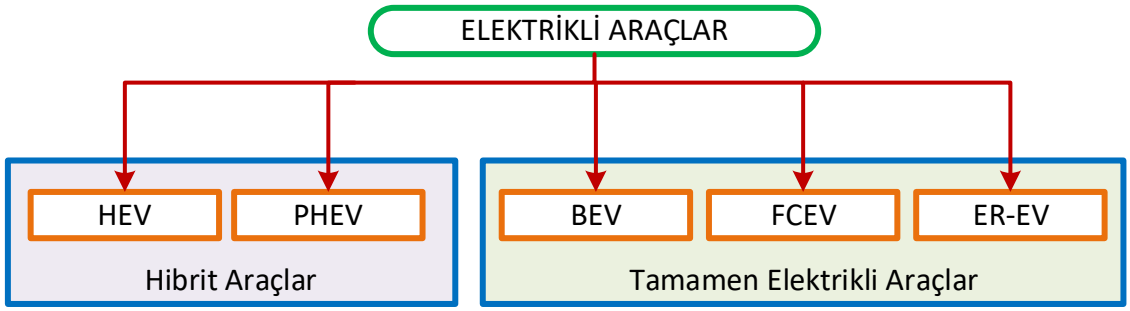
Şekil 2.6. Yakıt hücreli elektrikli araç (FCEV)

Altıncı ve son araç türü artırılmış mesafeli EV (ER-EV) Şekil 2.7'da gösterilmiştir. ER-EV'de araç sadece elektrik motoru ile hareket eder. Seyahat esnasında bataryanın SOC değeri azaldığında ER-EV hem elektrik şebekesinden şarj edilebilir hem de bir akaryakıt istasyonunda yakıt ikmali yaparak ICE tarafından şarj edilebilir. ICE motorun görevi sadece devreye girerek ER-EV'nin bataryasını şarj etmektir. Böylece ICE motor seyahat mesafesinin artırılmasına yardımcı olur.



Şekil 2.7. Artırılmış mesafeli EV (ER-EV)

Bu altı farklı teknolojideki araçların 5 tanesi elektrikli araç grubuna dahil edilmektedir. Elektrikli araçlar hibrit araç ve tamamen elektrikli araç kategorileri altında beş farlı kategoriye ayrılmaktadır (Şekil 2.8). Bu araçlardan PHEV, BEV, FCEV, ER_EV tamamen elektrik motoru ile hareket edebilmektedir. Çizelge 2.1'de şebekeden şarj olabilen, tamamen elektrik motoru ile hareket edebilen bu dört farklı teknolojiye sahip, farklı marka ve modeldeki araçlar ile bu araçların batarya güç kapasiteleri ve sürüş mesafeleri verilmiştir [25]. Bu altı farklı araçta enerji kaynağı olarak fosil yakıtlar (benzin, dizel, LPG), elektrik ve hidrojen kullanılmıştır. Çizelge 2.1'de EV'lerin sürüş mesafeleri WLTP (Worldwide Harmonized Light Vehicles Test Procedure) standartına göre belirlenmiştir. Çizelge 2.2'de ise EV'lerin hareketlerini sağlayan birincil ve ikincil enerji kaynaklarına göre sınıflandırma yapılmıştır.



Şekil 2.8. Elektrikli araç türleri

Çizelge 2.1. Farklı marka, model EV'ler ve özellikleri

Araç Marka Ve Model	Araç Türü	Batarya Kapasitesi (kWh)	Sürüş Mesafesi (km)
Chevrolet Volt	PHEV	18.4	85-Batarya
Mitsubishi Outlander	PHEV	20	84-Batarya
Volvo 40 series	PHEV	78	410
Nissan Leaf Plus	BEV	64	480
Tesla Model S	BEV	100	620
Tesla Model X	BEV	100	500
Tesla Model 3	BEV	82	580
Kia Niro- SUV	BEV	64	460
Lexus UX 300e	BEV	54.3	320
Ford Mustang	BEV	70	400
Jaguar ev400	BEV	90	450
Renault Zoe	BEV	52	390
BMW i3	BEV	37.9	310
Toyota Prius Prime	PHEV	8.8	40-Batarya
Honda e	BEV	28.5	220
Porsche Taycan	BEV	93	410
Volkswagen eGolf	BEV	35.8	230
Mercedes-EQA	BEV	66.5	420
Audi e-tron	BEV	95	400
BMW iX3	BEV	80	460
Toyota Mirai	FCEV	1.6	502
Hyundai Nexo	FCEV	40	570
Honda Clarity	FCEV	25.5	550
BYD Atto 3	ER-EV	60.4	420-Batarya
Hyundai Kona	ER-EV	64	577-Batarya

Çizelge 2.2. Yakıt türüne göre araçların sınıflandırılması

Araç Türü	Birincil Enerji Kaynağı	İkincil Enerji Kaynağı	Enerji Kaynağı
ICEV	Fosil Yakıt	-	Yakıt İkmali
HEV	Fosil Yakıt	Batarya	Yakıt İkmali
PHEV	Fosil Yakıt	Batarya	Yakıt İkmali/Şebeke Bağlantısı
BEV	Batarya	-	Şebeke Bağlantısı
FCEV	Hidrojen	Batarya	Hidrojen Dolumu
RE-EV	Batarya	Fosil Yakıt	Şebeke Bağlantısı/ Yakıt İkmali

2.3. EV'lerin Temel Bileşenleri

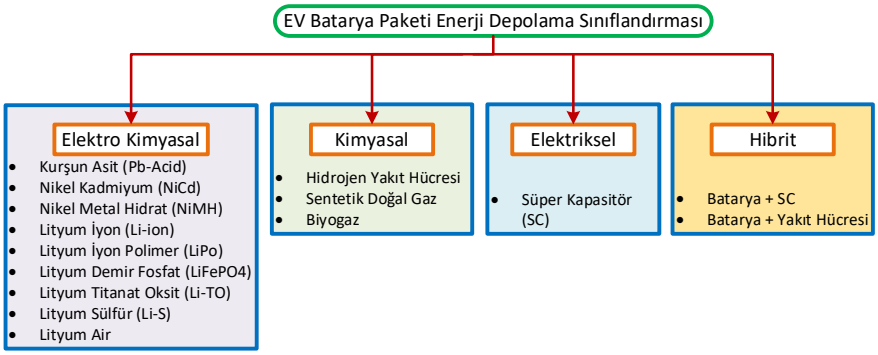
EV teknolojisi geliştikçe hedeflenen öncelik daha yüksek ulaşım mesafelerine seyahat etmektir. Bu hedef iki temel bileşen olan EV bataryası ve EV motorunun geliştirilmesi ile gerçekleştirilir. Bu kapsamda yapılan çalışmalarda daha büyük kapasitelere sahip bataryalar ve yüksek güce sahip motorlar geliştirilmeye çalışılmaktadır.

2.3.1. EV bataryaları

Batarya teknolojilerindeki ilerlemeler EV teknolojisinin çok hızlı ilerleyerek bir sonraki seviyeye ulaşmasını sağlamıştır. EV seçiminde en önemli unsur seyahat mesafesidir. Seyahat mesafesi büyük ölçüde batarya teknolojisine ve EV' nin batarya kapasitesine bağlıdır. EV seçiminde önemli diğer bir unsur da şarj süresidir. Hızlı şarj çözümlerinin geliştirilmesinde en önemli unsur da EV bataryasıdır. Günümüzde EV bataryalarının en büyük sorunu batarya ömrü ve maliyetidir. Üretici firmalar EV bataryalarının ömrünü uzatmak, maliyetlerini ise düşürmek için çalışmalar yapmaktadır. Günümüzdeki EV bataryalarının 8 ile 10 yıl içinde değiştirilmeleri gerektiği öngörülmektedir. Batarya değişim işleminin ise araç maliyetinin %75'ine denk gelecek fiyatlara ulaşması öngörülmektedir [4, 26, 27]. Bu nedenlerden dolayı EV teknolojisi ve EV pazarının gelişmesi batarya teknolojisine bağlıdır. EV'ler için farklı anma gerilimi ve enerji kapasitesine sahip farklı batarya teknolojileri vardır ve teknolojiler üzerinde geliştirme çalışmaları yapılmaktadır [28]. EV Batarya paketleri pillerden veya süper kapasitörlerden (SC) oluşmaktadır [29]. SC'ler aynı zamanda ultra kapasitör olarak da adlandırılmaktadır. SC'ler hacimsel ve kütlesel enerji yoğunluklarından dolayı daha fazla enerji depolayabilmektedirler. SC'ler, yüksek özgül kapasitans, uzun yaşam döngüsü, yüksek güç yoğunluğu, az bakım gerektirmesi, hafıza etkisinin olmaması, güvenli olması gibi nedenlerden dolayı büyük ilgi görmektedir. Fakat SC'ler bataryalara göre birim enerji başına maliyetinin çok yüksek olması, kontrolünün zor olması ve enerji yoğunluğunun bataryalara göre az olmasından dolayı daha az tercih edilmektedir. SC'ler PHEV'ler, BEV'ler ve FCEV'lerde ikincil enerji kaynağı olarak kullanılır. Özellikle, hızlı şarj ve deşarj özellikleri sayesinde, SC, rejeneratif frenleme teknolojisi ile üretilen enerjinin depolanmasını sağlar. Araçların ilk kalkış anında yüksek güç gerektiren kalkış hareketi SC ile gerçekleştirilir. Birincil enerji kaynağını desteklemek için yüksek güç potansiyeli SC aracılığı ile sağlanır. SC ile yakıt tasarrufu sağlanır ve SC birincil kaynakların ömrünü

uzatan olumlu etkiye sahiptir [30].

EV bataryası için farklı kimyasal yapı ve teknolojilere sahip farklı tipte şarj edilebilir bataryalar bulunmaktadır. Bu bataryalar kimyasal yapılarına göre kurşun-asit (Pb-acid), nikel kadmiyum (NiCd), nikel metal hidrit (NiMH) ve lityum-iyon (Li-ion), olmak üzere dört temel gruba ayrılır. EV batarya paketlerinin enerji depolama sınıflandırması Şekil 2.9'de verilmiştir [26-32].



Şekil 2.9. EV batarya paketi enerji depolama sınıflandırması

Li-ion pil türlerinden farklı olarak Pb-acid, NiCd ve NiMH piller kimyasal yapılarından dolayı zamanla toksik ağır metaller üretirler. NiMH pil, Li-ion pile göre daha ucuzdur, ısıya daha dayanıklıdır ve enerji depolamada Li-ion pil ile aynı performansı gösterir. Ancak NiMH pil, Li-ion pilden neredeyse iki kat daha büyük ve daha ağırdır. Li-ion batarya türleri yaşam döngüsü en uzun olan bataryalardır. Li-ion bataryaların enerji, güç yoğunluğu diğer bataryalara kıyasla oldukça yüksektir. Ayrıca Li-ion bataryaların şarj verimlilikleri de diğer bataryalara kıyasla çok yüksektir. Bu nedenlerden dolayı Li-ion bataryalar uygulamalarda en çok tercih edilen batarya türleridir [26-28].

2.3.2. Batarya parametreleri

Geçmişten günümüze EV'lerde kullanılan bataryalar ile günümüzde geliştirme aşamasında olan batarya türlerine ait nomal gerilim, enerji ile güç yoğunluğu, çevrim ömrü, kendi kendine deşarj oranı, hafıza etkisi ve çalışma sıcaklığı aralığı parametrelerine ait bilgiler Çizelge 2.3'de verilmiştir [31,33,34]. Bataryaların performansını ve kulanım kapasiteleri yani çevirim döngüsünü korumak için bazı değerlerin izlenerek batarya bakımlarının yapılması gereklidir.

Çizelge 2.3. EV Batarya türlerine ait parametre değerleri

Batarya Türü	Nominal Gerilim (V)	Enerji Yoğunluğu (Wh/kg)	Güç Yoğunluğu (W/kg)	Çevrim Ömrü	Kendi Kendine Deşarj Oranı Aylık (%)	Hafıza Etkisi	Çalışma Sıcaklık Aralığı (°C)
Pb-acid	2	35-50	180	1000	<5	Yok	-15 ~ +50
NiCd	1,2	50-80	200	2000	10	Var	(-20) ~ (+50)
NiMH	1,2	70-95	200-300	<3000	20	Kısmen	(-20) ~ (+60)
Li-ion	3,6	118-250	200-430	2000	5	Yok	(-20) ~ (+60)
LiPo	3,7	130-225	260-450	>1000	5	Yok	(-20) ~ (+60)
LFP	3,2	120	2000-4500	>2000	5	Yok	(-45) ~ (+70)
LTO	2,4	50-80	4000	3000-7000	<5	Yok	(-25) ~ (+60)
Li-S	2,5	350-650	7800	300	8-15	Yok	(-60) ~ (+60)
Li-Air	2,9	1300-2000	70-100	100	<5	Yok	(+25) ~ (+140)

Batarya kapasitesi

Bataryanın tam şarj edildiğinde oda sıcaklığında 1 saat boyunca verebileceği akım değeridir Birimi amper-saattir (Ah).

Nominal gerilim

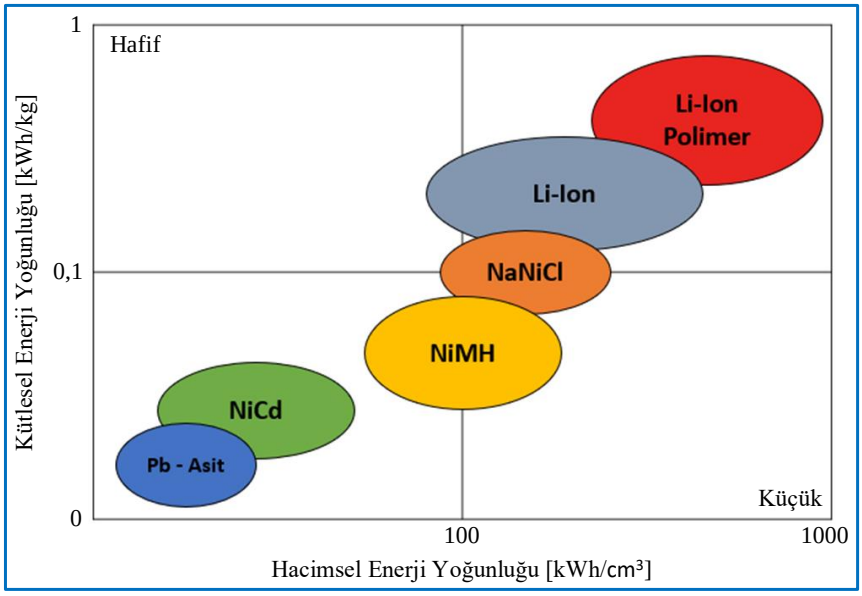
Batarya tam şarj edildikten sonra deşarj olana kadar sağladığı ortalama gerilim değeridir. Birimi volttur (V).

Enerji yoğunluğu

Birim kütle başına bataryanın sahip olduğu maksimum enerjiyi ifade eder. Birimi watt-saat/kg'dır (Wh/kg).

Güç yoğunluğu

Birim kütle başına bataryanın sahip olduğu maksimum gücü ifade eder. Birimi watt/kg'dır (W/kg). Bataryaların geçmişten günümüze farklı batarya kimyasallarına göre hacimsel ve kütlesel güç yoğunluklarının dağılımı Şekil 2.10' da gösterilmiştir [35].



Şekil 2.10. Bataryaların hacimsel ve kütlesel güç yoğunluklarının dağılımı

Şarj durumu (SOC)

Bataryanın deşarjı esnasında bataryadaki kalan enerji miktarını gösteren değerdir. Bu değer yorumlanarak bataryanın enerji yoğunluğu belirlenir ve EV'nin kalan ulaşım mesafesinin kestirimi yapılır. Bu işlem için bataryanın şarjı ve deşarjı esnasında batarya akımındaki elektrik yükü miktarı ölçülerek yapılır (Eş. 2.1) [27,30,36].

$$SOC(\%) = \frac{Q_0 \pm \int i_{bat} dt}{Q_n} \times 100 \qquad (2.1)$$

Bu eşitlikte Q_0, şarj /deşarj işleminden önceki mevcut olan ilk elektrik yüküdür birimi Coulomb'dur (C), Q_n, bataryanın nominal elektrik şarj kapasitesidir birimi Coulomb'dur (C) ve i_{bat}, batarya akımıdır birimi amperdir (A). i_{bat}, akımın mevcut yönüne bağlı olarak pozitif veya negatif olabilir. Akım bataryaya giriyorsa SOC değeri artacaktır ve akım bataryadan çıkıyorsa SOC değeri azalacaktır. Eşitlik 2.1'de gösterildiği gibi SOC değeri bataryanın enerji seviyesini yüzde olarak gösteren normalleştirilmiş bir değerdir [30, 36].

Batarya sağlığı (SOH)

Bataryanın mevcut depolama kapasitesinin, nominal depolama kapasitesine oranıdır (Eş. 2.2). Yüzde olarak ifade edilen bir değerdir. Batarya hücresinin durumunu belirlemeye

yönelik yapılan bu değerlendirme yöntemine SOH adı verilir. Pilin fabrikada garanti edilen çalışma koşullarının üzerinde çalışıp çalışmadığını belirlemek için pilin durumunu ölçer.

$$SOH(\%) = \frac{Q_f}{Q_m} \times 100 \quad (2.2)$$

Bu eşitlikte Q_f bataryanın tam şarj olma kapasitesidir birimi Coulomb'dur (C). Q_m bataryanın tasarlanan maksimum şarj olma kapasitesini ifade eder birimi Coulomb'dur (C) [27, 30].

Deşarj durumu (SOD)

Bataryanın deşarj durumunu ölçmek için kullanılır (Eş. 2.3). SOC'nin tamamlayıcısı anlamına gelir, yani bataryadan ne kadar enerji alındığını gösterir [30].

$$SOD(\%) = (1 - SOC) \times 100 \quad (2.3)$$

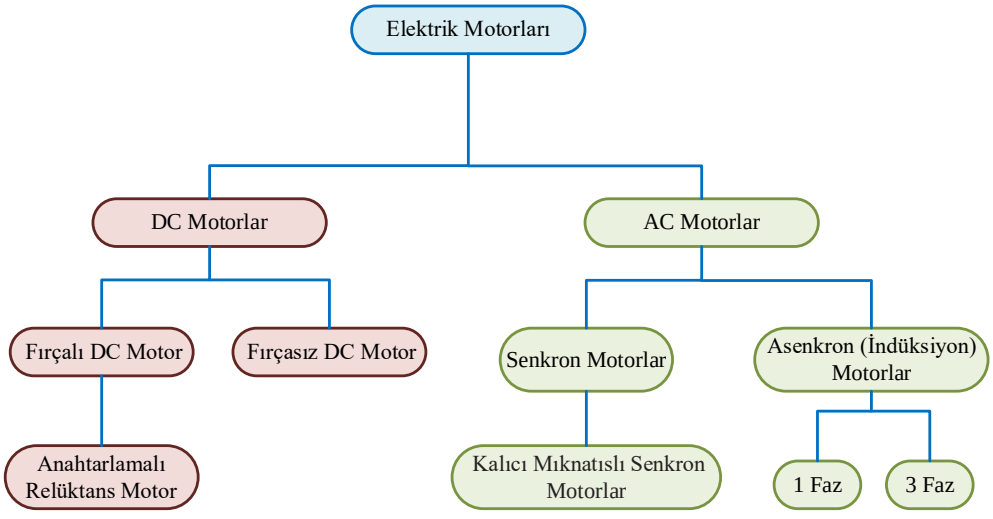
Bataryanın SOC, SOH ve SOD değerleri bataryanın çevrim döngüsünü etkiler. Çevrim döngüsü bataryaların performansını ve ömrünü belirleyen bir parametredir. Bataryaların güvenilir ve etkili bir şekilde kullanılması için bu parametreler doğru olarak belirlenip izlenmelidir. Bu parametrelerden SOH değeri, bataryanın çevrim döngüsünü belirleyen dolayısıyla batarya ömrünü belirleyen parametredir. SOH değeri düşük olan bir batarya, daha az enerji depolar ve daha hızlı boşalır. Bu durum, bataryanın performansının azalmasına ve kullanım ömrünün kısalmasına yol açabilir. Bu nedenle, bu parametreler düzenli olarak izlenmeli ve bataryaların periyodik bakımları yapılmalıdır [27, 30, 36].

2.3.3. EV motorları

EV'lerin çalışma prensibini daha iyi kavrayabilmek için elektrik motorunun bileşenlerini incelemek gereklidir. Elektrik motorlarında mekanik hareketli parçalar yer almaz. Bu tür motorlar, elektromanyetik alan kullanarak hareket enerjisi elde ederler ve stator ile rotor olmak üzere iki ana bileşenden oluşurlar. Statik bir parça olan stator, stator çekirdeği, stator çerçevesi ve bobin gibi bileşenleri içerir. Rotor ise, statorun içine yerleştirilen iletken çubuklardan oluşur. Bobin tarafından üretilen elektromanyetik alan, statorda iletken

tellerden geçerek rotorun dönmesini sağlar. Elektrik motorları, ICE'ler ile kıyaslandığında daha az bileşene sahip oldukları için daha basit bir çalışma prensibine sahiptir. Bataryadaki enerji önce doğru akım kontrol ünitesine gönderilir. Bu ünitede bataryadan gelen doğru akım, alternatif akıma dönüştürülür. Alternatif akım, statorda yerleştirilmiş bobin çiftlerinden geçerken bir elektromanyetik alan oluşturur. Sabit stator içinde üretilen bu elektromanyetik alan, rotor üzerindeki iletken çubuklar üzerinden geçerek rotorun dönmesini sağlar [26, 37-39].

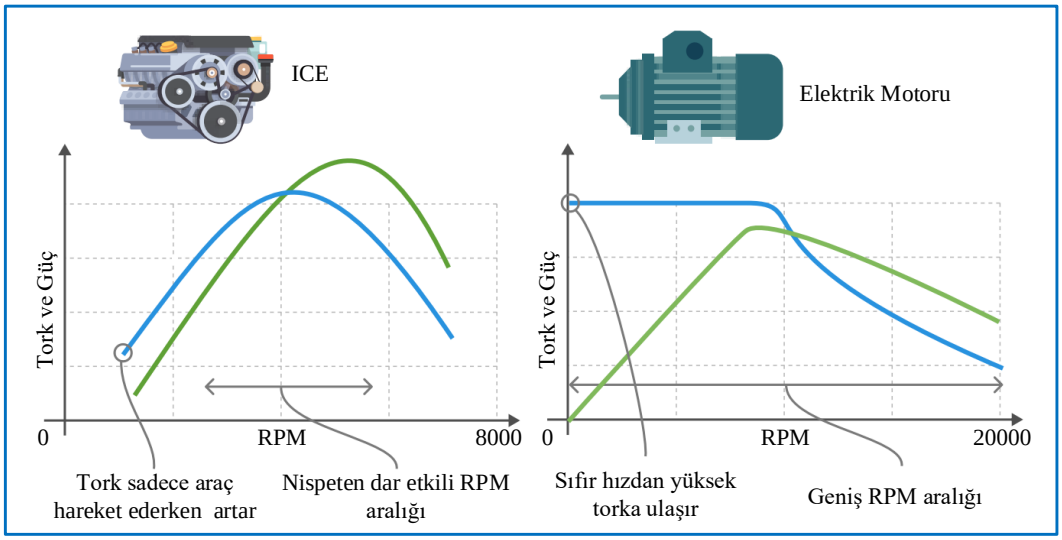
Elektrik motoru, elektrik enerjisini mekanik enerjiye dönüştüren elektrikli bir cihazdır. Bir EV'deki elektrik motoru, bataryadan gelen gücü kullanan ve bu gücü, kontrol cihazı ve sürücü tarafından verilen komutlara göre aracın tekerleklerinin dönme hareketine dönüştüren ana parçadır. EV'ler, araç konfigürasyonuna, maksimum hız ile torka, maksimum güce, akü kapasitesine, voltaja ve maliyete bağlı olarak farklı türde tahrik elektrik motorları kullanır. EV'lerde kullanılan beş temel tahrik elektrik motoru fırçalı DC motor (DCM), Fırçasız DC Motor (BLDC), anahtarlamalı relüktans motor (SRM), asenkron (indüksiyon) motor (ACIM) ve kalıcı mıknatıslı senkron motor (PMSM) dur [37,39]. Bu motorların sınıflandırılması Şekil 2.11 de gösterilmiştir.



Şekil 2.11. EV'lerde kullanılan temel elektrik motorlarının sınıflandırılması

EV için kullanılan elektrik motoru seçimi, yüksek verimlilik, hızlı tork tepkisi, düşük maliyet, yüksek güç yoğunluğu, yüksek ivme, yüksek anlık güç gibi özelliklere bakılarak değerlendirilir [39]. Elektrik motorları ICE motorlar ile kıyaslandığında yüksek tork ve yüksek hızlanma aralığına sahiptir (Şekil 2.12) [39]. Ayrıca EV'lerde motorlar mükemmel

kontrol, düşük bakım maliyeti, yüksek canlılık, kolay planlanma gibi önemli özellikleri kullanıcılara sunmaktadır [38]. Çizelge 2.4'de yıllar içerisinde üretilen farklı marka ve modeldeki EV'lerde kullanılan motor türleri verilmektedir [27,38].



Şekil 2.12. ICE motor ile elektrik motoru tork ve güç karşılaştırma grafiği

Çizelge 2.4. Farklı marka ve model EV'lerde kullanılan motor türleri

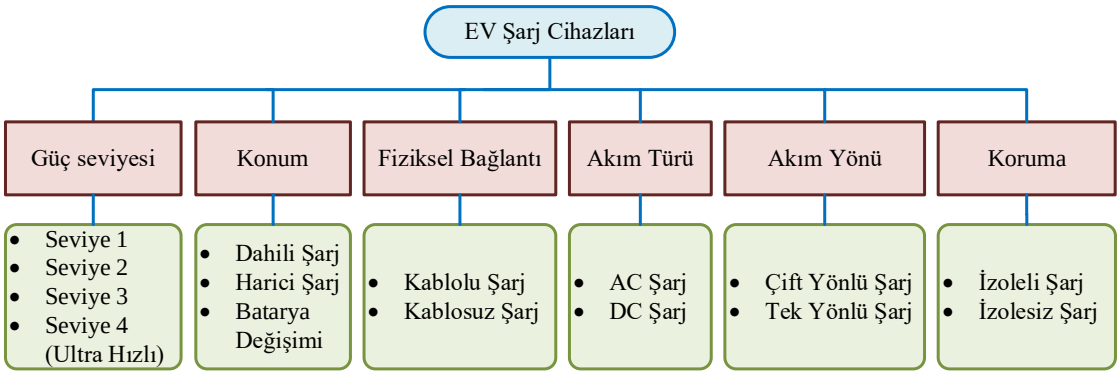
EV	Yıl	Motor Türü
GM Prototip	1990	SRM
Toyota Prius	1997	PMSM
Smart FortoWo ED	2009	PM-BLDC
Tesla Model S	2012	ACIM
Volswagen e Golf 7	2014	PMSM
Nissan Leaf	2017	PMSM
Ford Focus Electric	2018	PMSM
Tesla Model S70D	2018	SM(IM)
Audi E-Tron	2019	PMSM
Kia Niro	2020	PMSM
Honda e	2021	PMSM
Renault Megan e-Tech	2022	Akım-Uyarımlı Senkron Motor
TOGG T10X	2023	PMSM
Mercedes Benz X294 EQE	2024	PMSM

3. ELEKTRİKLİ ARAÇ ŞARJ CİHAZLARI VE STANDARTLARI

Dünya genelinde EV sayısı arttıkça, EV'leri her zamankinden daha hızlı şarj edebilen, enerji verimliliği yüksek şarj altyapılarının oluşturulmasına duyulan ihtiyaç da artmaktadır. Yeni elektrikli araçların öncekilere göre daha yüksek sürüş mesafelerine ve daha büyük batarya kapasitelerine sahip olması, hızlı şarj çözümlerinin geliştirilmesini gerektirmektedir. EV sektörünün gelişimi, şarj altyapısı ile şebeke etkileşimi için dünya çapında EV'lere yönelik şarj standartlarının uygulanması zorunluluğunu da beraberinde getiriyor [23, 40, 41]. Bu bölümde EV şarj cihazının sınıflandırılması, şarj standartları ve EV batarya şarj teknikleri hakkında genel bir bakış sunulmuştur. Şarj standartları ile birlikte şarj arayüzü ve teknik özellikleri hakkında da bilgilendirme de yapılmıştır.

3.1. Elektrikli Araç Şarj Cihazının Sınıflandırılması

EV şarj cihazlarının sınıflandırmasında farklı yöntemler kullanılmaktadır. Şekil 3.1'de batarya şarj cihazlarının sınıflandırılması yapılmıştır [2, 25, 42-45]. Bu sınıflandırmada şarj cihazının konumu, şarj işleminin güç seviyesi, şarj işleminde kullanılan fiziksel bağlantı, şarjı için kullanılan akım türü, şarj işlemi sırasında akımın yönü ve şarj işleminde kullanılan koruma yöntemi olmak üzere altı farklı yöntem kullanılmaktadır.



Şekil 3.1. EV şarj cihazının sınıflandırılması

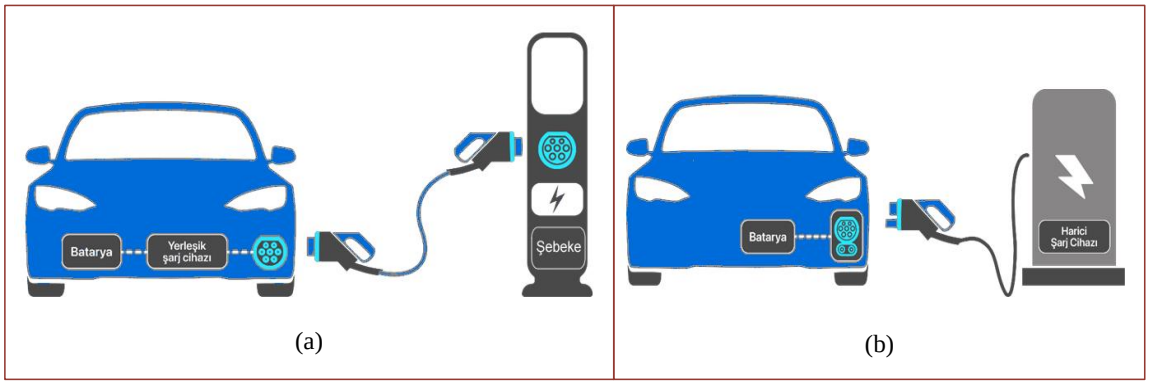
3.1.1. Güç seviyesine göre şarj işlemi

EV şarj istasyonu şebekenin bir parçası olarak, konutlarda, ticari binalarda veya halka açık alanlarda kurulabilir. Şarj işlemi Seviye 1, Seviye 2, Seviye 3 ve ultra hızlı seviye olmak

üzere dört farklı seviyede hem AC (Alternatif akım) hem de DC (Doğru akım) olarak gerçekleştirilebilir. AC şarj işlemi genellikle dahili şarj cihazlarıyla birlikte Seviye 1 ve Seviye 2'de gerçekleştirilir. DC şarj işlemi harici şarj cihazlarıyla birlikte Seviye 3'de gerçekleştirilir. Diğer DC şarj işlemi dördüncü seviye yani yeni nesil ultra hızlı şarj işlemi ile birlikte gerçekleştirilir [4, 23, 25, 26, 42- 45].

3.1.2 Konumuna göre şarj işlemi

Konumuna göre şarj işlemi dahili şarj cihazları, harici şarj cihazları veya batarya değiştirme yöntemi ile üç farklı şekilde yapılmaktadır. Dahili şarj cihazında Seviye 1'de tek fazda AC şarj işlemi gerçekleştirilir. Konutlarda veya iş yeri gibi yerlerde EV uzun süreli park halindeyken yavaş ve düşük güçlü şarj işlemi gerçekleştirilir. Dahili şarj cihazı bir alt yapı gerektirmez mevcut şebekeyi kullanır. Seviye 2'de de dahili şarj işlemi gerçekleştirilir [27]. Harici şarj cihazları Seviye 3 DC hızlı şarj ve Seviye 4 DC ultra hızlı şarj işlemi çin kullanılır [46]. Harici şarj cihazı genellikle park süresinin yarım saatten az olduğu, enerji ihtiyacının acil gerektiği durumlarda hızlı şarj istasyonlarında kullanılır. Harici şarj cihazı için bir alt yapı oluşturulmalıdır [47]. Şekil 3.2'de dahili ve harici şarj işleminin modeli verilmiştir [27]. Diğer bir yöntem ise batarya değiştirme yöntemidir. Dahili ve harici şarj imkanın olmadığı durumlarda deşarj olmuş batarya ile şarj olmuş batarya değiştirilir. EV batarya değiştirme istasyonları, özellikle kişi başına düşen gelirin düşük olduğu ve pahalı batarya fiyatlarının EV penetrasyonunu engellediği gelişmekte olan ülkelerde, hızlı ulaşımın elektrifikasyonunda önemli bir yardımcıdır [48].



Şekil 3.2. (a) Dahili şarj cihazı ile şarj işlemi (b) Harici şarj cihazı ile şarj işlemi

3.1.3. Fiziksel bağlantıya göre şarj işlemi

Bağlantı türüne göre şarj işlemi kablolu ve kablosuz şarj olmak üzere iki guruba ayrılır. Kablolu şarj işlemi genel olarak iletken şarj olarak da adlandırılır. Şebeke ile EV arasındaki bağlantı için belirli bir standartta bir güç kablosu gerektirir. Kablolu şarj işlemi pilin daha iyi bir verimlilikle şarj edilmesini sağlar. Son yıllarda, geliştirilen dönüştürücüler, sürekli yük akımı sağlamak, dönüştürücü anahtarlar üzerindeki anahtarlama stresini azaltmak, çift yönlü kapasite, artırılmış akım kapasitesi, birleşik yavaş ve hızlı şarj, geliştirilmiş güç kalitesi sağlamak gibi kablolu şarj için çeşitli avantajlar sunmaktadır. Dönüştürücülerin güç kaybı en aza indirilerek daha yüksek çıkış voltajları sağlanmaktadır. Kablolu şarj sahip olduğu kontrol metodolojisi ile kontrol edilebilirliğin artırılması, hızlı çalışma ve çok işlevli olma gibi yeteneklere de sahiptir. Kablolu şarj verimi çok yüksek olduğundan en yaygın ve tercih edilen şarj yöntemidir [23].

Kablosuz şarj günümüzde araştırma ve geliştirme aşamasındadır. Mobil şarj, robotik, tıbbi implantlar, dronlar, EV şarjı gibi çeşitli uygulamalarda denenmektedir. Büyük ölçekli uygulamalar için hala erken aşamadadır [23, 40, 42]. Kablosuz şarj EV şarjına yönelik bir uygulama olarak galvanik izolasyon, hareket halindeyken şarj etme ve pil kapasitesinin azaltılması gibi çok yönlü özellikler sunar. Yüksek elektriksel izolasyon, artırılmış güvenlik, kullanışlı ve kolay şarj yöntemi gibi avantajlarının yanında yavaş şarj işlemi, şarj pedinin yanlış hizalanması sorunu, karmaşık kontrol ve elektromanyetik parazit sorunu gibi nedenlerden dolayı verimi düşüktür [23,49].

3.1.4. Akım türüne göre şarj işlemi

EV bataryalarının şarjı için AC ve DC akım kullanılmaktadır. AC şarj sistemi, tek veya üç fazlı AC bağlantısıyla EV'nin dahili AC/DC güç dönüştürücüsü ile AC'yi DC'ye dönüştürerek EV bataryasının şarj edilmesini sağlar. AC akım, dahili şarj cihazlarında Seviye 1 ve Seviye 2 güç seviyelerinde yavaş şarj işlemi için kullanılmaktadır. DC şarj sistemleri, harici şarj cihazı ile dış istasyonlarda kullanılacak şekilde modellenip üretilmektedir. DC akım ise harici şarj cihazlarında Seviye 3 ve Seviye 4 hızlı şarj için kullanılmaktadır. DC şarj sistemleri daha karmaşık kablolama gerektirse de daha verimli ve daha hızlı şarj işlemi gerçekleştirirler. Harici şarj cihazlarının boyut ve ağırlık açısından herhangi bir sınırlaması olmadığından, yüksek güçte şarj oranları elde edilebilmektedir.

Modern şarj istasyonları, DC şarj işlemlerini otomatik olarak elektrikli araçların batarya türüne göre ayarlamaktadır [50].

3.1.5.Akım yönüne göre şarj işlemleri

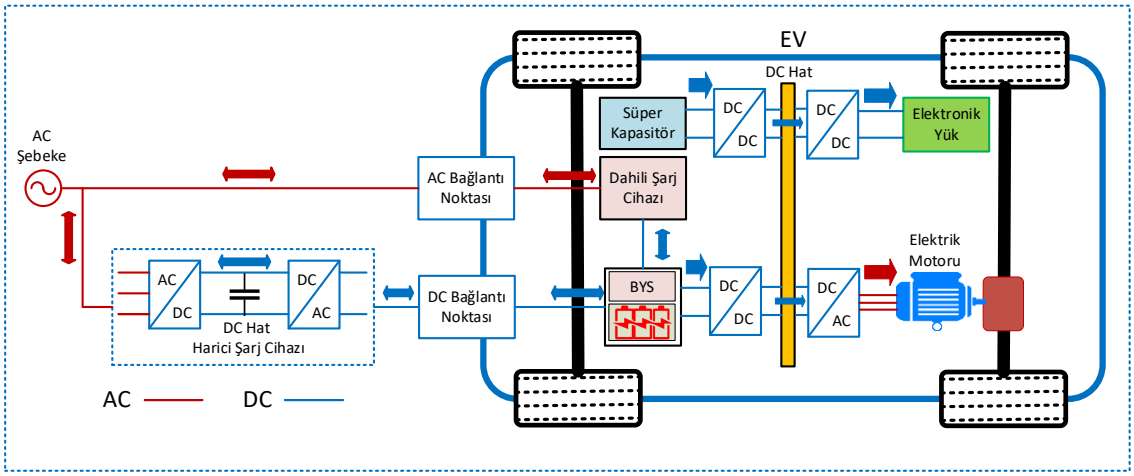
Akım yönüne göre şarj işlemi tek yönlü şarj ve çift yönlü şarj olmak üzere iki guruba ayrılır. EV ve ana şebeke arasındaki güç akışının yönü G2V'e doğru ise tek yönlü şarj olarak adlandırılır. Güç akışının yönü V2G'e ve G2V'e doğru ise çift yönlü şarj olarak adlandırılır. EV bataryalarının şarj işlemi için güç akışının yönü ana şebekeden EV bataryasına doğrudur fakat ana şebekede beklenmedik sistem arızaları durumunda şebekenin güvenirliği için güç akışının yönü tersine EV'den ana şebeke yönünde gerçekleşebilir. Bu durumda güç akışı G2V iken V2G olarak yön değiştirir ve çift yönlü güç akışı olarak isimlendirilir [2,25].

3.1.6. Koruma durumuna göre şarj işlemleri

Şarj cihazları izolasyon sınıfına göre iki temel gruba ayrılır. Şebeke ile araç bataryasının birbirinden galvanik izolasyon ile ayrılması durumunda izoleli, ayrılmaması durumunda ise izolesiz şarj cihazları olarak adlandırılır [51]. İzolesiz devre topolojileri güvenlik kaygılarından dolayı endüstriyel alanlarda kullanılmazlar. Genellikle deneme veya test maksadıyla tasarlanır ve kullanılırlar. AC şarj için tasarlanan izoleli devre topolojisi, izoleli AC/DC ve izoleli DC/DC olmak üzere 2 farklı şekilde tasarlanır. AC/DC dönüştürücü tarafında kullanılan galvanik izolasyon trafosu şebeke frekansında çalışır fakat kullanılan izolasyon trafosu ağırlık ve hacim açısından büyük bir dezavantaj oluşturur. EV şarj işleminde izoleli DC/DC dönüştürücülerde sıklıkla kullanılır. Bu dönüştürücülerde dönüştürme işlemi DC/AC, AC/DC ve DC/DC olmak üzere üç yönde gerçekleşir. Bu aşamalardan DC/AC ve AC/DC giriş ile çıkış arasında elektriksel bağlantıyı keserek izolasyon sağlar. Elektriksel izolasyon için AC/AC için yüksek frekanslı trafo kullanmaktadır. Yüksek frekanslı trafo hem yüksek voltaj kazancı hem de galvanik izolasyon sunar. EV şarjı için en çok kullanılan izoleli DC/DC dönüştürücülerdir. DC/DC dönüştürücü tarafında kullanılan izolasyon trafosu yüksek frekansta çalıştığı için hacim ve ağırlık bakımından daha fazla avantajlıdır. Bu anlamda tasarlanan şarj modüllerinde izolasyon genellikle DC/DC çevirici kısmında kullanılır [27, 51, 52].

3.2. Şarj Seviyeleri ve Standartları

EV'ler, kendilerine has gereksinimlerini karşılamak için farklı kapasitelerde çeşitli şarj ve deşarj stratejileri ile teknolojileriyle tasarlanmıştır. Bu nedenle, sektörde EV kullanımının yaygınlaştırılması ve yapılan araştırma geliştirme çalışmalarını ileriye taşımak için standartlaştırılmış şarj seviyeleri ve modelleri oluşturulmaktadır [25]. EV şarjı için AC veya DC voltaj kullanılmaktadır. EV şarj olduğu AC, DC veya hibrit şebeke ile bir mikro şebeke oluşturur. Bu kapsamda şarj istasyonlarında yüksek voltajlı AC veya DC kaynakları kullanılır. Dahili veya harici şarj cihazı ile AC ve DC elektrik enerjisi EV bataryasını şarj etmek için gerekli seviyeye dönüştürülür. EV şarj cihazları ile bağlandığı şebekedeki gerilim AC'den DC'ye dönüştürülerek veya DC'den farklı bir DC seviyeye dönüştürülerek EV bataryalarının şarjı için uygun seviyelerde gerilim ve akım sağlanır. Bir EV'de bulunan harici ve dahili şarj sistemi Şekil 3.3'de gösterilmektedir [42,50].



Şekil 3.3. Dahili ve harici EV şarj sistemi

EV şarj sisteminde EV bataryasını istenilen DC güçte (P_{ch}) (Eş. 3.1) şarj etmek için EV batarya gerilimi (V_{EV}) ve batarya şarj akımı (I_{ch}) dahili şarj cihazı ve harici şarj cihazı tarafından sağlanır [50].

$$P_{ch} = V_{EV} \times I_{ch} \tag{3.1}$$

Şarj süresince (t_{ch}) EV bataryası tarafından şebekeden çekilen enerji miktarı (E_{ch}) Eş. 3.2'deki gibi ifade edilir.

$$E_{ch} = \int_0^{t_{ch}} P_{ch}\ dt \tag{3.2}$$

Dünya genelinde EV bataryaları kendilerine has farklı güç seviyelerinde şarj edilmektedir. Bu nedenle şarj istasyonları için farklı bölgelerde farklı standartlar kullanılmaktadır. EV batarya şarjı için Kuzey Amerika otomotiv endüstrisinin belirlediği (Society of Automative Engineers- SAE) standart, Avrupa ve Çin'de kullanılan Uluslararası Elektro-Teknik Komisyonu (International Electrotechnical Commission-IEC) tarafından belirlenen standart ve Japonya, Amerika, Avrupa'nın da kullandığı (CHArge de MOve - CHAdeMO) standart tarafından şarj gücü seviyeleri belirlenmiştir. Ayrıca Tesla firması EV batarya şarjı için kendi standartlarını belirlemiştir. Türkiye'de ise IEC 61851 ve IEC 62196 standardı, SAE J1772 standardı ve CHAdeMO'nun hızlı şarj standardı kullanılmaktadır [45, 47,50]. Bu standartlara göre dahili şarj cihazı ile mevcut AC şebekeden yavaş şarj yapılmaktadır. Harici şarj cihazı ile DC mikro şebekeden hızlı ve ultra hızlı şarj işlemi gerçekleştirilmektedir. Çizelge 3.1'de dünya genelindeki farklı kuruluşların belirlediği standartlarda farklı seviyelerde AC ve DC şarj istasyonu özelliklerinin sınıflandırılması yapılarak karşılaştırılması yapılmıştır [19, 25, 42, 46, 50, 53].

Çizelge 3.1. EV şarj seviyeleri ile uluslararası standartlar arasındaki karşılaştırma

	Şarj Seviyesi	Şarj Türü			Şarj Süresi	Güç Seviyesi (kW)	Gerilim (V)	Maksimum Akım Oranı (A)
		Dahili	Harici	Faz				
SAE Standarttı								
AC	Seviye 1	✓	×	1 Φ	17 s	1.4–1.9	120	12–16
	Seviye 2	✓	×	1 Φ	1.2 s	19,2	208–240	80
	Seviye 3	×	✓	3 Φ	30 dk	>48	480	>100
DC	Seviye 1	×	✓	×	1.2 s	36	200–450	80
	Seviye 2	×	✓	×	24 dk	90	200–450	200
	Seviye 3	×	✓	×	12 dk	240	200–600	400
IEC Standarttı								
AC	Seviye 1	✓	×	3 x 1 Φ	> 3 s	4–7	250–450	16
	Seviye 2	✓	×	3 Φ	2 s	22	250–450	63
DC	Seviye 3	×	✓	×	<30 dk	50-350	300-600	400
	Ultra Hızlı	×	✓	×	2 s	>400	> 800	400
CHAdeMO Standarttı								
DC	Hızlı Şarj	×	✓	×	> 30 dk	60	500	125
Tesla süper şarj								
DC	Hızlı Şarj	×	✓	×	Model S 20–80% SOC; 75 dk	>135	> 480	200

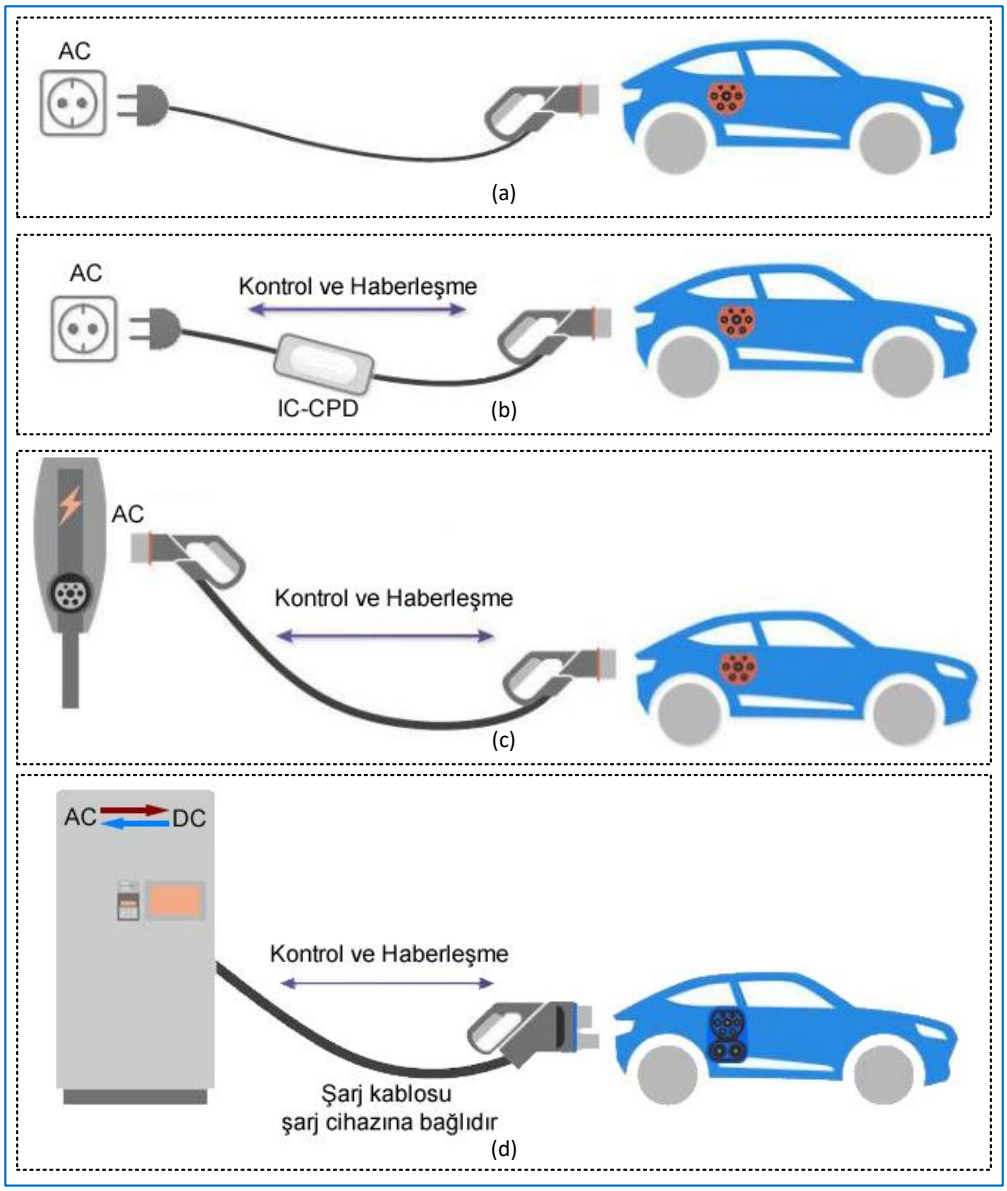
3.3. Şarj Modları ve Özellikleri

IEC-62196 ve 61851 standartları AC ve DC şarj sistemleri için dört şarj modu tanımlar (Şekil 3.4). Bu şarj modları şarj işleminin güvenli enerji gereksinimlerini tanımlar [25, 54]. Mod 1 şarjda, EV doğrudan ana şebekeye bağlanarak EV bataryası şarj edilir. Yavaş şarj işlemlerinde kullanılır. EV, mod 1'de normal bir soket aracılığıyla üç fazda 480 V veya tek fazda 240 V ile doğrudan AC şebekeye bağlanır gerilim ise tek fazda 250 Volt ve üç fazda ise 480 Volt ile sınırlıdır. Mod 1'in akım limiti ülkeye bağlı olarak 8 A ile 16 A arasında değişir. Mod 1 ayrıca topraklama gerektirmektedir. Birçok ülkede prizde topraklama ve koruyucu alt yapı olmadığından kullanılmamaktadır [25, 30, 54].

Mod 2 şarj, mod 1 şarjda bulunan güvenlik sorunlarını azaltmak için geliştirilmiştir. Yavaş şarj uygulamalarında, sızıntı akımlarına karşı, aşırı ısınmaya karşı ve koruyucu topraklama tespitine karşı koruma sağlar. Mod 2 şarjda, şarj kablosu elektrikli araçla birlikte verilir. Bu şarj kablosunda koruma sistemi (IC-CPD) bulunmaktadır [25, 30, 54].

Mod 3 şarjda EV batarya şarjı için özel bir şarj cihazının kullanılmasını içerir. Mod 3'te, bağlantı kablosu, şarj cihazı EV ile birlikte temin edilir. EV ile temin edilen şarj cihazı bu modda koruma ve kontrol standartlarını karşılamak amacıyla özel, evsel veya halka açık şarj istasyonlarında kalıcı olarak kurulur. Bu modda AC veya DC akımlarına karşı şok koruması sağlanır. Şarj cihazları araçlarla iletişim kurar, şarj sürecini takip eder, koruma sistemlerini içerir ve araçla bağlantı algılanmadığında enerji akışını durdurur. Şarj cihazı tarafından uygun şarj akımı belirlenerek EV'ye aktarılır. Şarj cihazı ana şebekedeki bir prize bağlanarak yavaş veya hızlı şarj için kullanılır. Mod 3, tek fazlı veya üç fazlı şebeke entegrasyonu gerçekleştirilebilir. Bu modda 32 A ve 250 A arası akımda şarj işlemi gerçekleştirilir [25, 30, 54].

Mod 4 şarj DC hızlı şarj ve DC ultra hızlı şarjı içerir. Mod 4 DC harici bir şarj cihazını içeren tek şarj moddur. Bu modda DC akım doğrudan bataryaya iletilir ve yerleşik şarj cihazı kullanılmaz. Bu mod, maksimum 400 A akımla 600 V DC sağlayabilir. Bu modda yer alan yüksek güç seviyesi, daha yüksek düzeyde iletişim ve daha sıkı güvenlik özelliklerini zorunlu kılar. Mod 4 şarjda şarj kablosu kalıcı olarak şarj istasyonuna bağlıdır [25, 30, 54]. Çizelge 3.2 de şarj modlarının özeti verilmiştir.



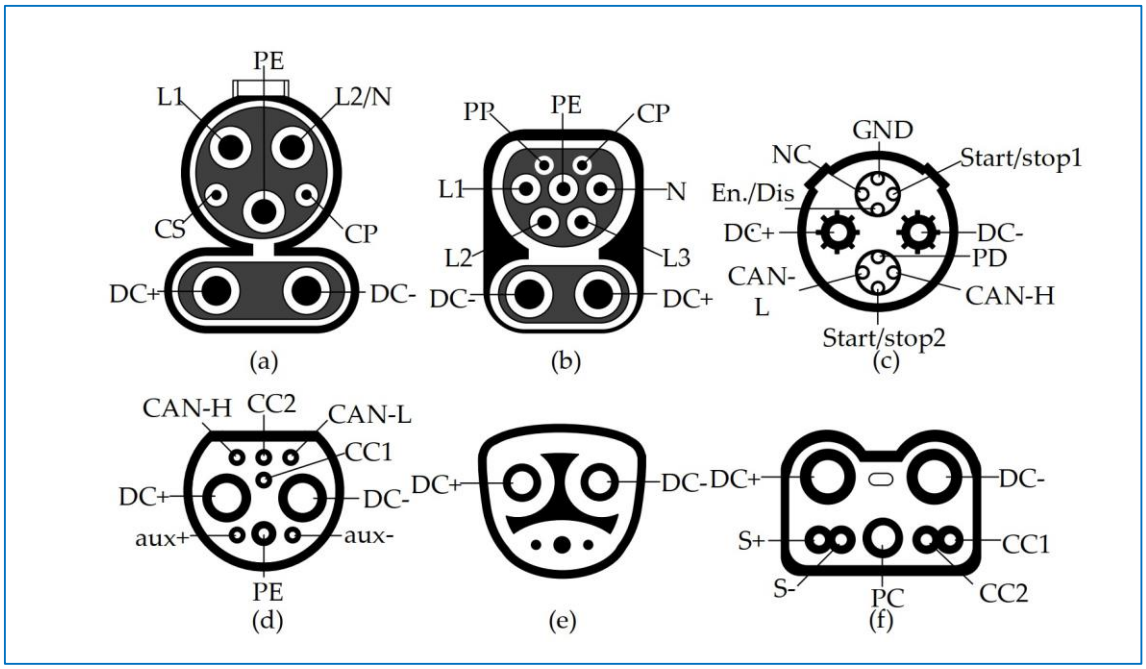
Şekil 3.4. EV şarj modları a) Mod 1 b) Mod 2 c) Mod 3 d) Mod 4

Çizelge 3.2. Farklı şarj modlarının karşılaştırılması

Şarj Modu	Faz	Akım (A)	Voltaj (V)	Güç (Mak.) (kW)	Özel Bağlayıcı	Koruma
Mod 1	AC- 1 Φ AC- 3 Φ	16	230~250 / 480	3.8 ~7.6	×	×
Mod 2	AC- 1 Φ AC- 3 Φ	32	230~250 / 480	7.6 ~15.3	×	✓
Mod 3	AC- 1 Φ AC- 3 Φ	32-250	230~250 / 480	60~120	✓	✓
Mod 4	DC	250-400	600~1000	>150	✓	✓

3.4. Şarj Arayüzü ve Teknik Özellikleri

Şarj arayüzü, şarj işlemi esnasında EV'leri güç kaynağı ekipmanına bağlayan önemli bir bileşendir. EV'lerin sanayileşmesi ve küreselleşmesiyle birlikte, çeşitli ülkelerde şarj arayüzü standartlarını birleştirme konusunda bir zorluk ortaya çıkıyor ve bu da farklı bölgelerdeki çeşitli EV türleri arasında şarj bağlantısı sağlama yeteneğini engelliyor. Bu durumda Çin, Amerika Birleşik Devletleri, Avrupa ve Japonya gibi bölgeler, şarj arayüzü standartlarının birleştirilmesini aktif olarak desteklemektedir. EV şarj arayüzü standartlarının standardizasyonu, EV'lerin yaygın şekilde benimsenmesi, kullanımının teşvik edilmesi ve şarj altyapısının geliştirilmesinin kolaylaştırılması açısından çok önemlidir. EV şarj arayüzleri için IEC standartları, kombine şarj sistemi (CCS) ortak şarj standartları, CHAdeMO standartları, SAE standartları, Çin tarafından geliştirilen GB/T standartları v.b. küresel standartlar geliştirilmiştir [25, 30, 46, 53, 55]. Dünya çapında kullanılan mevcut hızlı şarj arayüzleri Şekil 3.5'te gösterilmektedir [46]. Çizelge 3.3 de ise bu arayüz uçlarının anlamları verilmiştir [46].



Şekil 3.5. EV hızlı şarj arayüzleri (a) CCS Combo 1 (b) CCS Combo 2 (c) CHAdeMO (d) GB/T 20234.3 (e) Tesla Supercharger (f) CHAdeMO 3.0/Chaoji

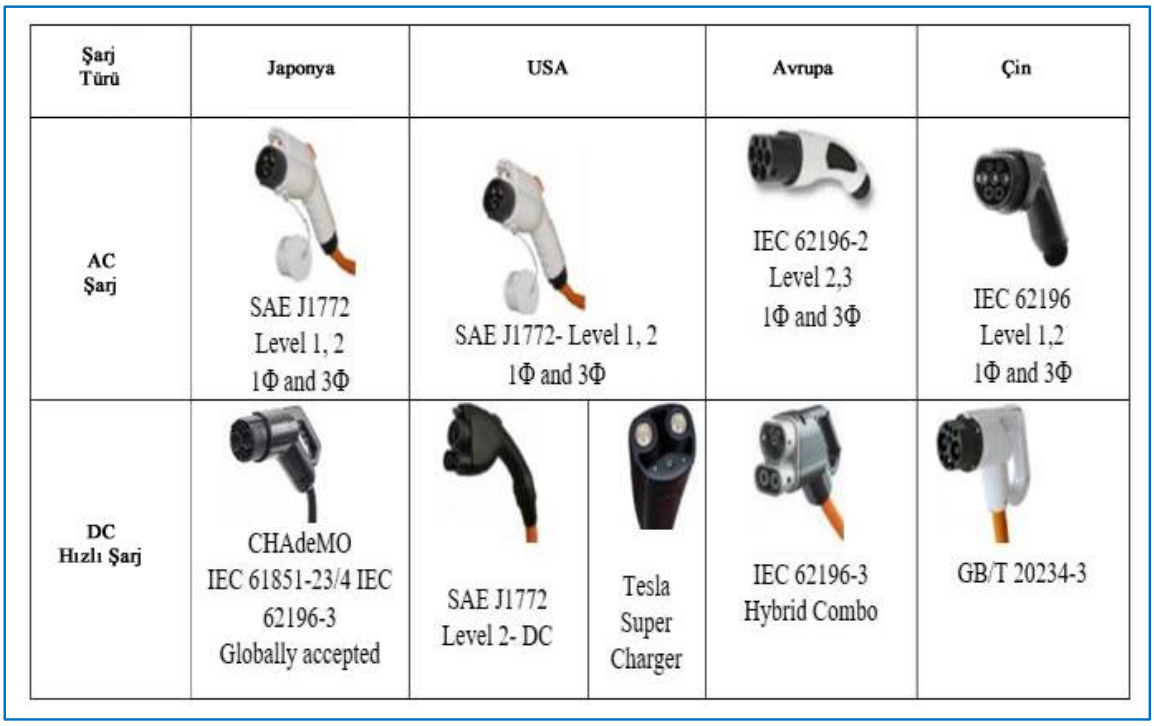
Çizelge 3.3. Arayüz bağlantı ucu açıklamaları

Arayüz Bağlantı Ucu	Açıklama	Arayüz Bağlantı Ucu	Açıklama
GND	Toprak (Ground)	DC±	DC Giriş (Input)
N	Nötr (Neutral)	CP	Kotrol Pilotu (Kontrol Pilot)
NC	Bağlantı yok (No Connected)	CS	Bağlantı Anahtarı (Connection Switch)
L1/2/3	AC Faz A/B/C	S±	CAN Giriş (High/low)
PC	Koruyucu İletken (Protective Conductor)	aux±	Yardımcı Güç Kaynağı (Auxiliary Power Supply)
PD	Yakınlık tespiti (Proximity Detection)	CAN-H/L	Kotrol Alan Ağı (Controller Area Network)
PE	Korumalı toprak (Protected Earth)	CC1	Şarj Sırası Sinyali 1 (Charge Sequence Signal 1)
PP	Yakınlık pilotu (Proximity Pilot)	CC2	Konektör Yakınlık Algılama (Connector Proximity Detection)

EV şarj bileşenleri güç çıkışları, konektörler, kablolar ve bağlı fişler, EV bataryasının güvenilir bir şekilde şarj /deşarj edilmesini ve korunmasını sağlayan şarj cihazının ana bileşenleridir. Şarj çevre cihazlarının konfigürasyonu, güç değerleri ve standartları konuma ve ülkeye göre değişmektedir. Ticari olarak mevcut farklı bağlantı noktaları ve konektörlerin pin görünümleri standartlara göre Şekil 3.6'da verilmiştir ve Şekil 3.7'de ise bu konektörlerin genel görünüşleri verilmiştir [25]. Ayrıca üreticiler ortak bir arayüz geliştirme çalışmalarını da yapmaktadırlar.



Şekil 3.6. Farklı standartlarda EV şarj arayüz portu bağlantı noktalarının pin görünümü



Şekil 3.7. Farklı standartlarda EV şarj konektörleri

3.5. Elektrikli Araç Batarya Şarj Teknikleri

EV'ler farklı motor güçlerine göre farklı güçlerde bataryalara sahiptirler. Batarya kapasitesi şarj sürelerini belirlemektedir. Batarya kapasitesi ve motor gücü ise sürüş mesafesini belirlemektedir (Çizelge 3.4) [56].

EV bataryasının şarjı esnasında batarya sıcaklığı, maksimum akım, voltaj dengesizlikleri ve batarya ömrü gibi kısıtlamalar nedeniyle farklı şarj teknikleri kullanılır [57]. Geleneksel şarj teknikleri sabit akım (CC), sabit voltaj (CV), darbe şarjı ve negatif darbe şarjıdır. Bir diğer teknikte bu şarj tekniklerinin kombinasyonu olan sabit akım/sabit voltaj (CC/CV) şarj tekniğidir [57,58].

3.5.1. Sabit gerilim (CV) şarj tekniği

Bu teknikte EV bataryası sabit bir gerilim değerinde şarj edilir. Şarj işlemi başladığında batarya yüksek akım çekerken bu akım değeri zamanla düşmeye batarya ise dolmaya başlar. Li-ion bataryaların nominal hücre ayar noktasında gerilim değeri 4,2 V'dur (±50 mV) ve izin verilen şarj akımı ise 1 C'dur. Batarya şarj akımı şarj işlemi boyunca azalır. Bu

şarj işlemi, her bir hücre aralarındaki şarjı dengelediği için Pb-asit bataryalar için kullanılır. Bu tekniğin dezavantajlarından birisi bataryanın tam olarak şarj olmaması ve şarj için gereken sürenin 2 saatten fazla olmasıdır. Diğer bir dezavantajı ise bu teknikte ilk anda çok fazla akım çekilmesi ve bu sebeple çoğu konut ve otoparkın elektrik alt yapısının talep edilen güce uygun olmamasıdır [47, 58].

Çizelge 3.4. Marka/modeline göre EV motor ve batarya özellikleri

EV Marka/Model	Sürüş Mesafesi Aralığı (km)	Motor Gücü (kW)	Batarya Kapasitesi		Dahili Yavaş Şarj (AC)		Harici Hızlı Şarj (DC)		
			Nominal (kWh)	Kullanılabilir (kWh)	Güç (kW)	Süre	Güç %10-80 (kW)	Mak. Güç (kW)	Süre (dk)
Renault 5 E-Tech	225-485	110	55	52	11	345	70	100	33
Renault 5 E-Tech 40kWh 120hp	180-385	90	43	40	11	270	55	80	32
Hyundai IONIQ 6 Long Range 2WD	355-715	168	77,4	74	11	480	200	233	16
Hyundai Kona Electric 65 kWh	275-580	160	68,5	65,4	11	420	86	105	34
Nissan Leaf	165-355	110	40	39	3,6	765	40	46	43
Nissan Leaf e+	240-505	160	62	59	6,6	645	44	46	59
Volkswagen ID. Buzz Pro	245-500	150	82	77	11	495	115	175	30
Volkswagen ID.7 Pro	340-675	210	82	77	11	495	125	190	27
Volkswagen ID. Buzz NWB GTX	240-485	250	84	79	11	510	135	185	26
Volkswagen ID.5 Pro	325-665	210	82	77	11	495	120	135	28
Volkswagen ID.3 Pro S - 4 Seats	325-666	150	82	77	11	495	120	170	28
Kia EV9 99.8 kWh AWD	315-625	283	99,8	96	11	630	194	209	22
Kia EV9 99.8 kWh AWD GT-Line	305-610	283	99,8	96	11	630	194	209	22
Kia EV9 99.8 kWh RWD	325-655	150	99,8	96	11	630	194	209	22
Kia EV3 Long Range	320-660	150	81,4	78	11	510	105	130	33
Polestar 3 Long Range Single motor	360-720	220	111	107	11	690	150	250	32
Polestar 3 Long Range Dual motor	350-695	360	111	107	11	690	150	250	32
Polestar 3 Long Range Performance	340-670	380	111	107	11	690	150	250	32
Volvo EX90 Twin Motor	335-665	300	111	107	11	690	150	250	32
Volvo EX90 Twin Motor Performance	325-645	380	111	107	11	690	150	250	32
Volvo EX90 Single Motor	330-665	205	104	101	11	660	140	250	32
BYD ATTO 3	235-490	150	62	60,5	11	390	73	89	37
BYD SEAL 82.5 kWh AWD Excellence	325-630	390	84	82,5	11	540	95	150	38
MG MG4 Electric 64 kWh	255-535	150	64	61,7	6,6	660	116	142	24
Tesla Model 3	300-610	208	60	57,5	11	375	100	170	25
Tesla Model Y	250-510	220	60	57,5	11	375	100	170	25
BMW iX xDrive40	260-515	240	76,6	71	11	465	102	148	31
BMW iX3	275-560	210	80	74	11	480	104	155	31
BMW i5 eDrive40 Sedan	340-670	250	84,4	81,2	11	525	137	206	26
Audi SQ6 e-tron	320-645	380	100	94,9	11	615	200	270	21
Audi Q4 e-tron 55 quattro	285-575	250	82	77	11	495	120	175	28
Mercedes-Benz EQS 450+	505-960	265	125	118	11	765	160	200	33
Mercedes-Benz EQA 250	280-585	140	69,7	66,5	11	435	100	112	29
Opel Astra Electric	225-475	115	54	50,8	11	330	85	100	26
Opel Corsa Electric 50 kWh	205-440	100	50	46,3	7,4	450	78	101	26
Opel Mokka-e 50 kWh	185-395	100	50	46,3	7,4	450	78	101	26
Peugeot e-5008 73 kWh	265-540	157	77	73	11	480	90	160	36
Peugeot e-308 SW	210-440	115	54	50,8	11	330	80	100	28
Fiat 500e Hatchback 42 kWh	165-355	87	42	37,3	11	240	67	85	25
Ford Mustang Mach-E ER AWD	315-645	258	98,7	91	11	585	85	150	47

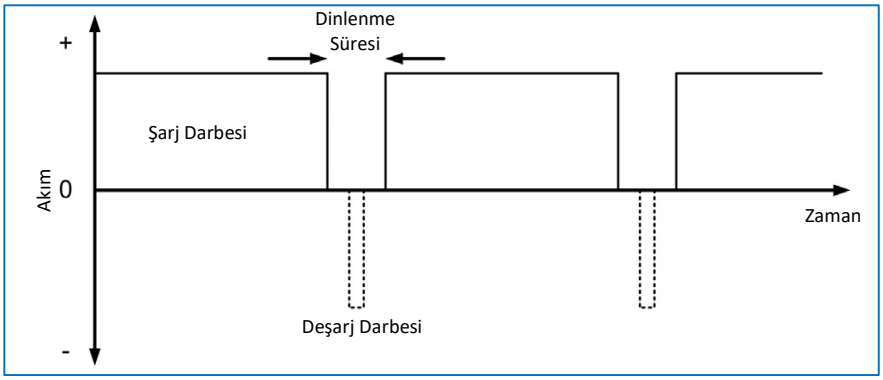
3.5.2. Sabit akım (CC) şarj tekniği

Bu şarj yönteminde, bataryaya sabit bir akım uygulanır ve Batarya gerilimi şarj işlemi süresince yükselir. Maksimum şarj gerilimine ulaşıldığında şarj cihazı kapatılır SOC zamanla doğrusal olarak artan bir grafik göstermektedir. Bu tekniğin en zor kısmı batarya hücresinin SOC değerinin belirlenmesidir. Bu nedenle bataryanın dolup dolmadığının kestirilmesi zordur. Bataryada daha fazla hücre varsa bu şarj yöntemi kullanılmaz, çünkü bazı hücreler diğerlerinden daha fazla şarj olur. Bu yaklaşım başarılı değildir ve batarya hücrelerinin aşırı strese girmesine neden olur. SOC değerinin kestirilmesi için batarya sıcaklığı, gerilim artış değeri ve şarj süresi gibi değerler izlenerek gerçekleştirilir. Ayrıca farklı kontrol algoritmaları kullanarak da SOC değerinin kestirimi yapılabilmektedir [47, 57, 58].

3.5.3. Darbe ve negatif darbe şarj teknikleri

Darbe şarj tekniğinde, şarj akımı bataryaya darbeler şeklinde uygulanır. Şarj oranı darbelerin genişliği değiştirilerek kontrol edilir. Bu şarj yönteminin en belirgin özelliği, bataryanın kimyasal reaksiyonlarını dengelemek için darbeler arasında 20-30 milisaniyelik dinlenme aralıklarının bulunmasıdır. Dinlenme süresi, kimyasal reaksiyonun şarj işlemine ayak uydurmasını sağlar ve bu süre ile elektrot yüzeyinde gaz oluşumu, kristal büyümesi gibi istenmeyen kimyasal reaksiyonlar azaltılır. Ayrıca darbe şarj tekniğinde, sabit darbe genişliği kullanmak yerine, şarj hızını ve şarj verimliliğini artırmak için bataryaya SOC değerine göre değişen darbe genişliğine sahip akım uygulanır [58-60].

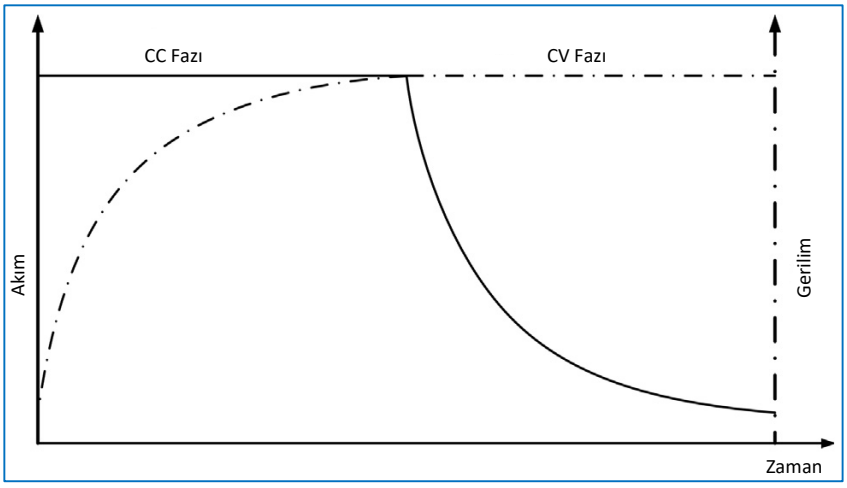
Negatif darbe şarj tekniği ise darbe şarj tekniği ile tamamlayıcı bir tekniktir. Bu yöntem, bataryayı depolarize etmek ve darbeli şarj sırasında elektrot üzerinde oluşan gaz kabarcıklarını temizlemek için darbeli şarj dinlenme süresi boyunca çok kısa bir deşarj darbesi uygular. Negatif darbeli şarjın genel şarj sürecini iyileştirdiği ve batarya ömrünü uzattığı iddia edilmektedir. Şekil 3.8'de darbeli şarj ve negatif darbeli şarjın genel işleyişi gösterilmiştir.



Şekil 3.8. Darbe ve negatif darbe şarj tekniklerinin işleyişi

3.5.4. Sabit akım/sabit voltaj (CC/CV) şarj tekniği

Bu şarj tekniği, Li-ion bataryaları şarj etmek için kullanılır. Bu şarj tekniğinin uygulaması basit, etkilidir. Bu nedenle Li-ion bataryaların şarj edilmesinde CC/CV şarj tekniği kullanılır. CC/CV şarj tekniğinin iki fazı vardır ilk fazında batarya voltajı önceden ayarlanmış bir maksimum şarj voltajına ulaşana kadar batarya sabit akımla şarj edilir. İkinci fazda ise akım önceden ayarlanmış bir minimum değere düşürülene kadar şarj voltajı sabit tutulur. CC/CV şarj tekniği bataryanın güvenli ve verimli bir şekilde şarj edilmesini ayrıca batarya ömrünün mümkün olduğunca uzun süre korunmasını sağlamak için kullanılır. CC/CV şarj tekniği batarya türü Li-ion olan modern EV'lerin çoğunda bataryayı hızlı şarj etmek için tercih edilir. CC/CV şarj tekniği akım ve gerilim grafiği Şekil 3.9'da gösterilmektedir [58,59].



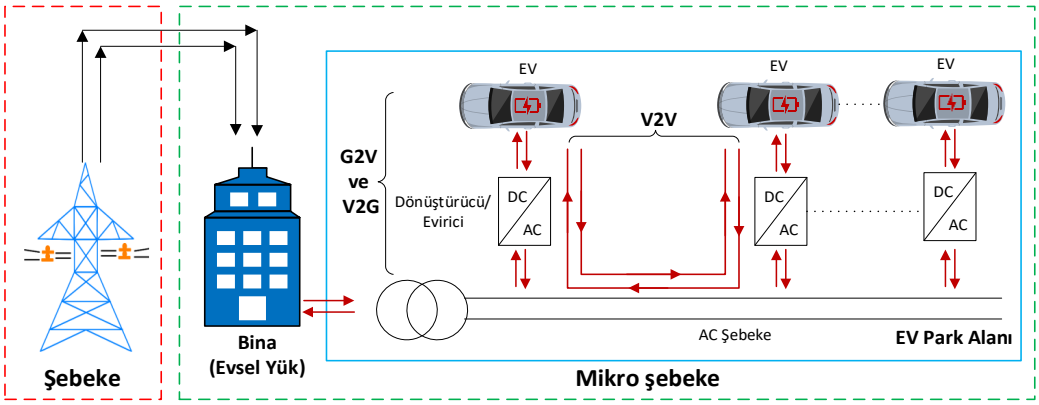
Şekil 3.9. CC/CV şarj tekniği akım ve gerilim grafiği

4. ELEKTRİKLİ ARAÇ ŞARJ TOPOLOJİLERİ VE ŞARJ İSTASYONU MİMARİLERİ

EV ve şebeke arasındaki güç akışının yönü, şarj yöntemini iki kategoriye ayırmaktadır. Güç yalnızca G2V topolojisinde ise tek yönlü şarj olarak adlandırılır. Çift yönlü güç akışı, G2V ve V2G topolojilerinin farklı uygulamalarını mümkün kılmaktadır. Çift yönlü enerji akış topolojileri arz talep dengesini koruyarak beklenmedik güç kalitesi problemlerini gidererek şebekenin kararlılığını sağlamaktadır. V2G topolojisi, şarj altyapısındaki iletişim stratejisi aracılığıyla EV ile elektrik şebekesi arasında çift yönlü enerji akış özelliğine sahiptir. EV bataryası çift yönlü enerji akış modunda elektrik şebekesi için dağıtık üretim, depolama ve yük görevi görür.

Elektrikli araçlar V2G teknolojisi ile ihtiyaca göre şarj veya deşarj olabilir. Büyük Japonya depremi ve tsunami felaketinden sonra etkilenen bölgelerde elektrik enerjisi yeniden sağlanana kadar aydınlatma, cep telefonlarını şarj edilmesi ve radyolar için Nissan firması 66 elektrikli aracıyla şebekeye elektrik sağlamıştır [27]. Son zamanlarda V2G topolojisi için yapılan çalışmalar ile puant yükün azaltılarak güç kalitesinin korunması hedeflenmektedir [11, 25]. Bununla birlikte V2G topolojisi gerilim ve frekans karalılığı sağlama, gelişmiş şebeke kararlılığı, yük takibi, pik yük azaltma, enerji tedariki, reaktif güç desteği ve YEK entegrasyonu gibi yan hizmetler sağlayabilmektedir [2, 24, 25, 61]. Çift yönlü enerji aktarım topolojisi V2G enerjinin aktarıldığı konuma göre araçtan eve (V2H), araçtan binaya (V2B), araçtan yüke (V2L) şekillerinde de isimlendirilmektedir. Çift yönlü enerji akışının gerçekleştiği bir diğer topoloji ise araçtan araca (V2V) enerji aktarım topolojisidir [25, 61]. EV şarj topolojileri bir mikro şebeke sistemi gibi davranacaktır (Şekil 4.1).

EV şarj topolojilerinde mikro şebeke özelliği, şarj istasyonlarına YEK' lerin entegre edilebilmesini ve farklı şarj algoritmalarının uygulanmasını sağlar. Bir mikro şebeke, kendisine bağlı olan YEK'ler sayesinde ada modunda çalışarak bağlı bulunduğu ana şebekenin arz talep dengesini koruyabilir. Bu bağlamda farklı şarj istasyonu mimarileri geliştirilmiştir.



Şekil 4.1. EV şarj topolojilerini gösteren mikro şebeke

Bu bölümde sırasıyla EV şarj istasyonu mimarileri, EV şarj istasyonu mimarileri kontrol yöntemleri, şarj kontrol stratejileri, EV ve şebeke arasındaki çift yönlü dönüştürücü topolojileri, ticari EV batarya şarj sistem mimarileri, çift yönlü eviricilerde kullanılan anahtarlama teknikleri ve evirici için filtre tasarımı konuları incelenmiştir.

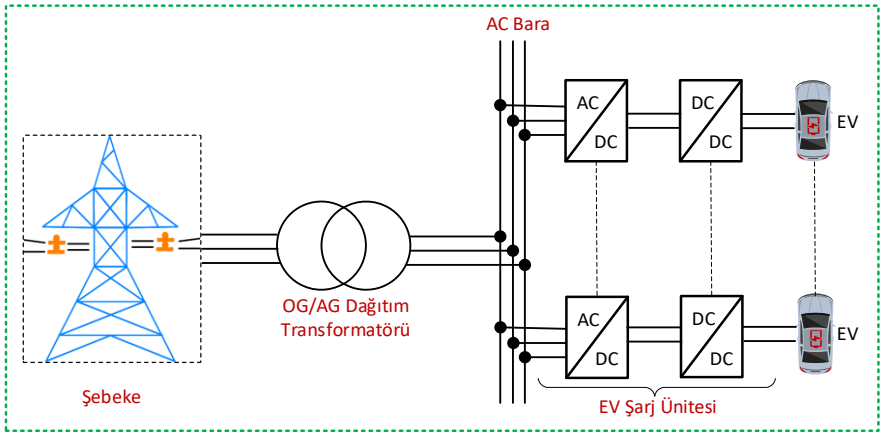
4.1. EV Şarj İstasyonu Mimarileri

EV'lerin şarj altyapısı, kullanıcı gereksinimlerini karşılayarak EV bataryasını rahat ve güvenilir bir şekilde şarj ve deşarj edebilmelidir. EV şarj istasyonu, şebekeden, YEK'den veya batarya enerji depolama sistemlerinden (BEDS) DC akım sağlayarak EV bataryalarının hızlı bir şekilde şarj edilmesini sağlar. Bu özelliği ile bir akaryakıt istasyonuna benzer şekilde performans gösterir. Hızlı şarj istasyonları, şebekeden yüksek güç sağlamak için orta gerilim şebekesine bağlanır. YEK'ler ve BEDS'ler, bu orta gerilim şebekesi üzerindeki yükü hafiflettiği için mevcut EV şarj istasyonunda yaygın olarak tercih edilmektedir. Ayrıca, şebeke desteğini artırmak için V2G yeteneklerine sahip şarj istasyonları şu anda yaygın olarak araştırılmaktadır. EV şarj istasyonlarının mimarisi, sahip oldukları mikro şebekede kullanılan ortak baranın özelliğine göre isimlendirilirler. Şarj istasyonun oluşturduğu mikro şebekede ortak bara AC bara, DC bara ve AC-DC hibrit bara şeklinde yapılandırılmaktadır [25, 62].

4.1.1. Geleneksel şarj istasyonu mimarisi

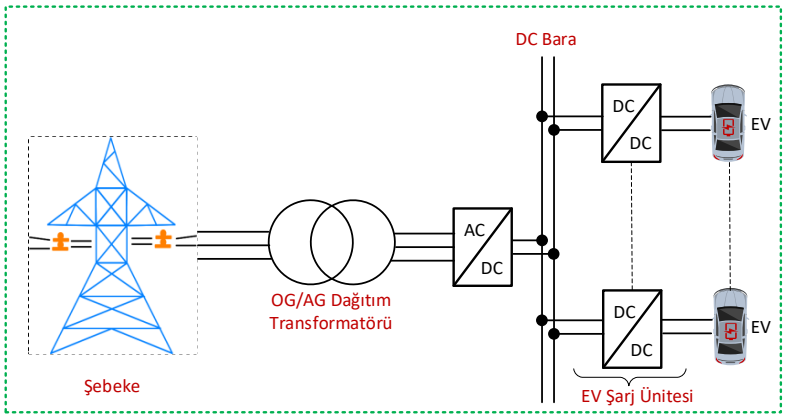
Hızlı şarj istasyonunda AC baraya bağlı üç fazlı AC sinyalin fazlar arası gerilimi 250V-480V arasındadır [2]. Geleneksel EV şarj istasyonundaki şarj ünitesi güç dönüşümü için

bir adet AC-DC doğrultucudan ve bir adet DC-DC dönüştürücüden oluşmaktadır. Şekil 4.2'de gösterilen AC baralı geleneksel şarj istasyonu mimarisinde, düşürücü transformatörün sekonder tarafı ortak AC bara görevi görür. Her bir EV'yi bu ortak AC baraya bağlamak için ayrı AC-DC dönüştürücüler ve DC-DC dönüştürücüler kullanılır.



Şekil 4.2. AC baralı geleneksel şarj istasyonu mimarisi

DC baralı geleneksel şarj istasyonu mimarisinde şarj ünitelerini bağlamak için ortak DC bara oluşturmak amacıyla AC-DC dönüştürücü kullanır ve her bir EV yükü, Şekil 4.3'de gösterildiği gibi bağımsız bir DC-DC dönüştürücü ile ortak DC baraya bağlanır. Dolayısıyla, DC bara mimarileri, AC bara tabanlı mimariye kıyasla daha verimli, uygun maliyetli, küçük ve daha esnek yapılar olup daha yüksek dinamik performansa sahiptir. Ayrıca DC bara BEDS'leri ve YEK'leri bağlama olanağı ile daha uyarlanabilir bir yapı sunar. Ancak, DC baralı geleneksel şarj istasyonu düşük işletme güç faktörüne sahip olduğundan şebekede istenmeyen harmonik etkilere neden olabilmektedir [25].



Şekil 4.3. DC baralı geleneksel şarj istasyonu mimarisi

AC şarj istasyonları, düşük üretim maliyetleri ve gelişmiş AC teknolojisi ve piyasadaki standart şarj bileşenlerinden oluşması nedeniyle halka açık şarj istasyonları olarak tercih edilir. AC bara sistemlerindeki yavaş şarj uygulaması maksimum 19,2 kW güce sahiptir. AC baraya bağlı hızlı ve ultra hızlı şarj istasyonlarında EV şarj standartlarına göre şebeke bileşenlerini korumak için şebeke gelişmiş bileşenlere ve gelişmiş kontrol sistemlerine sahip olması gerekir. Bu nedenle, DC bara mimarisi, şebeke üzerinde düşük etkiye, basit bir kontrol stratejisine ve yüksek verimliliğe sahip olduğundan hızlı ve ultra hızlı EV şarj istasyonları için yaygın olarak tercih edilir. DC ve hızlı şarj 22 kW-200 kW arası ve ultra hızlı şarj >300 kW güç değerlerine sahiptirler [25,50]. Yüksek güçlü harici şarj cihazlarında yaygın olarak kullanılırlar fakat IEC standartlarına göre EV bataryası ile şebeke arasında galvanik izolasyon zorunludur [42]. Şebekeye bağlı bir gerçek EV şarj istasyonu için AC ve DC bara mimarilerinin karşılaştırması Çizelge 4.1'de özetlenmiştir [25,62].

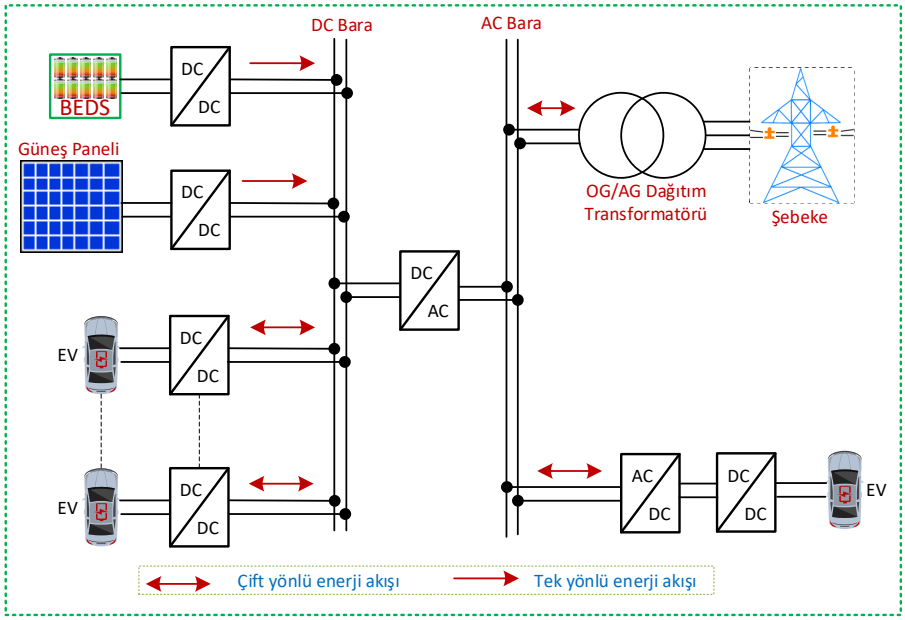
Çizelge 4.1. Şarj istasyonlarında AC ve DC bara mimarilerinin karşılaştırması

Mimari	Avantajlar	Dezavantajlar
AC Baralı Şarj İstasyonu	• Standartlara sahip gelişmiş yüksek teknoloji. • Koruma cihazlarının karmaşıklığı düşüktür. • Yerel yükler için doğrudan kullanım imkanı. • Kararlılık ve ölçeklenebilirlik yüksektir. • Güvenilir anahtarlama ve kontrol teknikleri. • Aktif ve reaktif gücü kontrol edebilme.	• Çok sayıda dönüştürücü nominal gücü ve verimliliği azaltır. • Çoklu dönüştürücüler nedeniyle yüksek maliyet. • Harmoniklerden kaçınmak için hızlı şarj cihazları için ek dönüştürme aşamaları gereklidir. • Yüksek güç kalitesi ve kararlılık elde etmek zordur. • YEK'leri entegre etmek karmaşıktır ve ek DC/DC kademesi gerektirir.
DC Baralı Şarj İstasyonu	• Az bileşen sayesinde yüksek verimlilik ve yüksek güç yoğunluğu sağlar. • Kontrol stratejisi basittir. • YEK ve BEDS kolayca entegre edilmesinde düşük maliyet ve esnek yapılandırma sağlar. • EV yüklerinin yüksek penetrasyonunun şebeke üzerindeki etkilerini azaltmaya yardımcı olur • Frekans dalgalanmalarında azaltma sağlar.	• Ek enerji kaynakları ile karmaşıklık artabilir. • Ani değişikliklere dayanmak için gerekli ek koruma cihazları gerektirir. • Merkezi dönüştürücü, nominal güçteki artış nedeniyle sunucu koşullarına ihtiyaç duyar.

4.1.2. AC-DC hibrit bara tabanlı şarj istasyonu mimarisi

AC-DC hibrit bara tabanlı şarj istasyonu mimarisi genellikle DC güç kaynaklarının kullanıldığı DC şebeke ve AC mikro şebekeden oluşmaktadır. EV şarj istasyonlarının bu hibrit mimarisi, Şekil 4.4'de gösterildiği gibi ayrı dönüştürücüler aracılığıyla AC ve DC baralara bağlanan güç şebekesini ve farklı enerji kaynaklarını içerir. Bu yapılandırma, ek güç dönüştürme durumlarını önleyerek hem AC hem de DC şarjının eş zamanlı çalışmasını sağlar [63]. Bu mimarideki AC ve DC baraları birbirine bağlamak için bir adet çift yönlü dönüştürücü kullanılır ve bu dönüştürücü birbirine bağlı güç dönüştürücüsü olarak

adlandırılır ve ilgili baralar AC ve DC yükleri bağlamak için kullanılır. Birbirine bağlı güç dönüştürücü, her iki taraf arasında enerji dengesini koruyabilir ve yük gereksinimlerine göre çalışabilir. Bu mimari, AC ve DC bara yapılandırmalarından çok güvenilir, esnek ve daha verimlidir. Çift yönlü DC-DC dönüştürücü, V2G topolojisiyle hızlı DC şarj ve deşarj elde etmek için EV ile DC bara arasına bağlanır. AC ve DC bara tabanlı bu mimari, mikro şebekeleri, BEDS'yi ve YEK güç özelliklerini araştırmak için kullanılır. Bu mimari ayrıca V2G topolojisinde AC-DC şarj ve deşarj performansını incelemek içinde kullanılmaktadır [64].

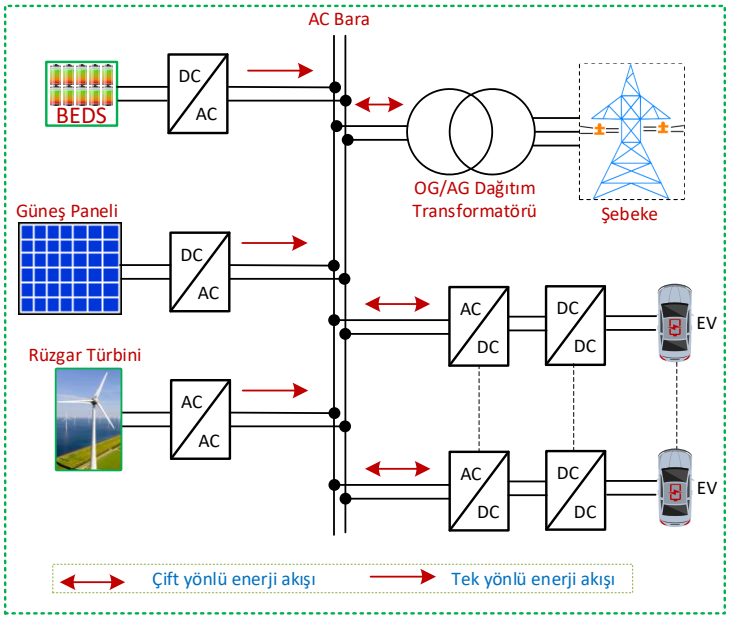


Şekil 4.4. AC-DC hibrit bara tabanlı şarj istasyonu mimarisi

4.1.3. Yenilenebilir enerji kaynağı bağlantılı şarj istasyonu mimarisi

EV şarj istasyonunun bağlı olduğu ana şebekenin aşırı yüklenmesini önlemek için ve daha yüksek oranda temiz enerji kullanımı sağlamak için ana şebekenin yük durumuna bağlı olarak şebeke, bağımsız YEK'ler veya şebeke bağlantılı YEK'ler tarafından desteklenebilir. Çoğu araştırmacı, şarj düzenlerini yöneterek şarj süresi boyunca güç talebini azaltmak için EV şarj istasyonlarında yenilenebilir enerji tabanlı yüksek güç üretimini etkinleştirmeye çalışmaktadır. Ana şebeke, BEDS, güneş paneli (PV), rüzgâr türbini ve V2G topolojisine sahip şarj ünitelerinden oluşan YEK bağlantılı AC bara tabanlı EV şarj istasyonu mimarisi Şekil 4.5'de verilmiştir. YEK bağlantılı AC baralı EV şarj istasyonunda AC bara azaltılmış dönüştürücü aşamalarıyla birlikte DC baraya dönüştürülebilir. YEK tabanlı şarj sistemleri,

EV'lerin pik saatlerde sürdürülebilir şarj için olağanüstü bir fırsat sunmaktadır [65]. YEK'lerin ve EV'lerin şebeke entegrasyonu, ek planlama aşamaları, dönüştürücü tasarımları ve kontrol stratejileri gerektirmektedir.



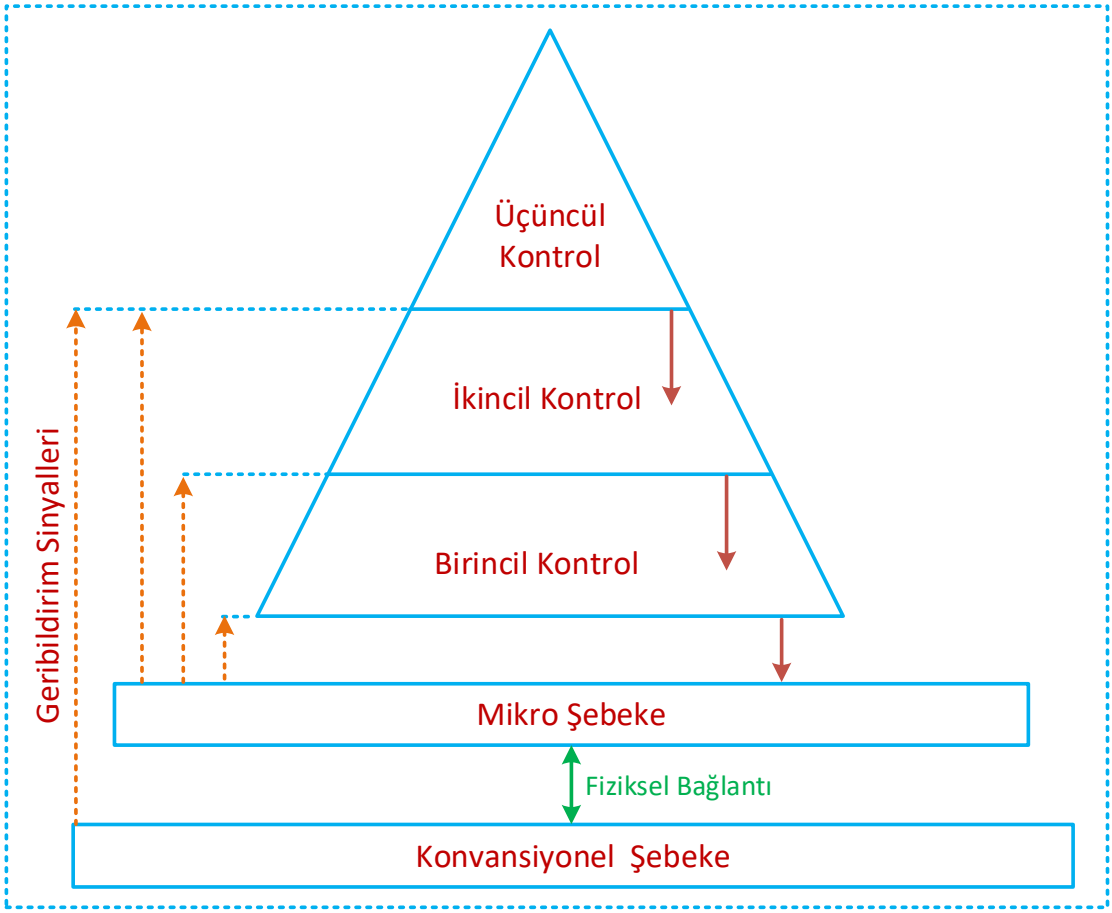
Şekil 4.5. YEK bağlantılı AC bara tabanlı EV şarj istasyonu mimarisi

4.2. EV Şarj İstasyonu Mimarileri Kontrol Yöntemleri

Açıklanan şarj istasyonu mimarilerindeki mikro şebekeler ana şebekeye dağıtık enerji kaynakları (DEK) entegre edilerek tasarlanmaktadır. Şarj istasyonu mikro şebekeleri bu nedenle şebeke bağlantılı ve ada modda çalışabilmektedir. Mikro şebekede meydana gelen hızlı talep değişikliklerine yanıt vermek için akıllı şebeke kavramı geliştirilmiştir. Akıllı şebeke kavramı DEK'lerin etkili şebeke entegrasyonunu ve arz ile talebe göre mikro şebekedeki güç akışının kontrol edilmesini gerektirir. Şarj istasyonu mimarilerindeki mikro şebeke uygun şekilde kontrol edilerek istikrarlı, verimli ve ekonomik olarak çalışması sağlanmalıdır [66-68]. Mikro şebeke kontrol yapısının başlıca rolleri şunlardır [66]:

- Her iki çalışma modu için voltaj ve frekans düzenlemesi;
- Uygun yük paylaşımı ve DEK koordinasyonu;
- Mikro şebekenin ana şebeke ile senkronizasyonu;
- Mikro şebeke ile ana şebeke arasında enerji akış kontrolü;
- Mikro şebeke işletme maliyetinin optimize edilmesi.

Bu gereksinimler farklı önem ve zaman ölçeklerine sahiptir, bu nedenle her gereksinimi farklı bir kontrol hiyerarşisinde ele almak için hiyerarşik bir kontrol yapısı geliştirilmiştir [66]. Hiyerarşik kontrol stratejisi, Şekil 4.6'da gösterildiği gibi birincil, ikincil ve üçüncül kontroller olmak üzere üç seviyeden oluşur [66-68].



Şekil 4.6. Hiyerarşik kontrol stratejisi

4.2.1. Birincil kontrol aşaması

EV şarj istasyonlarının hiyerarşik modelinde birincil kontrol aşamasında ada moda geçiş işleminden sonra mikro şebekenin gerilim akım ve frekans kararlılığı korunur. İkincil kontrol ile elde edilen referans değerleri ile mikro şebeke ile yükler arasındaki enerji akışı kontrol edilir. Ayrıca birincil kontrol seviyesi, DEK'lerin dahili gerilim ve akım kontrol döngülerini içeren, temel donanım kontrollerini de içerir. Bu sayede DEK'lerin aktif ve reaktif güç paylaşım kontrolleri gerçekleştirilir [50, 66].

4.2.2. İkincil kontrol aşaması

İkincil kontrol aşaması EV şarj istasyonlarının enerji yönetim sisteminin (EYS) kontrolleri gerçekleştirilir. Bu nedenle ikinci kontrol aşmasında akıllı şarj algoritmaları işletilir. EYS, birincil kontrol aşaması için referans sinyallerinin üretilmesini sağlar. İkincil kontrolün temel amacı, yenilenebilir enerjinin maksimum kullanımını gerçekleştirmek, elektrik depolama ve ana şebekeden gelen stresi azaltmak, işletme maliyetini düşürmek ve gerekli kısıtlamaları karşılamaktır [50, 66].

4.2.3. Üçüncül kontrol aşaması

Üçüncül kontrol aşamasında ana şebekeye bağlı farklı şarj istasyonlarının koordinasyonu gerçekleştirilir. Bu nedenle üçüncül kontrol aşaması sadece ana şebekenin kontrollerini içerir. Ana şebekenin mevcut durumuna göre referans sinyalleri üretmek için en üst düzey yönetim stratejileri kullanılır. Genellikle mikro şebeke sistemlerinin ikincil seviye denetleyicilerine kontrol sinyalleri üretilir. Temel amaç ana şebekenin güç kalitesinin korunmasıdır. Bu amaçla bu aşamada gerektiğinde ana şebekenin DEK'ler tarafından desteklenmesi, şebekenin arz talep dengesinin korunması için pik saatlerin kaydırılması, EV şarjının ana şebekenin mevcut durumuna göre planlanması ve düşük işletme maliyeti hedeflenmektedir.

Ana şebekenin gerektiğinde DEK olarak EV'ler tarafından desteklenmesi için V2G ve V2V topolojileri bu kontrol aşamasında işletilir. EV'ler şarj istasyonunda şarj edildiklerinde dağıtım şebekesinde bir yük olarak ve deşarj edildiklerinde ise şebekeye bir enerji tedarikçisi olarak çalışırlar. EV'ler şarj veya deşarj moduna herhangi bir başlatma veya kapatma maliyeti olmadan geçebilirler. Bu topolojiler EV şarj zamanını ve süresini ana şebekenin durumuna göre ayarlama, frekans düzenlemesi gibi yardımcı işlevler sağlar. Diğer yandan, EV'lerin belirli zaman noktalarında şarj edilmesi akıllı şarj programı içeriğine yol açar. Bununla birlikte, EV şarj programı büyük ölçüde EV'lerin ve yüklerinin parametrelerine ve özelliklerine bağlıdır. EV şarjının doğasını ve uygun kontrol modunu belirlemek, genellikle Çizelge 4.2'de verilen parametrelere bağlı olan karmaşık bir süreçtir [50].

Çizelge 4.2. EV şarj modunu belirleyen parametreler

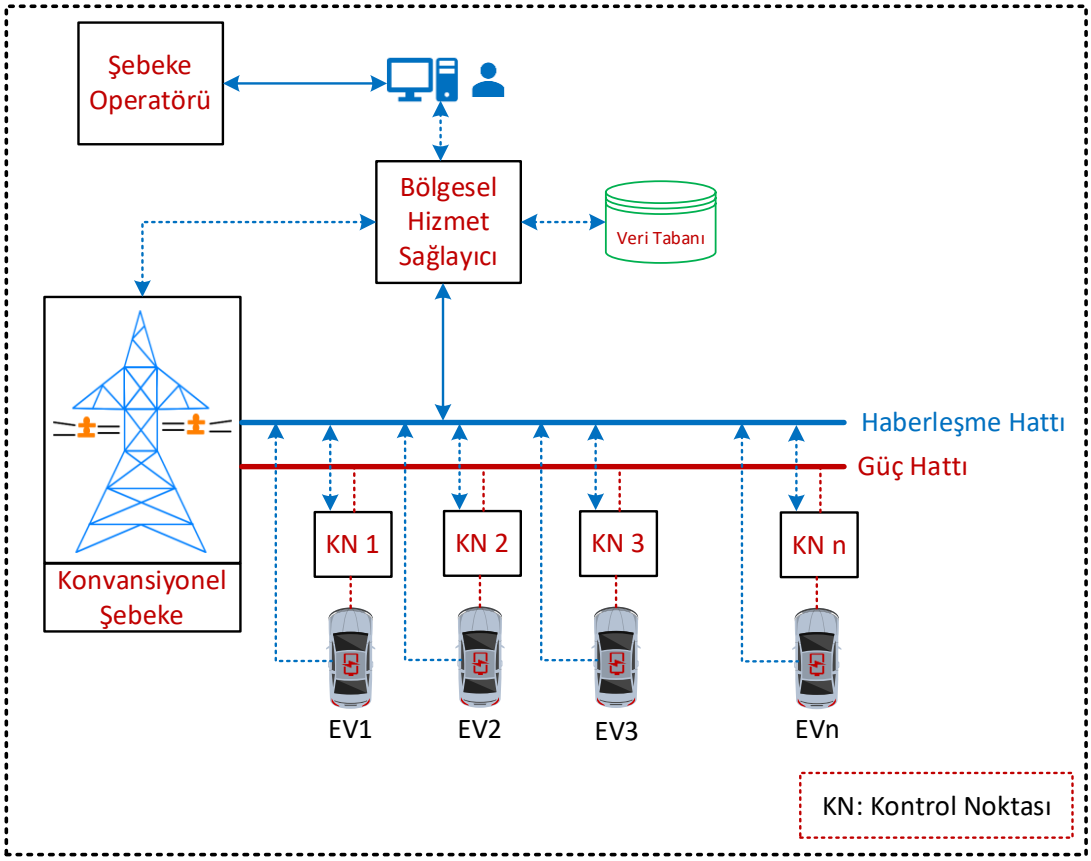
Parametre	Açıklama
EV seyahat süresi	Bu süre esas olarak kullanıcının kilometre veya seyahat aralığını ifade eder. Bu parametre ile kullanıcının şarj süresi, güç talebi ve şarj istasyonuna erişimi tanımlar.
EV sürüş düzeni	Bu parametre, kullanıcının şarj tercihlerini yansıtır; kullanım düzenlerindeki fark dikkate alındığında, belirli miktarda şarj yükü dağılımı ortaya çıkar.
EV batarya özellikleri	Bu özellikler batarya kapasitesi, şarj/deşarj oranı ve SOC değerlerini ifade eder.
EV sayısı	Bu sayı, yük profilinin genel düzenlemesini tanımlar
Şarj istasyonları ve standartları	Şarj istasyonlarının standartlarını tanımlar ve şarj seviyelerini belirler.
Şarj kontrol stratejisi	Bu strateji merkezi ve merkezi olmayan kontrol stratejilerini tanımlar.

4.3. Şarj Kontrol Stratejileri

Şarj Kontrol stratejileri ile doğrudan kontrol ve dağıtılmış kontrol olarak da bilinen merkezi ve merkezi olmayan kontrol stratejileri tanımlanır. Merkezi kontrol stratejisi, bilgi ve parametrelerin toplanmasının ardından toplu düzeyde merkezi olarak gerçekleştirilen EV şarj programını ifade eder. Merkezi olmayan kontrol stratejisi ise her EV'nin kendi şarj stratejisini içerir.

4.3.1.Merkezi şarj kontrol stratejisi

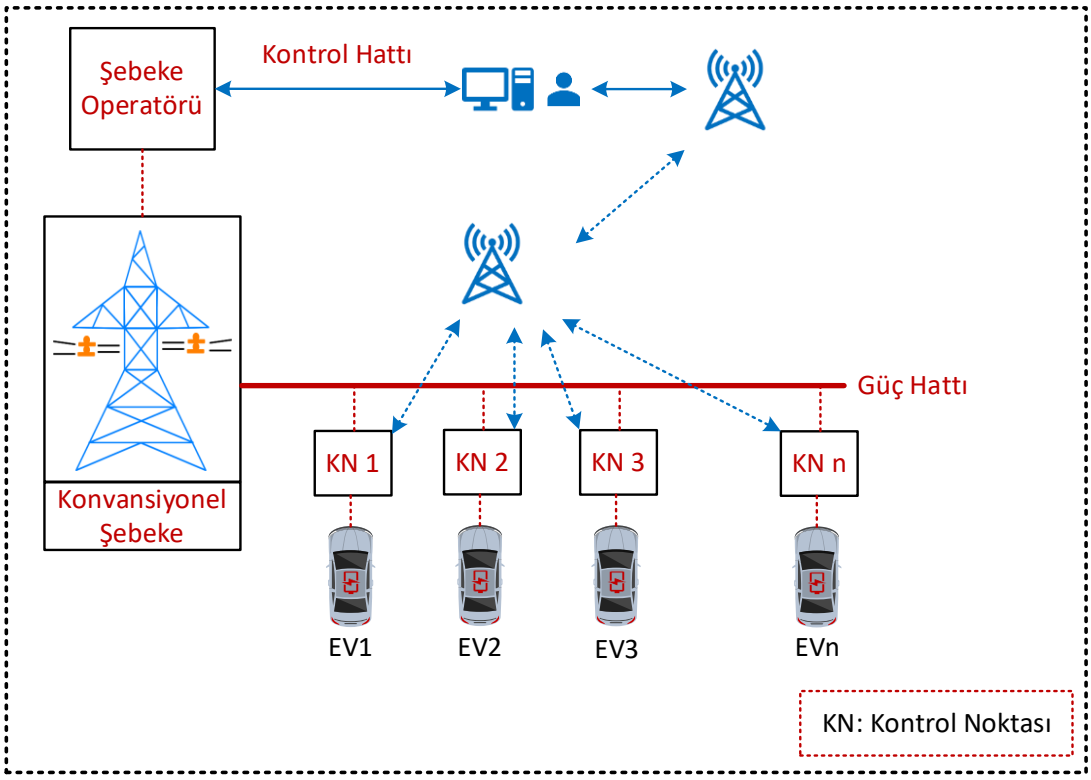
Merkezi kontrol stratejisinde kapasite seviyesi, şarj oranı ve SOC gibi EV'lerin batarya bilgileri bölgesel hizmet sağlayıcı tarafından toplanır. Toplanan bilgilere göre bölgesel hizmet sağlayıcının enerji gereksinimleri belirlenir. Bu enerji gereksinimlerine göre her bölgesel hizmet sağlayıcı ana şebeke operatörüyle bir sözleşme yapar [68]. Bölgesel hizmet sağlayıcıların yaptıkları sözleşmelere göre, ana şebeke operatörü diğer yükleri, çeşitli kaynakların güç üretim kapasitesi seviyelerini ve diğer sistem kısıtlamalarını göz önünde bulundurarak, sözleşme kapsamındaki her bölgesel hizmet sağlayıcısı için uygun enerji paylaşımına karar verir. Bölgesel hizmet sağlayıcı ise yapılan sözleşmeye dayanarak her EV için beklenen enerji gereksinimini belirler [69]. Ancak, merkezi şarj kontrol stratejisinin dezavantajı, sistemin dinamik olması ve EV'lerin şarj istasyonuna farklı zamanlarda gelip gitmesidir. Bu nedenle, uzun vadeli sabit bir planlama profili elde etmek oldukça zordur [50]. Merkezi kontrol stratejisi mimarisi Şekil 4.7'de sunulmuştur.



Şekil 4.7. Merkezi şarj kontrol stratejisi

4.3.2.Merkezi olamayan şarj kontrol stratejisi

Merkezi olmayan kontrol stratejisinde, her EV enerji gereksinimini doğrudan ana şebeke operatörü ile paylaşır. Ana şebeke operatörü derlenen bilgileri kullanarak enerji gereksinimlerini belirler. EV sahipleri potansiyel olarak araç bataryasını ne zaman şarj edeceğine ve ne kadar enerji gerektiğine karar verebilir. Ana şebeke operatörü kullanım maliyetini belirleyerek ücretlendirme yapar. Şebekeye bağlantı maliyetinin en yüksek ve en düşük fiyat arasında olduğu süre boyunca, tarife mümkün olan en düşük elektrik fiyatlarına sahip zaman adımlarını değerlendirmek üzere düzenlenir. Merkezi olmayan kontrolün temel faydası, birçok EV'yi barındırma esnekliği ve penetrasyonun planlama sürecine izin vermesidir. Ancak, eksiksiz EV bilgisinin olmaması nedeniyle, şarj şeması bazen optimum olamamaktadır [50]. Merkezi olmayan kontrol stratejisi mimarisi Şekil 4.8'de sunulmuştur.



Şekil 4.8. Merkezi olmayan şarj kontrol stratejisi

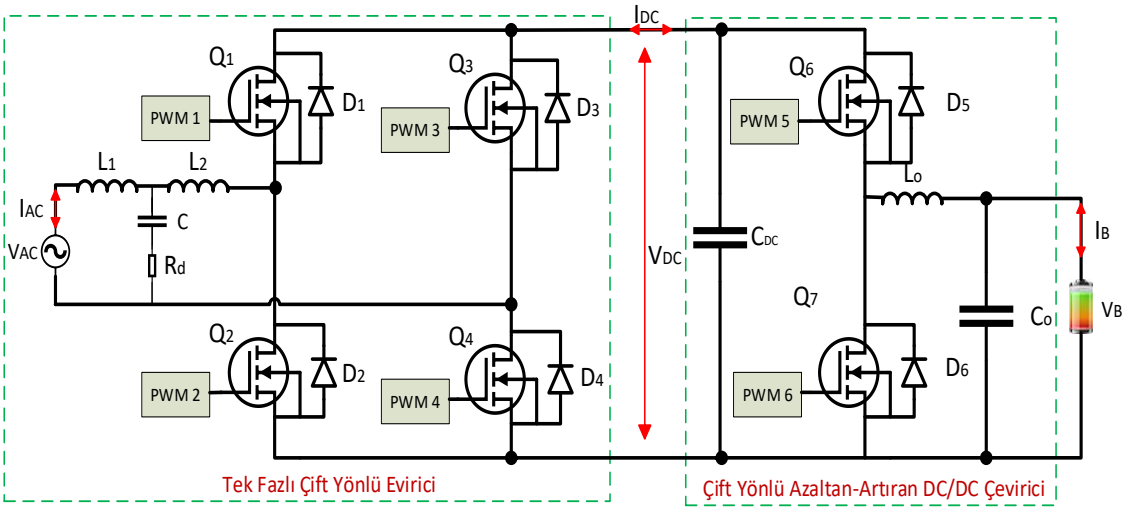
4.4. EV ve Şebeke Arasındaki Çift Yönlü Dönüştürücü Topolojileri

Bir EV'nin batarya enerji akış yönü, tek yönlü veya çift yönlü olabilmektedir. Tek yönlü şarj sisteminde, şebeke tarafında AC-DC dönüştürücü ve EV dahili şarj cihazında tek yönlü DC-DC dönüştürücü kullanır. Çift yönlü EV şarj sisteminde ise, çift yönlü AC-DC dönüştürücü ve çift yönlü DC-DC dönüştürücü kullanılır. Harici şarj cihazları aracılığıyla enerji hem EV bataryasına (şarj) hem de şebekeye (deşarj) aktarılabilir [25].

EV ile ana şebeke arasındaki enerji akışı için kullanılan çift yönlü dönüştürücü hem EV hem de şebeke için belirli temel gereksinimleri karşılamalıdır. EV bataryaları genellikle 300 ile 400 V arasında maksimum batarya voltajına ve yerleşik şarj modunda yaklaşık 3 kW'lık çift yönlü şarj cihazı güç derecesine sahiptir. Yalıtım, voltaj stresi ve akım stresi dikkate alındığında, genellikle tam köprü topolojileri tercih edilir. Dahası, yerleşik şarj modu koşulları dönüştürücünün yüksek güç yoğunluğuna, küçük boyuta, hafifliğe sahip olmasını ve uygun maliyetli, güvenilir, sürdürülebilir olmasını gerektirir. Ana şebekelerde, çift yönlü enerji akışı yüksek dönüşüm verimliliğini karşılamalı ve ilgili harmonik standartlarına uymalıdır [25, 51, 70].

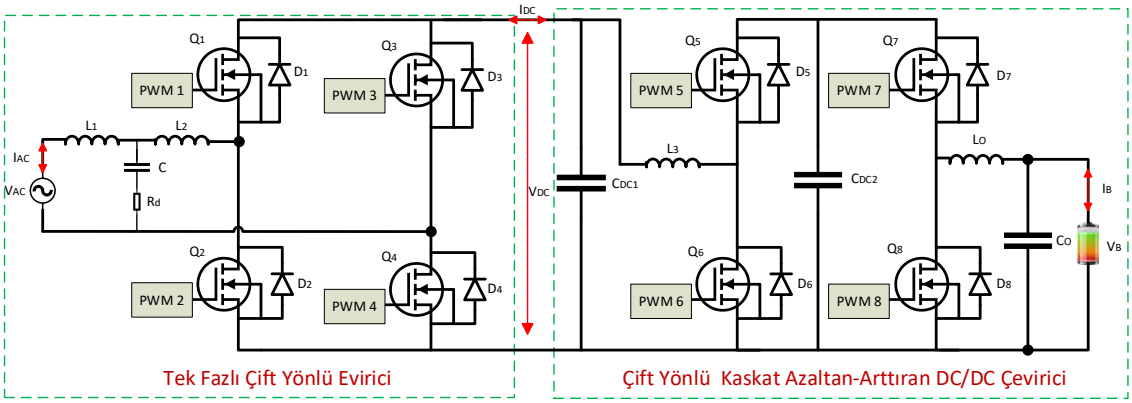
Çift yönlü AC-DC dönüştürücüler, G2V modunda AC gücünü DC gücüne dönüştüren bir doğrultucu ve V2G modunda DC gücünü AC gücüne dönüştüren bir invertör olarak çalışır. Çift yönlü AC-DC dönüştürücüler IEEE 519-2014 gibi standartlara uymak için şebekeye güç faktörü düzeltmesi (GFD) ve harmonik filtreleme de yapmalıdır. G2V modunda çift yönlü AC-DC dönüştürücülerde ilgilenilmesi gereken önemli bir husus, şebeke sıfır voltaj geçişlerini doğru bir şekilde tespit etmektir; aksi takdirde şebeke dönüştürücüsü boyunca faz-nötr kısa devreye ve giriş voltajı ile akım dalga biçimlerinin bozulmasına yol açabilir [71, 72]. İdeal olarak, V2G modunda şebekeye aktarılan gerilimin, voltaj seviyesi, fazı ve frekansı şebeke gerilimi ile senkronize olmalıdır. V2G modunda çıkış akımının toplam harmonik bozunumu (THD) değerinin standartlara uygun olması gerekir. V2G topolojisi için çeşitli ve farklı çift yönlü AC-DC dönüştürücüler geliştirilmiştir. Dahili ve harici şarj cihazlarında kullanılan çift yönlü dönüştürücüler izoleli ve izolesiz olarak tasarlanmaktadır.

Şekil 4.9'da izolesiz dahili çift yönlü şarj cihazları için kullanılan çift yönlü AC-DC dönüştürücü mimarisi sunulmuştur. Bu mimari tam köprü devre düzeni ve kontrol esnekliği nedeniyle en yaygın kullanılan çift yönlü AC-DC dönüştürücü mimarisidir. Bu mimari G2V ve V2G topolojilerinde çalışmaktadır. Bu mimari tek fazlı çift yönlü evirici ve çift yönlü azaltan-artıran DC/DC çevirici yapılarından oluşmaktadır. V2G topolojisinde EV bataryası, ana şebekede güç problemleri meydana geldiğinde evsel yükleri beslemek için ada modda voltaj kontrollü bir kaynak olarak kullanılabilir. Çift yönlü AC-DC dönüştürücüler, G2V topolojisinde aktif bir doğrultucu işlevi görür. V2G topolojisinde ise, çift yönlü AC-DC dönüştürücüler güç faktörünü korumak için şebekeye elektrik sağlayan düzenlenmiş bir akım kaynağı olarak çalışır. α-β koordinatlarında bir faz kilitli döngü (PLL) algoritması, V2G topolojisinde sağlanan gücün voltajını ve fazını, şebeke voltaj ve frekansı ile senkronize etmek için kullanılmıştır. DC bara voltajını düzenlemek için bir Orantılı-İntegral (PI) denetleyici kullanılır. L_1, L_2 ve C birlikte giriş tarafında düşük geçişli bir LCL filtre görevi görürken, L_o ve C_o birlikte çıkış tarafında düşük geçişli bir LC filtre görevi görür. C ile seri olarak kullanılan R_d, bir sönümleme direncidir. C_{DC}, anlık enerji depolama elemanı görevi görür ve üzerinde DC voltaj indüklenir. Galvanik izolasyon olmadığından, dahili bir arıza durumunda güvenlik sorunu meydana gelebilir [70-72].



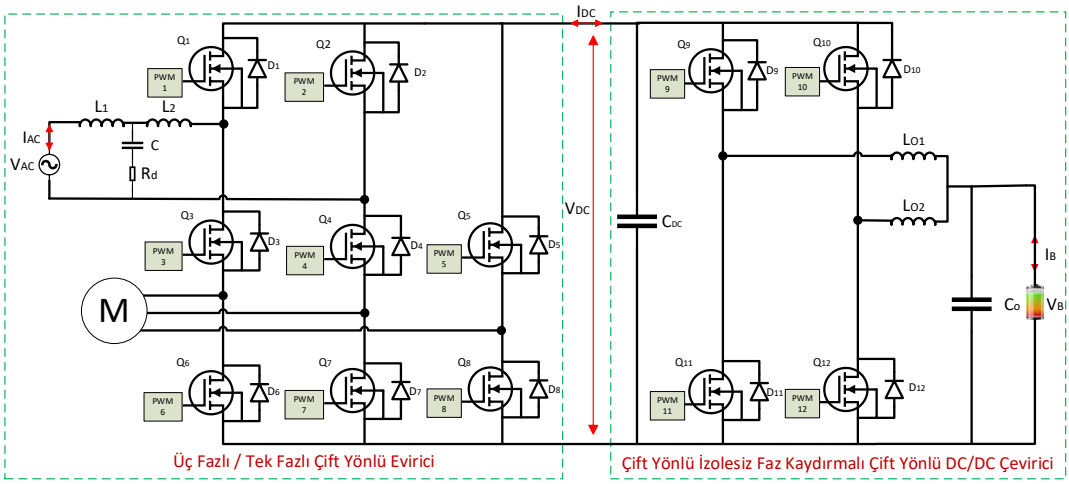
Şekil 4.9. Tek faz çift yönlü evirici ve çift yönlü artıran-azaltan DC/DC çeviriciden oluşan izolesiz dahili, şarj cihazı mimarisi

Şekil 4.10'da da izolesiz dahili çift yönlü şarj cihazları için kullanılan çift yönlü AC-DC dönüştürücü mimarisi sunulmuştur. Bu mimari ise AC tarafta tek fazlı çift yönlü evirici, batarya tarafında ise çift yönlü kaskat azaltan-arttıran çeviriciden oluşmaktadır. EV bataryası, sabit akım, voltaj ve güç değerleri ile bir kontrolör tarafından şarj edilir. Bu mimaride de şebeke tarafında LCL filtre kullanır ve batarya tarafında ise LC filtre kullanır. V2G topolojisinde EV bataryasının giriş ve çıkış voltajının örtüşmesini sağlayan izolesiz çift yönlü kaskat azaltan-artıran DC/DC çevirici kullanılmaktadır. Bu mimaride giriş ve çıkış voltaj aralıklarını örtüştürmek için yalnızca dört anahtar ve bir ara DC bağlantı kapasitörü (C_{DC2}) kullanır. İki ayrı PI kontrolörü, çıkış voltajını ve ara DC bağlantı voltajını kontrol eder. Çift Yönlü kaskat azaltan-artıran DC/DC çevirici basit bir yapıya sahiptir ve minimum parça sayısı, yüksek verimlilik, yüksek güvenilirlik ve mükemmel geçici performans sağlar. Ancak bu çeviricinin bazı sınırlamaları da vardır. Bu sınırlamalar daha fazla anahtarlama kaybına yol açan daha fazla anahtar sayısı, karmaşık kontrol algoritması ve diyotların ters geri dönüşümü nedeniyle daha fazla açma kaybıdır. Bu şarj mimarisinde hem G2V hem de V2G topolojisinde reaktif güç kompanzasyonu kolaylıkla yapılabilmekte ve dolayısıyla güç faktörü kompanzasyonu sağlanabilmektedir [24, 70-73].



Şekil 4.10. Tek fazlı çift yönü evirici ve çift yönlü azaltan-artıran DC/DC çeviriciden oluşan dahili, şarj cihazı mimarisi

Şekil 4.11'de izolesiz dahili çift yönlü şarj cihazları için kullanılan AC-DC dönüştürücü mimarisi verilmiştir. Bu mimari çift yönlü sekiz anahtarlı evirici ve çift yönlü faz kaymalı DC/DC çeviriciden oluşmaktadır. Bu topolojide araç üzerinde kullanılan DC/DC çevirici, batarya şarj ve deşarjı için kullanılmaktadır. Üç faz evirici, motor sürücü devresi için kullanılmaktadır. Tek faz çift yönlü evirici ise G2V topolojisinde EV batarya şarjı için kullanılırken V2G topolojisinde ise EV bataryası ile şebekeye enerji aktarılır. Çift yönlü faz kaydırmalı DC/DC çeviricide çift faz kaydırma ile her iki koldaki akım arasında180º faz farkı oluşturulur. Bunun sayesinde toplam çıkış akım dalgalılığı yarı yarıya düşürülmektedir. Bu dönüştürücü mimarisi akım dalgalanmalarını ve THD'yi etkili bir şekilde en aza indirir. EV bataryasının ısınmasını sınırlamak için güç faktörünün birlik oranında çalışmasını sağlayarak sistemin güvenilirliğini artırır. Bu dönüştürücü mimarisi, EV şarj uygulamaları için yapılan çalışmalarda sıklıkla tercih edilmektedir. Bu çift yönlü, çok fonksiyonlu ve iki aşamalı mimari karmaşık bir kontrol yapısı gerektirmektedir. Bu nedenle dönüştürme işlemleri sırasında önemli komplikasyonlar ortaya çıkarmaktadır. Ayrıca evirici katındaki motor sürücü ve şebeke bağlantılı eviricide kullanılan anahtarlar maliyetin artmasına ve performans düşüşüne neden olmaktadır [51, 53, 71, 72, 74, 75].

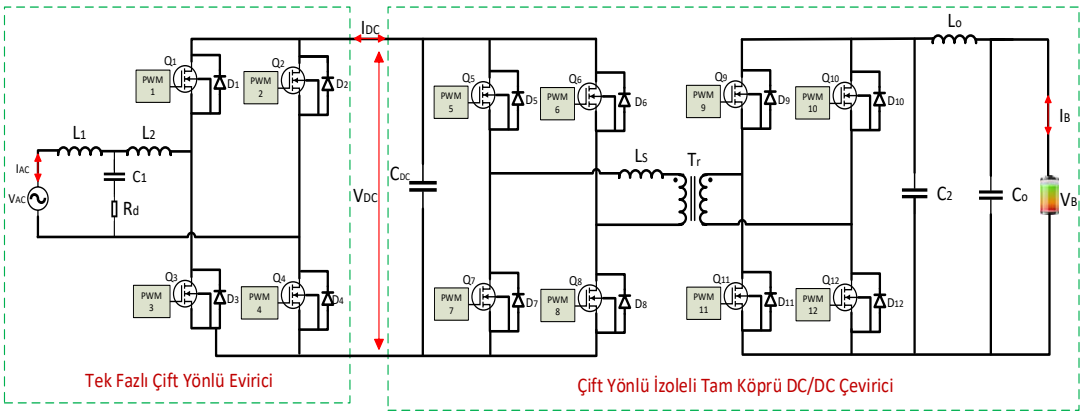


Şekil 4.11. Çift yönlü sekiz anahtarlı evirici ve çift yönlü faz kaymalı DC/DC çeviriciden oluşan izolesiz dahili şarj cihazı mimarisi

Yukarıda verilen çift yönlü şarj cihazları için verilen AC-DC dönüştürücü mimarileri izolesiz mimarilerdir. İzolesiz dönüştürücüler, basit yapıları, yüksek güç yoğunlukları ve ulaşılabilir kontrol stratejileri nedeniyle EV bataryalarının şarjında orta ve yüksek güç uygulamaları için tercih edilir [2].

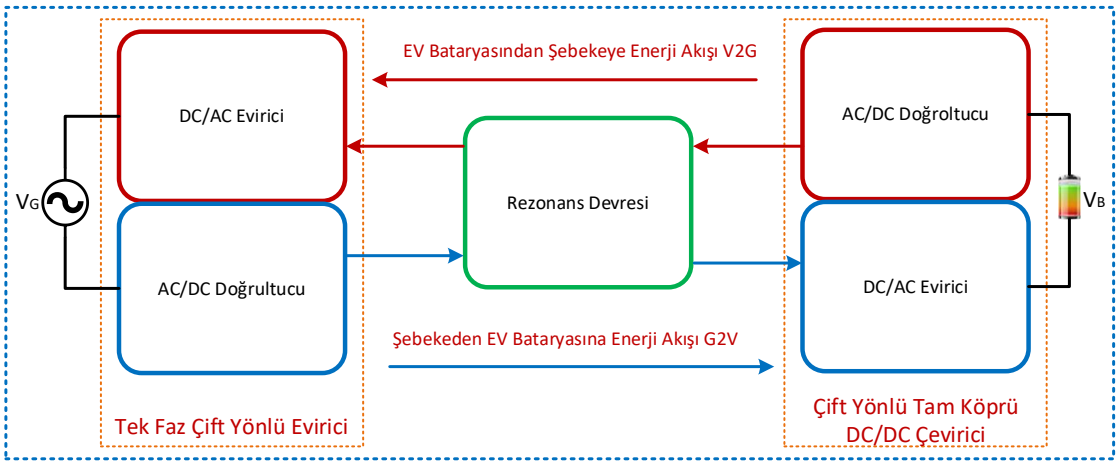
EV'lerde batarya şarjındaki güvenlik kaygıları nedeniyle dahili şarj cihazlarında izoleli dönüştürücüler tercih edilir. Şekil 4.12'de izoleli dahili çift yönlü şarj cihazları için kullanılan AC-DC dönüştürücü mimarisi verilmiştir. Bu mimaride şebeke tarafında tek fazlı çift yönlü evirici, batarya tarafında ise çift yönlü tam köprü DC/DC çevirici kullanılmıştır. Tek fazlı evirici girişinde yüksek frekanslı harmonikleri bastırmak için LCL filtre kullanılmıştır. Çift yönlü evirici, DC hat kapasitörü (C_{DC}) aracılığıyla izole edilmiş çift yönlü tam köprü DC/DC çeviriciye bağlanmıştır. Bu çevirici yüksek verimliliği, yüksek güç yoğunluğu, çift yönlü güç akışı, doğal yumuşak anahtarlama, galvanik izolasyon ve geniş voltaj transfer oranı aralığı nedeniyle DC-DC güç aktarım aşamasında kullanılmaktadır. İzolasyon trafosu (T_r) şebeke ile enerji depolama aygıtı arasında voltaj eşleştirme ve/veya galvanik izolasyon gerektiren çoğu uygulamada kullanılır. İzoleli mimarilerde hacim, ağırlık ve hat gürültüsü önemli ölçüde artacaktır. Sonuç olarak, yerleşik durumda, hat frekansı transformatörünü yüksek frekans izolasyon transformatörü ile değiştiren birkaç topoloji yaygın olarak kullanılır ve bu da mobil enerji depolama sistemini daha kompakt ve esnek hale getirir. Bu mimarinin DC-DC kısmındaki anahtarlama elemanları (Q_5'den Q_{12}'ye) sıfır voltaj anahtarlama ile açılmasını sağlamak için faz kaydırma kontrolü ile kontrol edilir. İki köprü arasındaki, faz kayması açısının

polaritesi enerji akışının yönünü belirler. Faz kayması açısı çıkış gücünü kontrol eder. Bu dönüştürücü mimarisinde yüksek titreşimli giriş akımı, sınırlı yumuşak anahtarlama aralığı, dönüştürücüdeki yüksek dolaşım akımı gibi çeşitli sınırlamalar vardır [2, 42, 70, 72, 76].



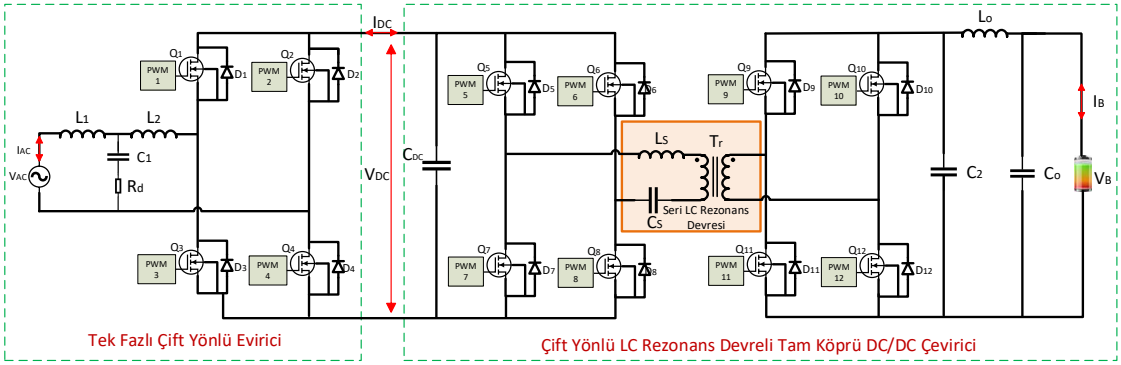
Şekil 4.12 Çift yönlü tek fazlı evirici ve çift yönlü izoleli tam köprü DC/DC çeviriciden oluşan izoleli dahili şarj cihazı mimarisi

Diğer bir çift yönlü izoleli şarj mimarisi ise Şekil 4.13'deki çift yönlü izoleli rezonans DC/DC çeviricinin kullanıldığı mimaridir [76]. Çift yönlü rezonans dönüştürücü, özel bir izolasyonlu çift yönlü DC/DC çevirici türüdür. Bu tip çevirici genellikle EV şarj istasyonları, rüzgar enerjisi ve güneş enerjisi gibi YEK'lere, enerji depolama sistemleri gibi çift yönlü enerji akışına sahip sistemlere uygulanır. Çift yönlü rezonans dönüştürücünün temel çalışma prensibi, makul şekilde tasarlanmış endüktif ve kapasitif bileşenler vasıtasıyla rezonans durumundaki giriş elektrik enerjisinin dönüşümünü gerçekleştirmektir. Çift yönlü rezonans dönüştürücünün özelliklerinden biri, düşük seviyede elektromanyetik girişimle yüksek verimli çift yönlü enerji dönüşümü sağlama yeteneğidir. Yaygın çift yönlü rezonans dönüştürücü topolojileri arasında çift yönlü seri rezonans dönüştürücü, çift yönlü paralel rezonans dönüştürücü, çift yönlü LC rezonans dönüştürücü, çift yönlü LLC rezonans dönüştürücü, çift yönlü LCC rezonans dönüştürücü, çift yönlü LCL rezonans dönüştürücü, çift yönlü CLLC rezonans dönüştürücü, çift yönlü CLLLC rezonans dönüştürücü gibi mimariler bulunur [53, 76].



Şekil 4.13. Çift yönlü rezonans dönüştürücünün çalışma prensibi

Şekil 14'de verilen mimari Şekil 4.12'de verilen mimaride batarya tarafında çift yönlü tam köprü izoleli DC/DC çeviricide LC rezonans devresi kullanılarak elde edilmiştir. Tam köprü DC/DC çeviricide rezonans devresinde de faz kaymalı kontrol kullanılır. Faz kaymalı kontrol yöntemiyle enerji akış yönü değiştirilerek G2V ve V2G topolojileri işletilir. Bu şarj mimarisinde rezonans devresinde primer tarafındaki sürücü dört anahtar sıfır voltaj anahtarlama modunda, sekonder tarafta yer alan dört anahtar ise sıfır akım anahtarlama modunda çalışır. Bu sayede anahtarlama kaybı sıfıra yakın olmaktadır. Bu sayede en yüksek verim seviyelerine ulaşabilmektedir. Rezonans çeviricilerde akım yolundaki seri kondansatör C_S akım taşıdığından boyut olarak devrenin boyutlarında önemli yer tutmaktadır. Anahtarlama frekansı MHz'ler seviyesine çıktıkça rezonans devresindeki C_S'nin kapladığı yer küçülmektedir. Böylelikle bu sorun giderilmiş olur [51, 70].



Şekil 4.14. Çift yönlü tek fazlı evirici ve çift yönlü LC rezonans devreli tam köprü DC/DC çeviriciden oluşan izoleli dahili şarj cihazı mimarisi

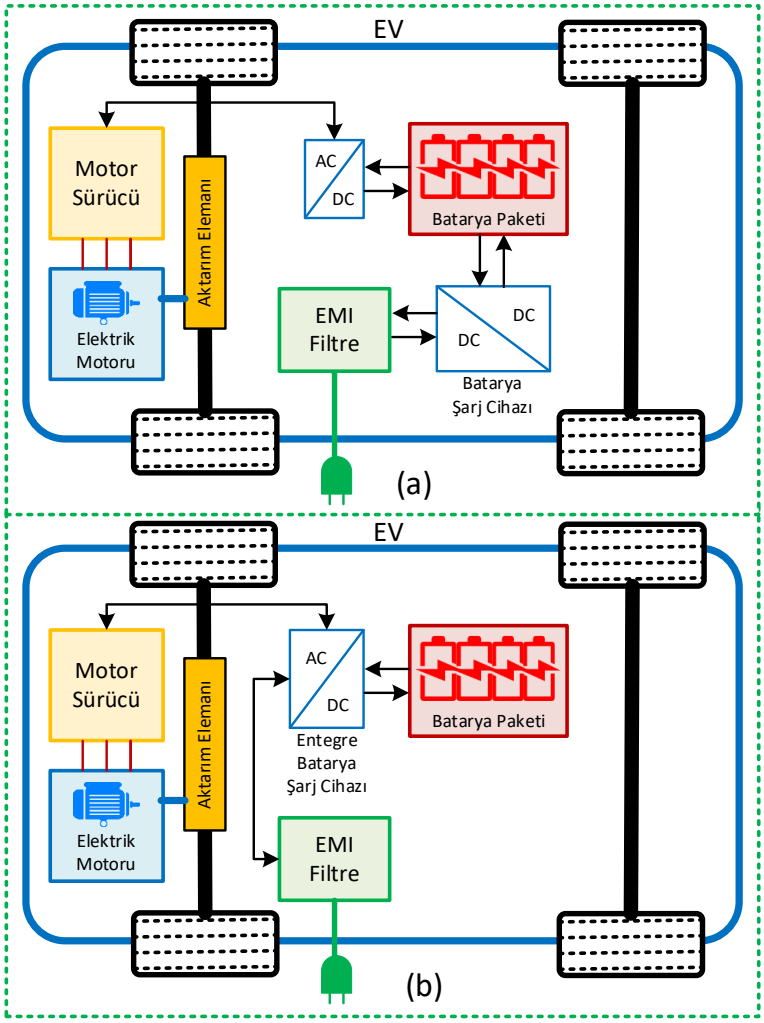
Yukarıda EV şarj cihazları için dahili çift yönlü izolesiz ve izoleli çevirici mimarileri açıklanmıştır. Bu mimarilerin hepsinin ortak özelliği çift yönlü enerji akışına izin vermeleridir. Kontrol teknikleri kullanılarak bu mimarilerde G2V ve V2G topolojileri işletilmektedir. Güvenlik gerekçeleri nedeniyle izolesiz çeviriciler deneme ve test amaçlı yapılan çalışmalarda kullanılmaktadır. Trafiğe çıkabilecek, yolcu taşıyacak EV'lerde standartlara uygun izoleli çeviriciler kullanılmaktadır.

4.5. Ticari Elektrikli Araç Batarya Şarj Sistem Mimarileri

Ticari EV şarj cihazları dahili ve harici olmak üzere iki kategoride sınıflandırılmaktadır. Dahili ve harici şarj cihazları farklı firmalar tarafından tasarlanarak üretilmektedir.

4.5.1. Dahili batarya şarj cihazlarının sistem mimarileri

Dahili şarj cihazları, sınırlı boyut, ağırlık, hacim ve güç nedeniyle Seviye 1 ve Seviye 2 şarj cihazlarıyla uyumlu olan tek yönlü veya çift yönlü enerji aktarımı yeteneklerine sahiptir. Yerleşik şarj cihazının yapılandırması Şekil 4.15'de sunulmuştur [25]. Yerleşik şarjlar 1,9 kW (Seviye 1) ve 19,2 kW (Seviye 2) AC güç seviyeleri sağlayabilir. Şebekeye bağlı AC şarj istasyonundan dahili şarj cihazındaki AC-DC dönüştürücü beslenir. Daha sonra DC-DC dönüştürücü, uygun güç seviyelerini düzenler ve batarya yönetim sistemi (BYS), güç kontrol ünitesi ile iletişim kurarak bir koruma devresi aracılığıyla EV bataryasını şarj eder. Dahili EV şarj cihazları genel olarak tek yönlü veya çift yönlü ve tek fazlı veya üç fazlı şarj cihazları olarak kategorize edilir. Ticari olarak mevcut dahili şarj cihazları özel ve entegre şarj sistemleri olarak sınıflandırılmaktadır. Son zamanlarda EV'lerin yüksek penetrasyonuna optimum bir çözüm olarak çeşitli tipte dahili şarj cihazları tanıtıldı. Geleneksel EV batarya şarjı, özel dahili bir şarj cihazı aracılığıyla sağlanır. Geleneksel veya özel dahili şarj cihazları, Şekil 4.15 (a)'da gösterildiği gibi batarya şarjı ve motor kontrolü için kullanılan iki dönüştürücüden oluşur. Özel dahili şarj cihazları, aracın hacmi, maliyeti ve ağırlığı dahil olmak üzere çeşitli kısıtlamalar nedeniyle sınırlı güç aktarım kapasitelerine sahiptir. Entegre dahili şarj cihazları, Şekil 4.15 (b)'de gösterildiği gibi elektrik motoru ve sürücüsü ile entegre tek bir AC-DC dönüştürücüden oluşur. Bu yapı yukarıdaki sınırlamaların üstesinden gelmek için tasarlanmıştır. Entegre şarj cihazları, hacimli bileşenlerden ve özel yapılandırmalardan kaçınarak mevcut tahrik sistemini kullanır [25, 77-79].



Şekil 4.15. Dahili şarj cihazı (a) Özel şarj cihazı mimarisi (b) Entegre şarj cihazı mimarisi

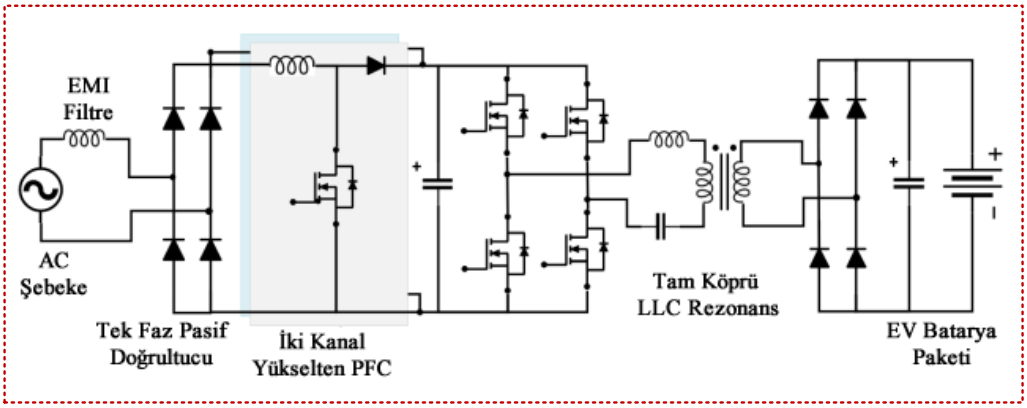
Dahili özel şarj cihazı

Geleneksel veya özel şarj cihazı olarak adlandırılan dahili şarj cihazlarının, tek görevi koşullu çıkış gücü sağlayarak bir EV bataryasını şarj etmektir. Özel şarj cihazları, küçük boyutlu, hafif bir yapıya sahiptirler. Seviye 1 ve Seviye 2 şarj standartlarında tek fazlı veya üç fazlı AC güçle çalışırlar. Güç seviyesi tek faz için 3,6 kW, üç faz için ise 22 kW seviyelerindedir. Özel bir şarj cihazı doğrudan AC duvar prizine takılarak kullanılırlar. Çalışma modu olarak Mod 1 veya Mod 2 de çalışırlar. AC-DC ve DC-DC güç dönüşümleri gibi ilgili dönüşümler dahili şarj cihazının içinde gerçekleştirilir. Modern dahili şarj cihazları, şebekedeki güç kalitesi etkilerini azaltmak için IEC 61000 standartlarına uygun olarak tasarlanırlar. Ticari EV'ler, aracın alan ve ağırlık sınırlamaları nedeniyle 22 kW'a (32A ve 400V üç faz) ile sınırlı AC şarj güç seviyelerine sahiptirler. Dahili şarj cihazlarının temel dezavantajları; şarj çıkışına bağımlılık, bataryanın voltaj sınırlamaları,

AC voltaj kontrol cihazı ile kontrol edilen DC akım ve toprak referans uyumsuzluğudur. Ayrıca, yüksek güç seviyelerinde kapsamlı güvenlik gereksinimlerinin dikkate alınması zorunluluğu ile araca eklenen bileşenler ile EV'nin boyutu ve ağırlığı artabilir. Dahili özel DC şarj cihazları (22 kW) evlerde, işyerlerinde, apartmanlarda ve alışveriş merkezlerinde kullanılmaktadır.

Ticari olarak satılan dahili şarj cihazlarının çoğu iki aşamalı güç dönüştürücü topolojilerine sahiptir. Geleneksel dahili şarj yapılandırması bir elektromanyetik girişim filtresi (EMI), AC-DC dönüştürücü ve izole edilmiş DC-DC dönüştürücü içerir. Şebeke tarafı AC-DC dönüştürücüler, harmonikleri sınırlamak ve ilk aşama olarak DC bağlantısına güç sağlamak için bir GFD devresinden ve DC-DC dönüştürücüden oluşur.

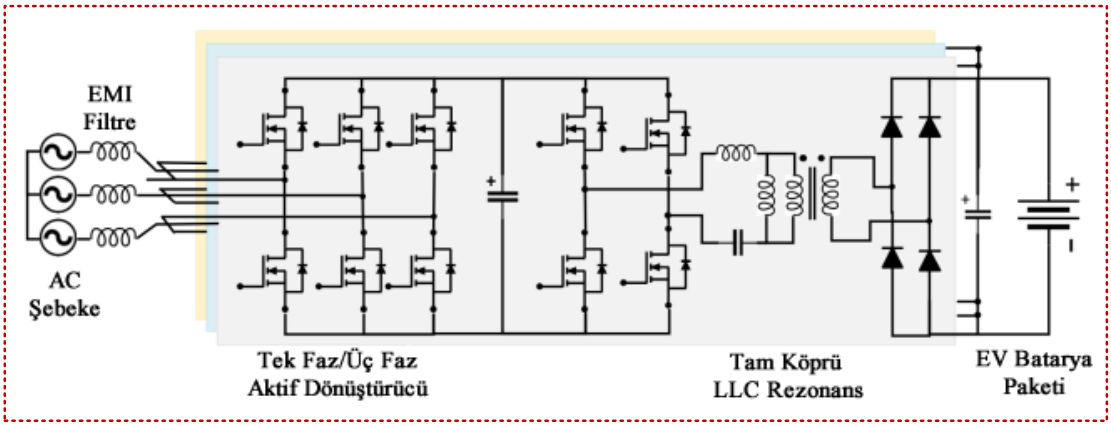
Dahili şarj cihazlarının en geleneksel yapılandırmaları, iç içe geçmiş GFD yükseltici dönüştürücü ve diyot köprü dönüştürücüsüdür. General Motors'un değerlendirmelerine göre, iç içe geçmiş topolojiler modern yerleşik şarj cihazlarının dönüşüm aşamalarında yaygın olarak kullanılmaktadır. Şekil 4.16'da ikinci nesil Volt dahili şarj cihazı gösterilmektedir [25]. Bu şarj cihazı 400 V DC bağlantı voltajını sağlamak için şebeke tarafında dört diyot köprüsü ve iki paralel iç içe geçmiş yükseltici dönüştürücüden oluşmaktadır. Batarya çıkış voltajı elde etmek için DC-DC dönüşüm aşamasında rezonans LLC tam köprü dönüştürücü, kullanılır.



Şekil 4.16. İkinci nesil Volt dahili özel şarj cihazının mimarisi

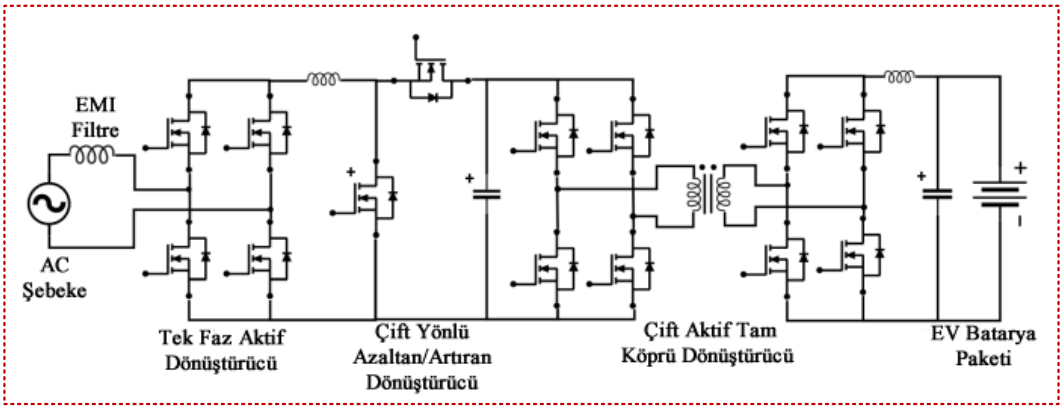
Tesla firması Model 3/Y araçlarında dahili şarj cihazında DC-DC dönüşüm aşamasında benzer bir yaklaşımı benimsemiştir. Şekil 4.17'de gösterildiği gibi şebeke tarafına üç paralel kanal entegre edilmiştir [25]. Tesla yerleşik şarj cihazlarının maksimum şarj

kapasitesi 11,5 kW'tır. Ayrıca Tesla EV batarya şarjı için 240 kW V3 süper şarj cihazlarını geliştirmiştir [80, 81].



Şekil 4.17. Tesla Model 3/Y dahili özel şarj cihazı mimarisi

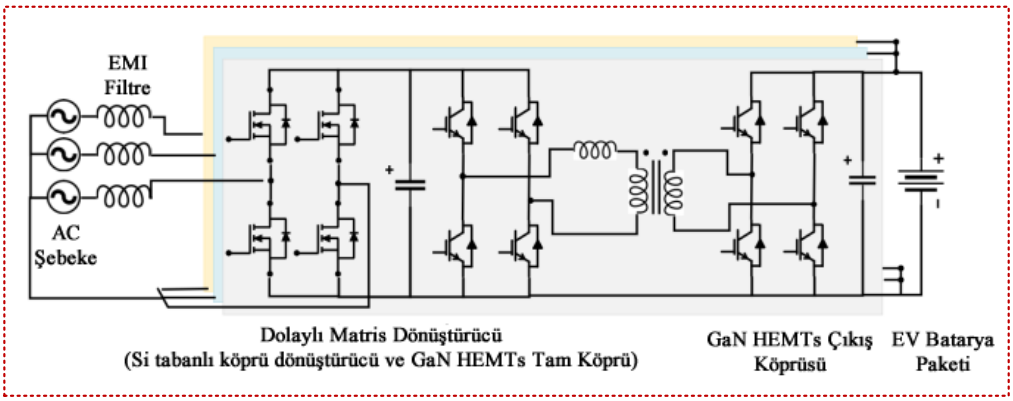
Şekil 4.18'de çift yönlü güç akışı yoluyla araçtan cihaza (V2D) uygulamalarını destekleyen Hyundai firmasının dahili özel şarj cihazının mimarisi verilmiştir [25,82]. Bu şarj cihazının şebeke tarafında tek faz aktif dönüştürücü ve çift yönlü güç akışını sağlamak için çift yönlü azaltan-artıran dönüştürücü kullanılmıştır. Bu dönüştürücünün arkasında ise çift yönlü enerji akışını kolaylaştırmak ve farklı seviyeler için uygun voltajı ayarlamak için çift aktif tam köprü dönüştürücü kullanılmıştır [82]. Köprüsüz artıran tip GFD topolojileri, dönüştürme aşamalarını ve güç kayıplarını azaltmak için pasif diyot doğrultucuların yerini alarak özel dahili şarj cihazlarında da kullanılmaktadır [83].



Şekil 4.18. Hyundai V2D destekli dahili özel şarj cihazı mimarisi

Hella Electronics firması, dönüşüm aşamalarını daha da azaltmak için matris tipi dönüştürücüleri geliştirdi. Şekil 4.19'da verilen Hella Electronics dahili şarj cihazı

mimarisindeki matris dönüştürücü, giriş şebeke frekansını ara frekansa dönüştürür ve bu mimaride batarya tarafına daha büyük bir DC filtre bağlanır. Bu dönüştürücüde tek fazda 7,2 kW çalışma için maksimum verim %98'e kadar çıkarılmıştır [25].

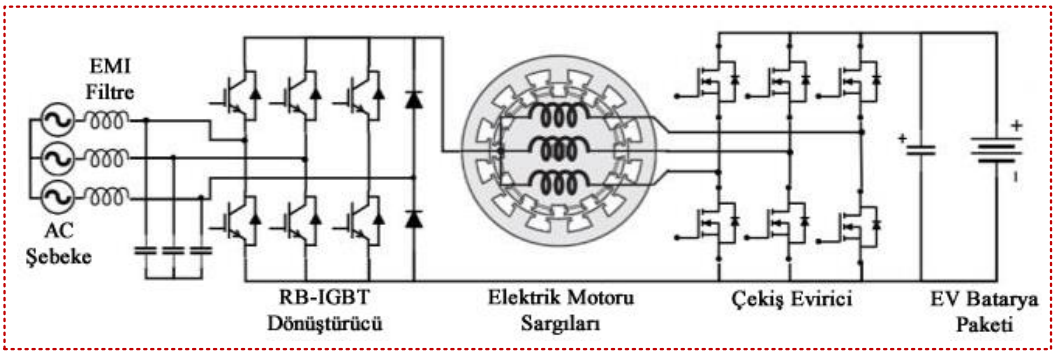


Şekil 4.19. Hella Electronic dahili özel şarj cihazı mimarisi

Dahili entegre şarj cihazı

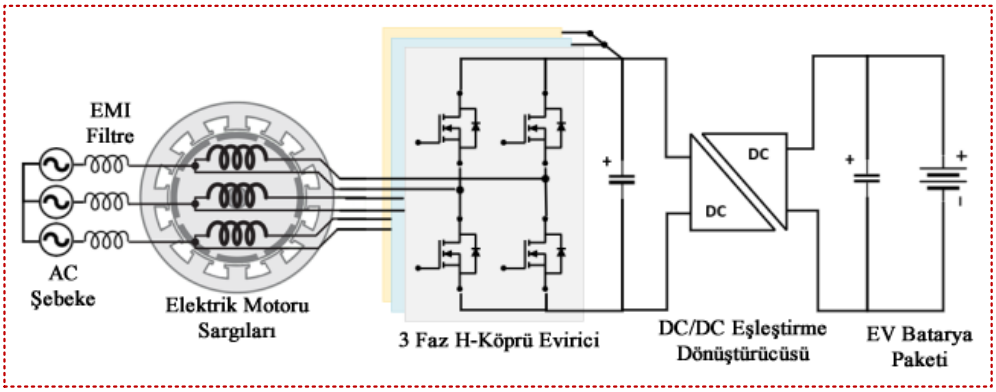
Dahili Entegre şarj cihazları geleneksel dahili şarj cihazlarının dezavantajlarını gidermek için tasarlanmıştır. Azaltılmış bileşenler, maliyet ve şarj cihazının hacmi dahili entegre şarj cihazlarının avantajları olarak sayılabilir [84]. Entegre dahili şarj cihazları geleneksel şarj cihazlarında bulunan, hacimli kapasitörler ve indüktörler yerine EV bataryasının şarjı için tahrik sistemi, elektrik motoru ve evirici kullanır. Bu nedenle dahili entegre şarj cihazları, çift yönlü güç akışı, yüksek güç seviyelerinde şarj imkanı sunar [25]. Tahrik eviricisi çift yönlü bir AC-DC dönüştürücü olarak çalışır ve motor sargısı galvanik izolasyon ve filtre iletkenliği sağlar [85,86]. Bölünmüş sargılı AC motorlar, izole edilmemiş entegre şarj cihazlarında kullanılır. Ancak, tek aşamalı entegre şarj cihazları DC tarafında akım dalgalanmalarına sahip olabilir ve voltaj dalgalanmalarını azaltmak için ek bileşenlere ihtiyaç duyabilir. Çekiş (traction) kontrolörleri şarj gücünü sınırlayabilir ve elektrik motoru entegre şarj cihazlarında şarj modunda çalışabilir. Şarj modunda motor sargı sınırlamaları ve sıfır ortalama tork gibi teknik gereksinimler mevcut olabilir [25, 85, 87]. Renault firması entegre şarj cihazı tasarımına öncülük etmektedir. Ford Motor şirketi şu anda batarya şarjını ve endüksiyon motoruna dayalı motor tahrikini birleştiren dahili entegre bir şarj cihazı kullanmaktadır [25]. Şekil 4.20'de AC tarafında tek ve üç fazlı AC şebekesi için filtreleme bileşenleri olan ters blokajlı bir IGBT doğrultucu kullanan Renault Chameleon dahili entegre şarj cihazının topolojisi verilmiştir [25, 88]. Ticari olarak kullanılan ilk

entegre şarj cihazı olan Chameleon şarj cihazları, şu anda motorda tork üretilmediği için çalışma modları arasında ek bileşenler gerektirmeyen Renault ZOE'de kullanılmaktadır [88]. Motor sargısı bir DC bağlantısı görevi görür ve çekiş evirici ile batarya paketi için gereken akımı sağlamak üzere motor ile batarya arasına bağlanır [25]. Özellikle Chameleon şarj cihazı, motor invertörünü üç ayrı artıran tip çeviriciye dönüştürmek için motorun nötr noktasını kullanmak üzere tasarlanmıştır [89].



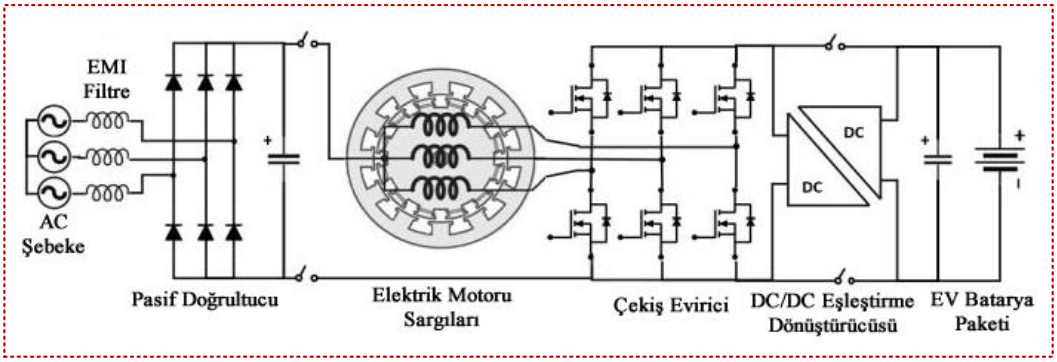
Şekil 4.20. Renault Chameleon dahili entegre şarj cihazı mimarisi

Motor sargısının konfigürasyonu veya motor arayüzüne ek şebeke bileşeni, elektrik motorunda tork üretmeden yüksek güç şarjı sağlamaya yardımcı olur [89]. Şekil 4.21'de gösterilen Valeo dahili entegre şarj cihazı, senkron motor sargılarına bağlanan üçlü bir H-köprü evirici kullanılarak geliştirilmiştir. Evirici DC hat bağlantısında yüksek voltaj sağlayabilir ve batarya voltajını ayarlamak için batarya ile invertörler arasında eşleştirici bir DC-DC dönüştürücü kullanılır [25].



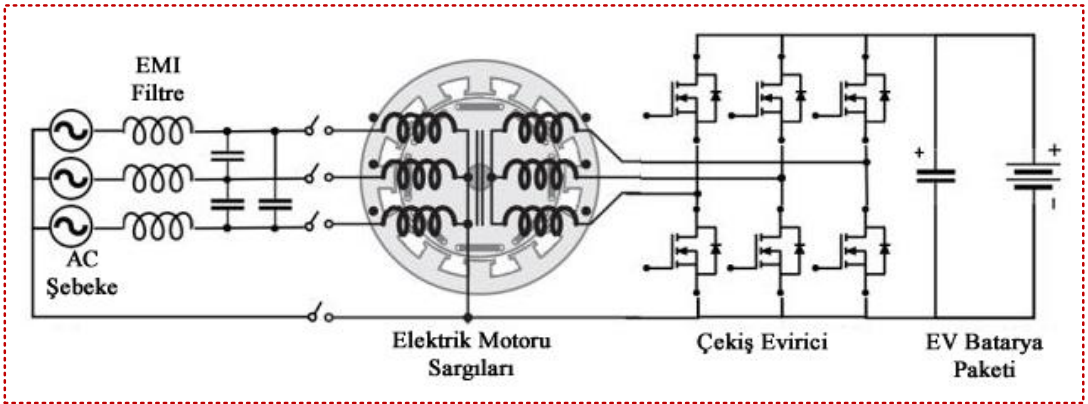
Şekil 4.21. Valeo dahili entegre şarj cihazı mimarisi

Şekil 4.22'de gösterilen Continental firmasının yüksek güçlü dahili şarj cihazlarında pasif doğrultucu ve filtre bileşenleri kullanılmaktadır [25]. Üç faz kullanılarak yüksek güç şarj oranı elde edilir. Continental dahili entegre şarj cihazlarında galvanik izolasyon ek koruma sağlamaktadır [90].



Şekil 4.22. Continental dahili entegre şarj cihazı mimarisi

Bir diğer dahili entegre şarj cihazı türü ise çekiş modunu yürütmek için çok terminalli motorlarla donatılmış ve batarya şarjı sırasında galvanik izolasyon sağlayan dahili izoleli entegre şarj cihazıdır. Şekil 4.23'de dahili izoleli entegre şarj cihazı topolojisi verilmiştir [25]. Bu şarj mimarisindeki elektrik motoru iki adet üç fazlı motor sargısına sahiptir. Stator sargıları normalde şarj konfigürasyonuna bağlı olarak üç fazlı bir set oluşturmak için seri olarak bağlanır. Bu özel şarj cihazları tek fazlı sistemler için kullanılabildiği gibi yüksek güçlü izole çift yönlü hızlı şarj olarak da çalışabilmektedir [91].



Şekil 4.23. Galvanik izoleli, çekiş eviricili dahili entegre şarj cihazı mimarisi

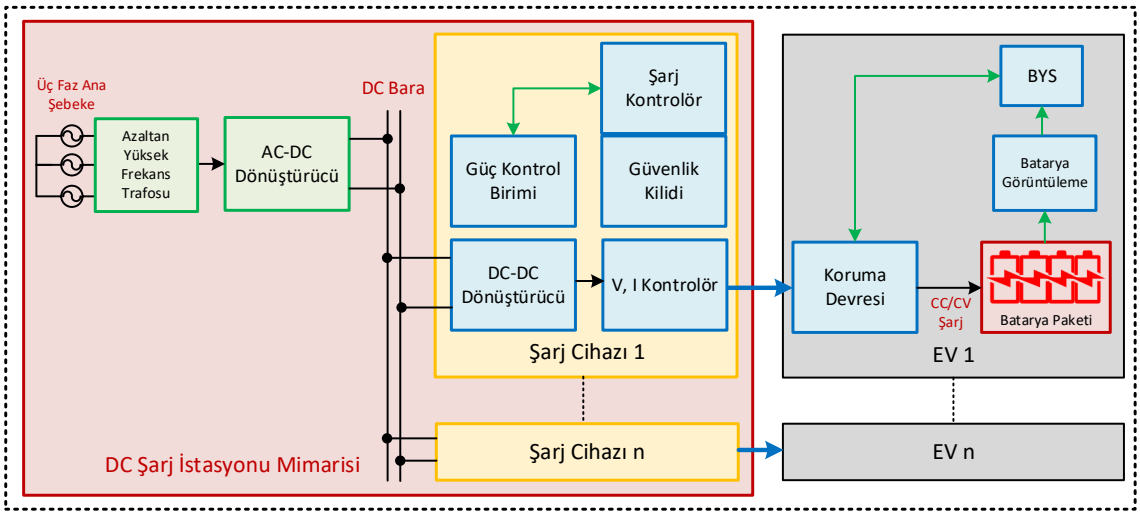
Piyasada bulunan yerleşik şarj cihazları, batarya voltajı, kapasitesi, şarj gücü, şarj süresi ve sürüş mesafesi gibi özellikleriyle birlikte Çizelge 4.3'de verilmiştir [25].

Çizelge 4.3. Piyasada dahili şarj cihazına sahip EV'lerin özellikleri

Model ve Üretici	Batarya Kapasitesi (kWh)	Şarj Gücü (kW)	Batarya Voltajı (V)	Şarj Süresi (Dakika)	Sürüş Mesafesi (km)
Model S, long range - Tesla - 2022	100	200	400	24	624
Model 3 Performance - Tesla - 2021	79.5	120	360	33	567
Bolt EUV - Chevrolet - 2022	65	50	350	66	402
Leaf SL - Nissan - 2019	62	100	360	35	346
Leaf S - Nissan - 2019	40	50	350	36	378
Ioniq 5 Long Range - Hyundai - 2022	72.6	160	800	18	412
e-208 GT - Peugeot - 2019	50	100	400	30	450
Taycan 4S - Porsche - 2022	79.2	225	800	21	407
MX-30 - Mazda - 2021	35.5	50	355	34	265
e-tron 55 Quattro - Audi - 2022	95	150	396	26	441
Q4 Sportback 55 - Audi – 2022	82	110	400	38	460
i4 M50 - BMW – 2022	83.9	210	398.5	31	510
iX xDrive50 - BMW -2022	111.5	195	330	35	630
EQS 350 - Mercedes Benz - 2022	90.56	170	500	30	626
I-Pace S AWD - Jaguar - 2020	90	100	388	43	470

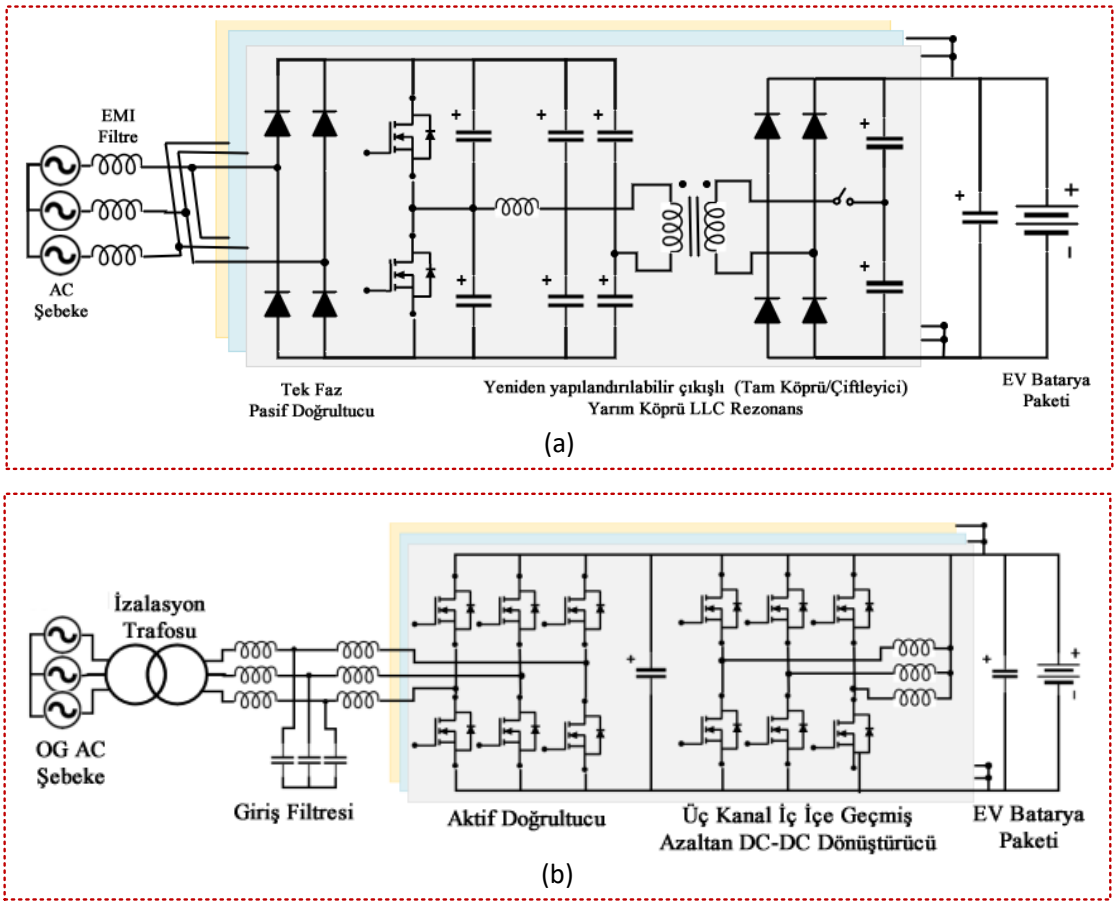
4.5.2. Harici batarya şarj cihazlarının sistem mimarileri

Harici şarj cihazları hızlı ve ultra hızlı DC şarj işlemini destekler. Harici şarj cihazının güç dönüştürme aşaması EV dışında şebeke ile EV bataryası arasında gerçekleştirilir. Harici şarj cihazları sayesinde, dahili şarj cihazları ile EV'nin artan hacim, ağırlık, boyut ve maliyet gibi unsurları önemli ölçüde azaltılır. Harici şarj cihazları AC bara veya DC bara konfigürasyonu ile birleştirilir. Çoğu hızlı ve ultra hızlı şarj mimarisinde, AC güç şebekesindeki iyi donanımlı konfigürasyonlar ve gelişmiş güç dönüştürücüler nedeniyle AC bara bağlantılı hızlı şarj istasyonları tercih edilmektedir. Şekil 4.24'de gösterildiği gibi harici şarj cihazı mimarisinde DC şarj gücünü sağlamak için AC-DC ve DC-DC dönüştürücüler kullanılmaktadır. DC baralı sistemler, AC baralı hızlı şarj sistemlerinden daha verimli ve esnektir. Ayrıca DC baraya YEK'ler bağlanarak ana şebeke tarafı desteklebilir [21, 92]. Modern harici şarj cihazları, ultra hızlı şarj için EV bataryasına 400 kW'tan fazla güç sağlayabilmektedir ve yakın gelecekte bataryaları 800 V ile şarj olan EV'lerle uyumlu hale gelecektir. Harici şarj topolojilerinde güvenlik için DC-DC dönüştürücü aşamasında galvanik izolasyon kullanılmaktadır. Galvanik izolasyonda voltaj ayarlamalarının daha iyi kontrolü ve kompaktlık sağlamak için hat frekansı transformatörü yerine yüksek frekanslı (50 kHz- 300 kHz) trafolar kullanılmaktadır [21, 93, 94].



Şekil 4.24. Geleneksel harici şarj cihazı mimarisi

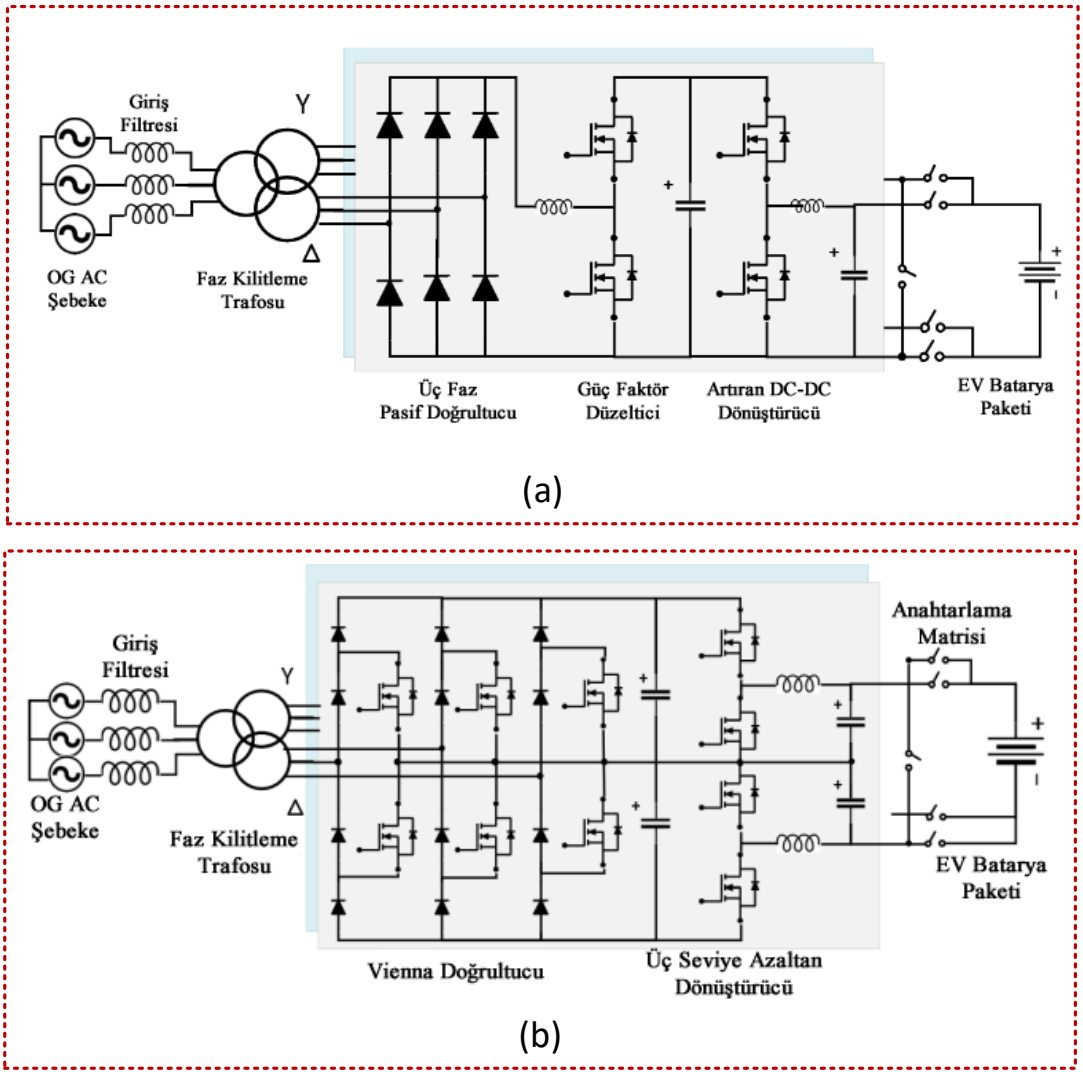
Çoğu EV üreticisi, şarj cihazlarından uyumluluk, yüksek verimlilik ve ekonomik faydalar elde etmek için şarj cihazlarını modüler hale getirerek tasarlama eğilimindedir. ABB firmasının Terra 53/54 serisi harici hızlı şarj cihazı mimarisi Şekil 4.25 (a)'da gösterilmektedir [25]. Bu mimari bir güç elektroniği yapı bloğuna dayanarak tasarlanmıştır. Güç elektroniği yapı bloğu, uygulamaların maliyetini, boyutunu, kayıplarını ve bileşenlerini azaltmak için çok sayıda topolojiyi bünyesinde barındıran yaygın olarak kabul görmüş bir kavramdır [95]. Aktif güç aşamalarının sayısı çıkış gereksinimlerine göre değişir ve yüksek güç seviyesi ile izolasyon gereksinimlerini karşılamak için izole edilmiş bir DC-DC dönüştürücü kullanılır. ABB Terra 53/54 hızlı şarj cihazının modüler sistemi, üç adet aynı tip güç elektroniği yapı bloğu kullanılarak tasarlanmıştır verimlilik %94'tür. ABB Terra HP yüksek güçlü şarj cihazı mimarisi, Şekil 4.25 (b)'de gösterilmiştir. Bu şarj mimarisi 150 kW yüksek güce ulaşmak için modüler üç adet güç elektroniği yapı bloğu kullanılarak yapılandırılmıştır. Şebeke tarafındaki harmonikleri azaltmak için bir izolasyon transformatörü ve LCL filtresi kullanılır. Yüksek güçlü ABB Terra HP harici şarj cihazı mimarisinde modüler yapılandırmada aktif bir doğrultucu ve iç içe geçmiş dönüştürücü kullanılır [25].



Şekil 4.25. Harici şarj cihazı (a) ABB Terra 53/54 50 kW hızlı şarj cihazı mimarisi (b) ABB Terra HP 150 kW yüksek güçlü şarj cihazı mimarisi

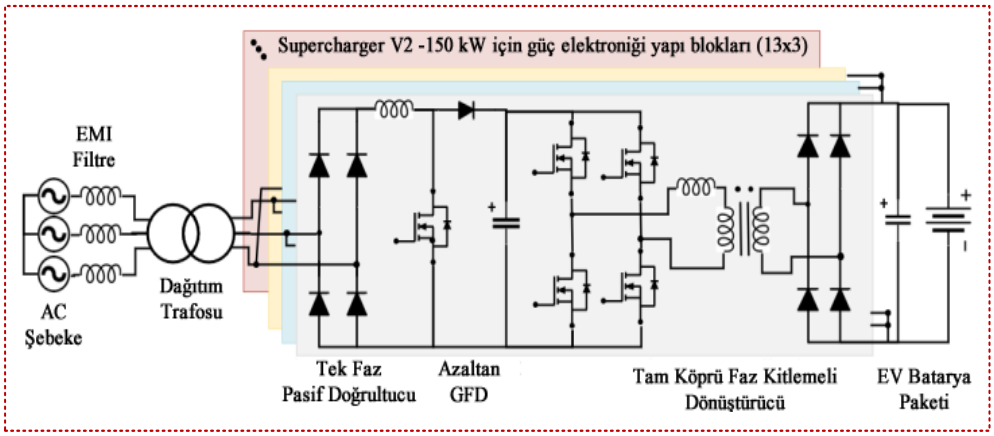
Porsche firmasının harici hızlı şarj cihazı mimarisi, modüler hızlı şarj topolojisi ile 800V şarjı desteklemektedir. Porsche Modular Park A ve Park B hızlı şarj cihazı mimarileri sırasıyla Şekil 4.26 (a) ve (b)'de verilmiştir [25]. Her iki yapılandırmada da galvanik izolasyon sağlamak ve AC şebeke tarafının güç kalitesini iyileştirmek için giriş filtresinden sonra faz kaydırma trafosu kullanılmıştır. Porsche Modular Park A hızlı şarj cihazında faz kaydırma trafosundan sonra kullanılan üç fazlı pasif doğrultucu ve yükseltici GFD dönüştürücü ile EV bataryası şarjı için gerekli olan akım ve gerilim seviyelerini ayarlamak için DC-DC azaltan dönüştürücü kullanılır. Vienna dönüştürücü ve üç seviyeli iç içe geçmiş azaltıcı dönüştürücünün birleşimi sağlanmıştır. Bu birleşim ile GFD sağlanır, akım dalgalanmaları azaltılır ve Park B hızlı şarj cihazındaki diğer yapılandırmalarla uyumlu olması için batarya şarj dönüştürücüsünde değişiklikler yapılmasını sağlar [25, 96]. DC hızlı şarj cihazları hala geliştirme aşamasındadır ve bu nedenle yüksek güç, karmaşık topraklama topolojileri ve hata türlerindeki özellikler nedeniyle standartlar ve koruma gereksinimleri iyi bir şekilde belirlenmemiştir. Ayrıca, şebeke kesintilerine karşı çok

hassas oldukları için çift yönlü hızlı şarj cihazları için koruma ve ölçüm gereksinimleri kritik öneme sahiptir. Bu nedenle harici DC şarj cihazı mimarisi kontrol ve koordinasyon yöntemleri dikkatlice seçilmelidir [25, 96, 97].



Şekil 4.26. Harici şarj cihazı (a) Porsche modüler hızlı şarj cihazı Park A mimarisi
(b) Porsche modüler hızlı şarj cihazı Park B mimarisi

Tesla süper şarj cihazları mimarisi, Şekil 4.27'de verilmiştir [25]. Bu harici şarj mimarisi %92 verimlilikle 150 kW güç sağlayabilmektedir. Bu şarj mimarisi güç elektroniği yapı bloklarının (13 x 3) bir kombinasyonu ile tasarlanmıştır [98]. Şu anda piyasada mevcut olan ultra hızlı ve hızlı şarj sistemlerinin özellikleri marka ve modele göre Çizelge 4.4'de sunulmuştur.



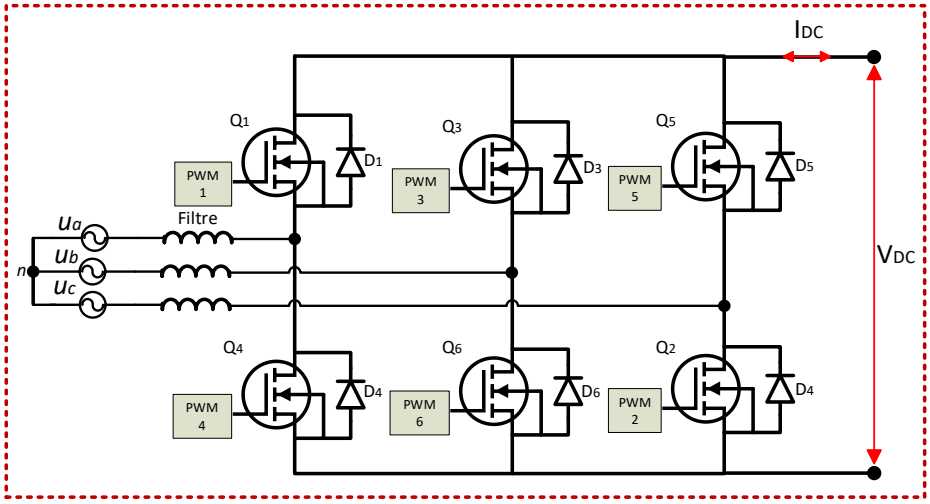
Şekil 4.27. Tesla Supercharger V2 harici şarj cihazı mimarisi

Çizelge 4.4. Marka/modele göre harici ultra hızlı ve hızlı şarj cihazlarının özellikleri

Marka ve Model	Giriş Voltajı (V_{AC})(V)	Giriş Voltajı (V_{DC})(V)	Çıkış Akımı (A)	Güç (kW)	Desteklediği Standartlar
ABB Terra 54	3 Φ 400 (± %10)	150-500	125	50	CHAdeMO, CCS1
ABB Terra High Power GEN III	3 Φ 400 (± %10)	150-920	500	350	CHAdeMO, CCS1, CSS2
Tesla Supercharger V3	3 Φ 380- 480	880-970	640	250	Superchargers
Signet FC100K-CC	1 Φ 480	150-500	200	100	CHAdeMO, SAE, Combo
Tritium PK350	3 Φ 480	200-920	200-500	350	CHAdeMO, CSS2
Blink 60kW DCFC	3 Φ 480	150-500	140	60	CCS1
Blink 180kW High Power DCFC	3 Φ 480	150-1000	240	180	CCS1
EVBox Troniq 100	3 Φ 400	50-500	200	100	CHAdeMO, CCS2
Siemens VersiCharge Ultra 175	3 Φ 480 (± %10)	200-920	200-350	178	CHAdeMO, CCS
Ingeteam - INGEREV RAOID ST400	3 Φ 380-440	50-920	500	360	CHAdeMO

4.6. Çift Yönlü Eviricilerde Kullanılan Anahtarlama Teknikleri

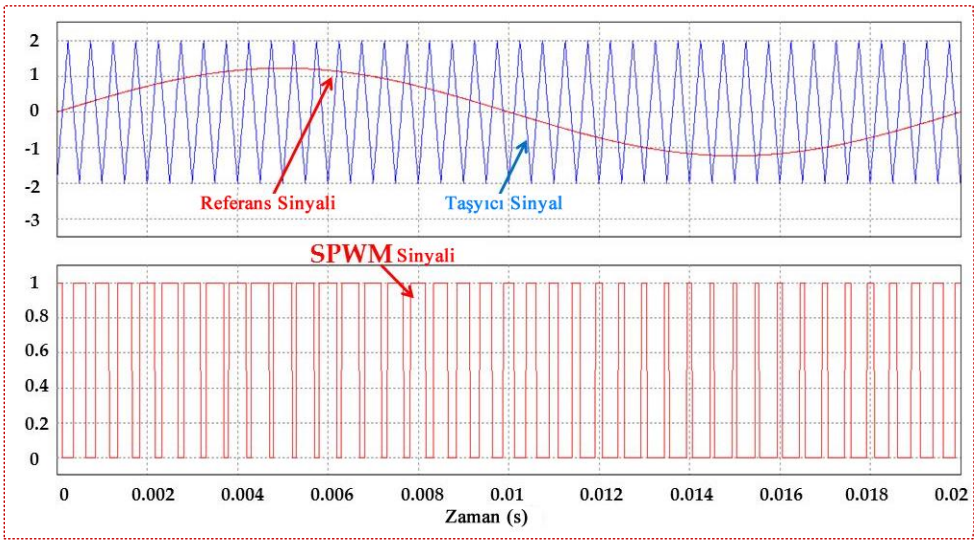
Bu tez çalışmasında çift yönlü üç fazlı yarım köprü şebeke bağlantılı eviricinin simülasyonu gerçekleştirildi. Üç fazlı şebeke bağlantılı eviricilerde anahtarlama elemanlarında kapı sinyalleri üretmek için çeşitli anahtarlama teknikleri vardır (Şekil 4.28). Darbe genişlik modülasyonu (PWM) tekniği bunların arasında en yaygın olanıdır ve endüstriyel uygulamalarda üç fazlı dönüştürücüler için PWM standart teknik haline gelmiştir. En çok kullanılan PWM teknikleri ise sinüs PWM (SPWM) ve uzay vektör PWM'dir (SVPWM) [99].



Şekil 4.28. Üç fazlı yarım köprü evirici anahtarlama elemanlarının bağlantı şeması

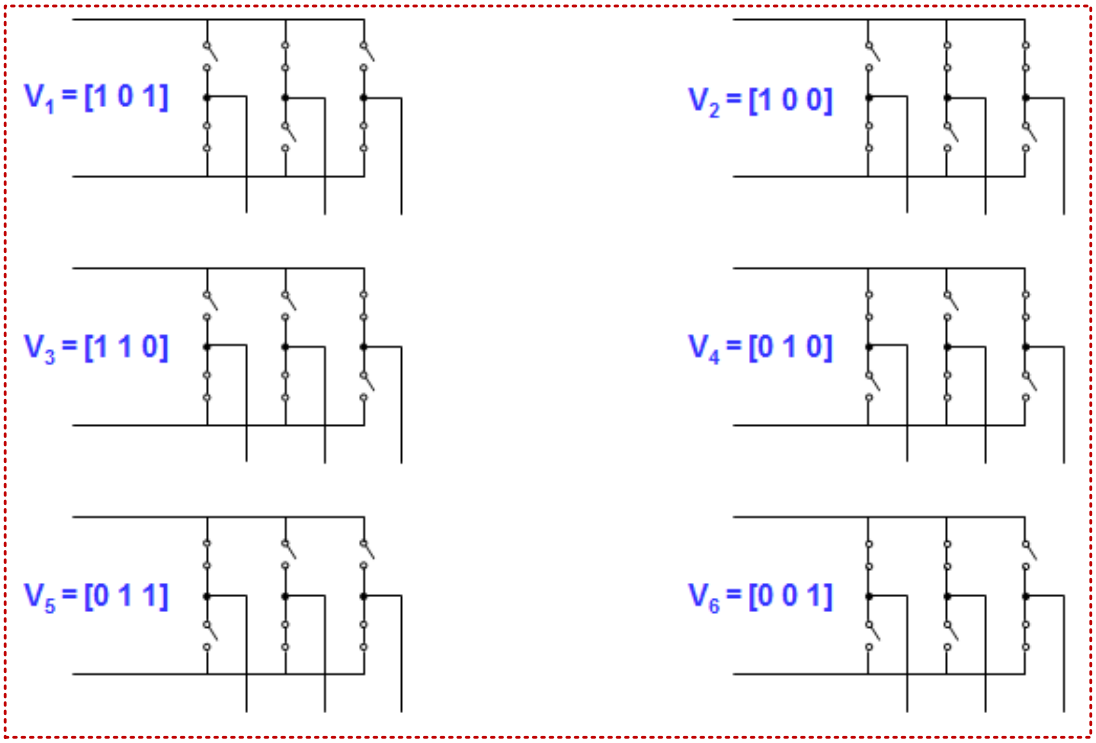
4.6.1. SPWM tekniği

SPWM modüle edilmiş iki seviyeli üç fazlı eviricide, her faz için referans olarak birbirine göre 120º kaydırılmış üç referans sinüs dalgası kullanılır. Referans sinüs dalgalarının frekansı çıkış frekansı ile aynıdır. Referans sinüs dalgalarını taşıyıcı üçgen dalga formlarıyla karşılaştırarak, her bacağın üst ve alt anahtarları için kapı sinyalleri elde edilir. Taşıyıcı sinyalin frekansı anahtarlama frekansını belirler. Üçgen taşıyıcı sinyal ve referans sinüs dalgalarından biri ile SPWM üretimine ilişkin örnek dalga formları Şekil 4.29'da verilmiştir [99-101].

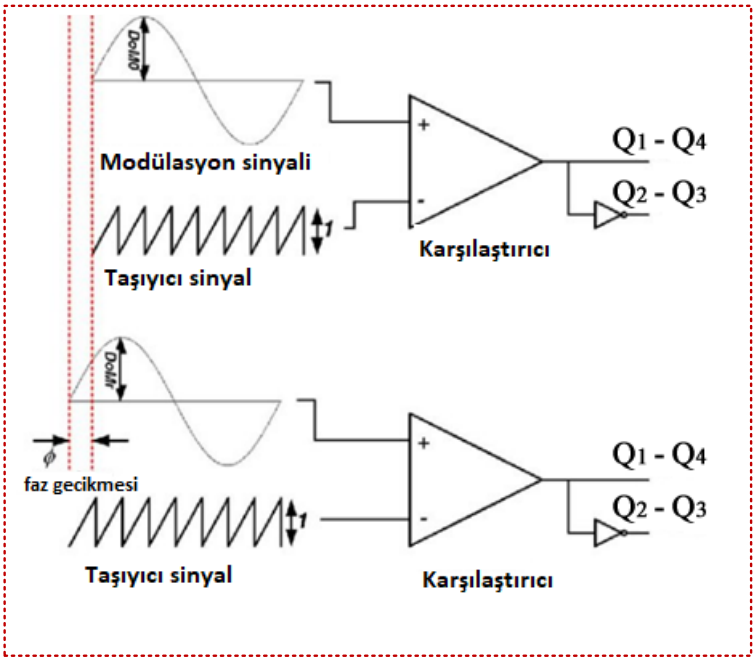


Şekil 4.29. SPWM üretimine ilişkin örnek dalga formları

SPWM tekniğinde evirici anahtarlama elemanları ilk önce iletimdedir (ON), daha sonra kesimdedir (OFF). Anahtarlama elemanlarının durumları Şekil 4.30'da verilmiştir. SPWM anahtarlama sinyalinin elde edilmesinin blok şeması ise Şekil 4.31'te verilmiştir [102].



Şekil 4.30. SPWM anahtarlama şeması



Şekil 4.31. SPWM anahtarlama sinyalinin elde edilmesine ait blok şema

SPWM sinyali genliği V_S, frekansı f_S olan modülasyon sinyali (sinüs işareti) ile genliği V_T ve frekansı f_T olan üçgen veya testere dişi taşıyıcı sinyal karşılaştırılır. Modülasyon sinyalinin genliğinin mutlak değerinin büyük olduğu noktalarda çıkış ON, taşıyıcı sinyalin anlık değerinin büyük olduğu noktalarda çıkış OFF olur. Modülasyon sinyalinin negatif alternans durumunda da davranış aynı şekildedir. Çıkıştaki sinyalin frekansı, girişteki sinüs modülasyon sinyalinin işaretinin frekansına eşittir. SPWM'de modülasyon sinyalinin genliğinin veya frekansının taşıyıcı sinyalin genliğinin veya frekansına oranına modülasyon indeksi (m_a) (Eş. 4.1) denir. m_a, 0 ile 1 arasında değişir [102].

$$m_a = \frac{V_S}{V_T} \tag{4.1}$$

SPWM tekniği ile elde edilen sinüs dalganın maksimum tepe değeri V_m Eş. 4.2 ile hesaplanır. V_m, faz voltajının temel bileşeninin tepe değeridir ve V_{DC}, DC bağlantı voltajını temsil eder [99].

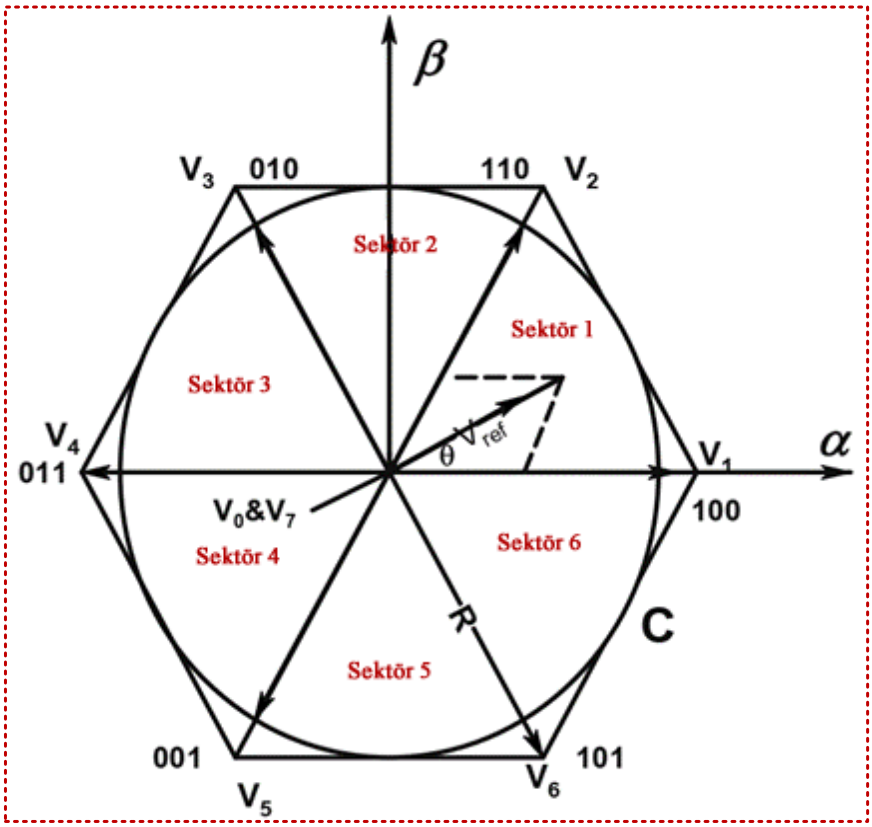
$$V_m = m_a \frac{V_{DC}}{2} \tag{4.2}$$

SPWM dönüştürücü için faz-faz geriliminin RMS değeri (V_{rms}) Eş. 4.3'deki gibi ifade edilir [99].

$$V_{rms} = m_a \frac{\sqrt{3}V_{DC}}{2\sqrt{2}} \tag{4.3}$$

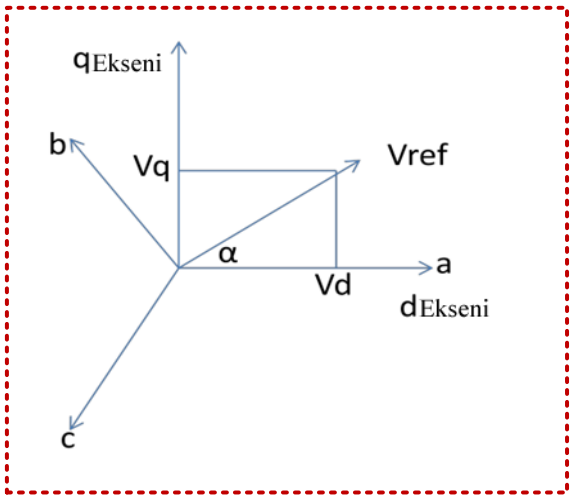
4.6.2. SVPWM tekniği

SVPWM üç fazlı eviricilerde (Şekil 4.28) kullanılan anahtarlama yöntemlerinden birisidir. SVPWM'in temel amacı 3 fazlı değişkenlerin, 2 boyutlu uzay vektör düzleminde sektör adı verilen 6 eşit alanda sekiz vektör ile ifade edilmesine dayanmaktadır (Şekil 4.32) [103].



Şekil 4.32. SVPWM anahtarlama vektörü

SVPWM'de ilk adım, clarke-park dönüşümü ile üç fazlı büyüklükler iki fazlı büyüklüklere dönüştürülür. Bu iki fazlı büyüklükler kullanılarak referans vektörü üretilir. Ayrıca d-q ekseni etrafında dönen referans vektörünün açısı belirlenir (Şekil 4.33) [104].



Şekil 4.33. Park (dq0) dönüşümü

Park dönüşümü ile elde edilen V_d, V_q ve V_0 değerleri sırasıyla Eş. 4.4, Eş. 4.5 ve Eş. 4.6'da verilmiştir.

$$V_d = \frac{2}{3}[V_a\, sin(\omega t) + V_b\, sin\left(\omega t - \frac{2\pi}{3}\right) + V_c\, sin\left(\omega t + \frac{2\pi}{3}\right)] \quad (4.4)$$

$$V_q = \frac{2}{3}[V_a \sin(\omega t) + V_b \cos\left(\omega t - \frac{2\pi}{3}\right) + V_c \cos\left(\omega t + \frac{2\pi}{3}\right)] \quad (4.5)$$

$$V_0 = \frac{1}{3}\,(V_a + V_b + V_c) \quad (4.6)$$

Üç fazlı evirici şemasında (Bkz. Şekil 4.28) Q_1, Q_3, Q_5 anahtarları üst anahtarlardır ve Q_4, Q_6, Q_2 anahtarları alt anahtarlardır. Üst anahtarlar ON olduğunda 1 ve benzer şekilde alt anahtarlar ON olduğunda ise 0 şeklinde ifade edilmektedir. Anahtar konumlarına göre faz-nötr ve faz-faz gerilimleri Çizelge 4.5'de verilmiştir.

Çizelge 4.5. SVPWM anahtar konumuna göre faz-nötr ve faz-faz gerilimleri

Gerilim Vektörü	Anahtar Durumu	Faz-Nötr Gerilimi			Faz-Faz Gerilimi		
Vi	*V* [a b c]	V_{an}	V_{bn}	V_{cn}	V_{ab}	V_{ac}	V_{bc}
V_0	[0 0 0]	0	0	0	0	0	0
V_1	[1 0 0]	$\frac{2V}{3}$	$-\frac{2V}{3}$	$-\frac{2V}{3}$	*V*	*0*	*-V*
V_2	[1 1 0]	$\frac{2V}{3}$	$\frac{2V}{3}$	$-\frac{2V}{3}$	*0*	*V*	*-V*
V_3	[0 1 0]	$-\frac{2V}{3}$	$\frac{2V}{3}$	$-\frac{2V}{3}$	*-V*	*V*	*0*
V_4	[0 1 1]	$-\frac{2V}{3}$	$\frac{2V}{3}$	$\frac{2V}{3}$	*-V*	*0*	*V*
V_5	[0 0 1]	$-\frac{2V}{3}$	$-\frac{2V}{3}$	$\frac{2V}{3}$	*0*	*-V*	*V*
V_6	[1 0 1]	$\frac{2V}{3}$	$-\frac{2V}{3}$	$\frac{2V}{3}$	*V*	*-V*	*0*
V_7	[1 1 1]	0	0	0	0	0	0

Anahtar durumlarından matris denklemi kullanılarak üç fazlı eviricinin çıkış gerilimlerine clarke ($\alpha\beta 0$) dönüşümü uygulanır (Eş. 4.7) [103].

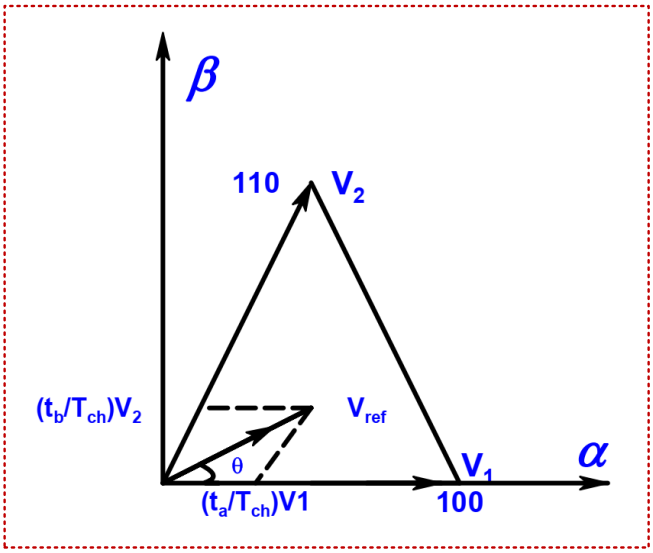
$$\begin{bmatrix} V_{\propto} \\ V_{\beta} \end{bmatrix} = \frac{V_{dc}}{3} \begin{bmatrix} 2 & -1 & -1 \\ 0 & \sqrt{3} & -\sqrt{3} \end{bmatrix} \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix} \quad (4.7)$$

Eşitlik 4.7'den sektör θ açısı ve referans gerilimi (V_{ref}) sırasıyla Eş. 4.8 ve Eş. 4.9'daki gibi elde edilir.

$$\theta = \tan^{-1} \frac{V_{\propto}}{V_{\beta}} = \frac{2\pi}{3} \quad (4.8)$$

$$V_{ref} = \sqrt{V_{\propto}^2 + V_{\beta}^2} = \frac{2V_{DC}}{3} \quad (4.9)$$

SVPWM sektörlerinde (Şekil 4.31) her anahtara bir ON/OFF zaman periyodu belirlenebilir. Örnek olarak sektör 1'i (Şekil 4.34) ele alalım [103].



Şekil 4.34. Sektör 1 vektörleri

Bu sektör, $2t_0$ süresince aktif olmayan vektörler V_0 ve V_7 uygulanırken iki aktif vektör t_a periyodu boyunca V_1 ve t_b periyodu boyunca V_2 ile tanımlanır. Bu durumda V_{ref} Eş. 4.10'daki gibi tanımlanır [103].

$$\int_0^{T_{ch}} V_{ref}\, dt = \int_0^{t_a} V_1\, dt + \int_{t_a}^{t_a+t_b} V_2\, dt + \int_{t_a+t_b}^{t_a+t_b} V_0\, dt + \int_{t_a+t_b+t_0}^{t_{ch}} V_7\, dt \quad (4.10)$$

αβ0 koordinasyonunda ve Eş 4.10'dan t_a, t_b, t_0 değerleri sırasıyla Eş. 4.11, Eş. 4.12 ve Eş. 4.13 ile bulunur.

$$t_a = T_{ch}\frac{3|V_{ref}|}{2V_{DC}} \cdot \frac{\sin(\frac{\pi}{3}-\theta)}{\sin(\frac{\pi}{3})} \tag{4.11}$$

$$t_b = T_{ch}\frac{3|V_{ref}|}{2V_{DC}} \cdot \frac{\sin(\theta)}{\sin(\frac{\pi}{3})} \tag{4.12}$$

$$t_0 = T_7 = \frac{T_{ch}-t_a-t_b}{2} \tag{4.13}$$

Sektör numarası k için yukarıdaki denklemler sırasıyla Eş. 4.14, Eş. 4.15 ve Eş. 4.16'daki gibi genelleştirilebilir.

$$t_a = T_{ch}\frac{3|V_{ref}|}{2V_{DC}} \cdot \frac{\sin(\frac{\pi}{3}k-\theta)}{\sin(\frac{\pi}{3})} \tag{4.14}$$

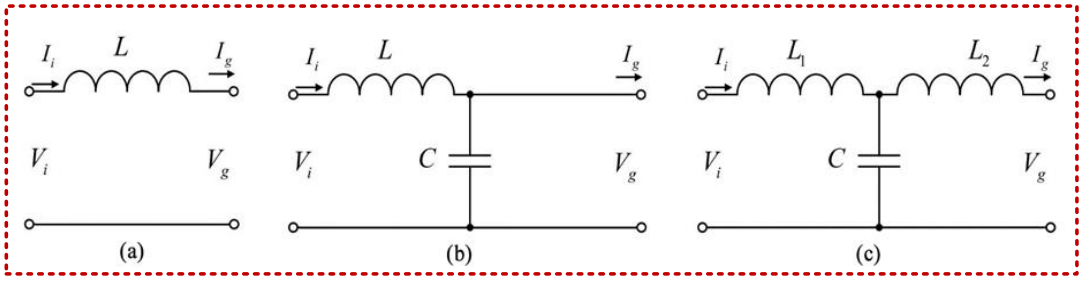
$$t_b = T_{ch}\frac{3|V_{ref}|}{2V_{DC}} \cdot \frac{\sin(\theta)}{\sin(\theta-\frac{\pi}{3}(k-1))} \tag{4.15}$$

$$t_0 = T_7 = \frac{T_{ch}-t_a-t_b}{2} \tag{4.16}$$

4.7. Evirici İçin Filtre Tasarımı

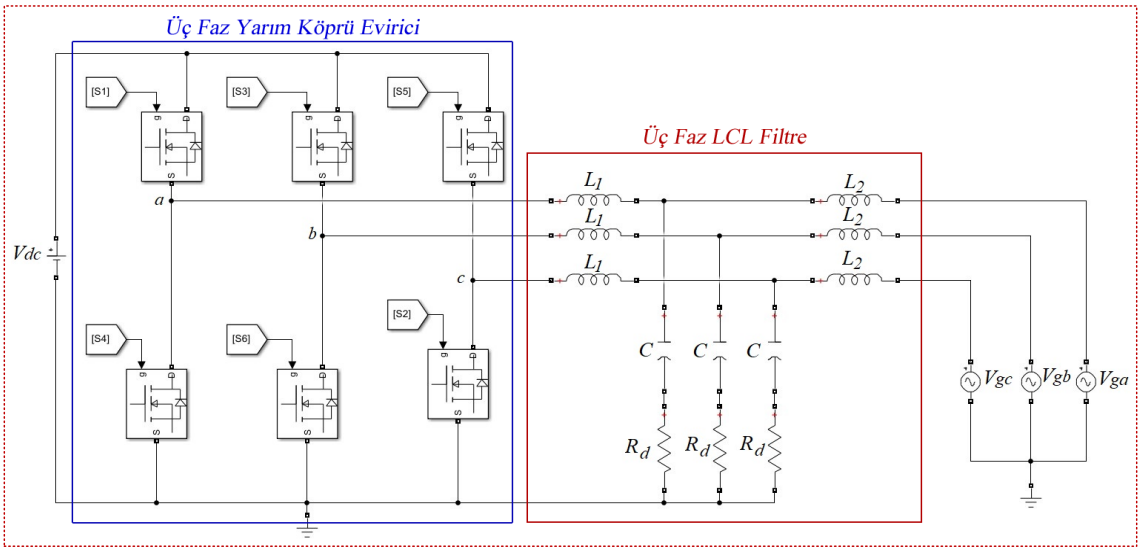
V2G topolojisinde evirici çıkışının güç kalitesi çok önemlidir. Evirici çıkışındaki gerilim tam sinüs haline getirilmelidir. Anahtarlama frekansından dolayı evirici çıkışındaki sinyal farklı seviyelerde harmonikler içermektedir. Bu nedenlerle evirici çıkışında filtre kullanımı zorunludur [105, 106]. Şebeke Bağlantılı eviricilerde L, LC ve LCL filtre türleri (Şekil 4.35) kullanılmaktadır. Şebeke bağlantılı eviricilerde en yaygın kullanılan filtre L filtredir. Akım dalgalanmasını azaltmak için yüksek endüktans değerine sahip olması gerekir. Bu nedenle L filtrenin hacmi çok büyük olmaktadır dolayısıyla maliyet de yüksek olmaktadır. L filtrenin büyük olan fiziksel yapısını küçültmek için diğer filtre türü olan LC filtre kullanılır. LC Filtrede ağ empedansının belirsizliği nedeniyle rezonans frekansı sabit değildir ve filtreleme etkisi iyi değildir. LCL filtreler, daha yüksek harmonik bastırma

oranına sahiptir. Harmonikler, belirli ölçülerde şebekeyi ve sistemde bulunan yükleri olumsuz etkilemekte hatta ciddi zararlar verebilmektedirler. THD değerinin standartlara uygun olması gerekir. Eviricilerin anahtarlama frekansı, LCL filtre kullanılarak büyük oranda azaltılmaktadır ve daha küçük bileşen boyutları sağlamaktadır. Böylece maliyet tasarrufu da sağlanmaktadır [107].



Şekil 4.35. Temel Güç Filtreleri: (a) L Filtre (b) LC Filtre (c) LCL Filtre

Bu tez çalışmasında V2G topolojisinde simülasyonu gerçekleştirilen üç fazlı şebeke bağlantılı evirici çıkışı için LCL filtre tasarımı gerçekleştirilmiştir (Şekil 4.36). LCL filtre çıkışındaki yüksek dereceli harmonikleri bastırmaktadır, fakat tasarım çok dikkatli yapılmalıdır. Yanlış tasarım değerleri filtre çıkışında distorsiyon artışına neden olabilir. Bu nedenle filtre uygun değerler ile tasarlanmalıdır [107]. LCL Filtrenin transfer fonksiyonu Eş. 4.17'de verilmiştir.



Şekil 4.36. LCL filtreli üç faz şebeke bağlantılı evirici

$$\frac{I_g(S)}{V_i(S)} = \frac{1}{(L_1L_2C)\,S^3 + (R_1L_2C + R_2L_1C)S^2 + (R_1R_2C + L_1 + L_2)S + (R_1 + R_2)} \quad (4.17)$$

LCL filtre tasarımında rezonans frekansı (f_r) şebeke frekansının (f_g) uzağında olmalıdır. LCL Filtrenin rezonans frekansı Eş. 4.18 ile hesaplanır.

$$f_r = \frac{1}{2\pi}\sqrt{\frac{L_1+L_2}{L_1L_2C}} \quad (4.18)$$

LCL filtrenin performansı seçilen rezonans frekansı, C kondansatörünün değeri ile L_1 ve L_2 bobinlerinin endüktans değerlerinden etkilenmektedir. Bu nedenle f_r seçiminde f_g ve anahtarlama frekansı (f_{sw}) kullanılarak Eş. 4.19'daki aralıkta seçilmelidir.

$$10f_g \leq f_r \leq (f_{sw}/2) \quad (4.19)$$

Reaktif güç gereksinimleri, şebeke ile etkileşime giren kapasitörün rezonansına neden olabilir. Bu nedenle, kapasitöre seri bir direnç dahil edilerek pasif veya aktif sönümleme eklenmelidir. Bu çalışmada pasif sönümleme çözümü benimsenmiştir ancak aktif çözümler de uygulanabilir [107]. Filtre kondansatörüne seri bağlı sönümleme direncinin (R_d) değeri Eş 4.20 ile hesaplanabilir.

$$R_d = \frac{1}{3w_rC} \quad (4.20)$$

Filtre tasarımını gerçekleştirilebilmesi için aşağıdaki parametreler bilinmelidir:

V_n : Evirici çıkışındaki faz faz RMS gerilim değeri
V_p : Evirici çıkışındaki faz gerilim değeri
P_n : Nominal Aktif Güç
V_{dc} : DC hat gerilimi
f_g : Şebeke frekansı
f_{sw} : Anahtarlama frekansı
f_r : Rezonans frekansı

Filtre değerleri baz değerleri kullanılarak elde edilir [107]. Baz empedansı Z_b ve baz kapasitansı C_b sırasıyla Eş. 4.21 ve Eş. 4.22'de verilmiştir.

$$Z_b = \frac{V_n^2}{P_n} \tag{4.21}$$

$$C_b = \frac{1}{w_g Z_b} \tag{4.22}$$

Filtre kapasitansının tasarımında güç düzeltme faktörü maksimum %5 olarak seçilmiştir. Bu hesaplanan değer, baz kapasitans değerinin %5'ine karşılık gelmektedir (Eş. 4.23).

$$C = 0.05 C_b \tag{4.23}$$

Evirici çıkışında akımdaki maksimum dalgalanma miktarı Eş 4.24'de verilmiştir.

$$\Delta I_{Lmak} = \frac{2V_{DC}}{3L_1}(1-m)mT_{sw} \tag{4.24}$$

Bu eşitlikte;

T_{sw} : Eviricinin anahtarlama süresi
m : Eviricinin modülasyon faktörüdür.

En yüksek tepeden tepeye akım harmoniği m = 0.5'te oluşmaktadır. Endüktans akımının maksimum dalgalanma miktarı Eş. 4.25 ile hesaplanır.

$$\Delta I_{Lmak} = \frac{V_{DC}}{6 f_{sw} L_1} \tag{4.25}$$

L_1 evirici tarafındaki endüktanstır. Maksimum nominal akım için, akımdaki %10'luk dalgalanma dikkate alınır. Maksimum nominal akım Eş. 4.26 ile hesaplanmaktadır.

$$\Delta I_{Lmak} = 0.1 I_{mak} \tag{4.26}$$

Eş. 4.26'daki I_{mak} Eş. 4.27 ile hesaplanır.

$$I_{max} = \frac{P_n \sqrt{2}}{V_p} \tag{4.27}$$

Eş 4.26 kullanılarak L_1 endüktans değeri Eş 4.28 ile hesaplanır.

$$L_1 = \frac{V_{dc}}{6 f_{sw} \Delta I_{Lmax}} \tag{4.28}$$

Her bir harmonik frekansı için dalgalanma azaltmayı hesaplamak için, LCL filtre eşdeğer devresi, bir akım kaynağı olarak analiz edilir. LCL filtre, beklenen %10 akım dalgalanmasını azaltmak için kendi değerinin %20'sini sınırlar ve çıkış akımında %2'lik bir dalgalanma ile sonuçlanır [107]. Eviricinin ve şebekenin harmonik akımı arasındaki bağıntı ve basitleştirilmiş hali Eş 4.29'da verilmiştir.

$$\frac{i_g}{i_i} = \frac{1}{\left|1+r\left|1-L_1 C_b w_{sw}^2 x\right|\right|} = k_a \tag{4.29}$$

Eşitlik 2.29'da elde edilen kazanç katsayısı k_a değeri kullanılarak şebeke tarafındaki endüktans değeri L_2, Eş 4.30 ile hesaplanır.

$$L_2 = \frac{\sqrt{\frac{1}{k_a^2}+1}}{C_f w_{sw}^2} \tag{4.30}$$

Eş. 4.29 ve Eş. 4.30'da bulunan kazanç katsayısı ka sabiti istenilen azaltma oranı olarak da ifade edilmektedir. C = 0.01 / 0.05C_b olarak gösterilir.

Şebeke ve evirici tarafındaki endüktansların birbirlerine oranı r sabiti olarak ifade edilir. L_1 ve L_2'nin r sabiti ile Eş. 4.31 deki gibi ifade edilir.

$$L_2 = rL_1 \tag{4.31}$$

5. MAKİNE ÖĞRENMESİ YÖNTEMLERİ

Günümüzde yenilenebilir enerji kaynaklarının önemli bir rolü vardır. Ancak yenilenebilir enerji kaynaklarının esnekliği şebekelerde kararsızlıklara neden olmaktadır ve önemli bir enerji depolama kapasitesi gerektirmektedir. Elektrik şebekesi ve EV arasındaki enerji akış yönü kontrol edilerek yenilenebilir enerji talebi daha iyi yönetilebilir ve şebeke kararsızlıkları dengelenebilir. EV şarj sisteminin içerisinde bulunduğu mikro şebekede, EV'lerin artan güç talebini karşılamak için, aynı sahadaki geleneksel yük talebini karşılamak için veya V2G topolojisinin işletilebilmesi için güvenilir ve verimli bir enerji akış modeli kullanılmalıdır. Bu tez çalışmasında EV'lerin şebeke entegrasyonu için V2G topolojisinde ML tabanlı yeni, gerçek zamanlı ve uygulanabilir enerji akış modeli önerilmektedir.

ML bir diğer adıyla yapay öğrenme, insanların geçmiş deneyimlerini kullanarak öğrenme şeklini modelleyen yapay zekanın alt alanıdır. ML; insan, hayvan, bitki, hava durumu gibi canlı veya cansız bir organizmaya ait bir veri setini kullanarak bilgisayar sistemlerinin matematiksel veya istatiksel algoritmalar ile karar verme süreci olarak tanımlanır. ML bilgisayar sistemlerinin açık talimatlar (komutlar) olmadan bir veri setindeki davranışsal modeli kullanarak karar verme süreci ile bir görevi yerine getirmesi olarak da tanımlanır. Bir diğer tanımda ise veriden bilgiye ulaşma süreci olarak da ifade edilir [108-111].

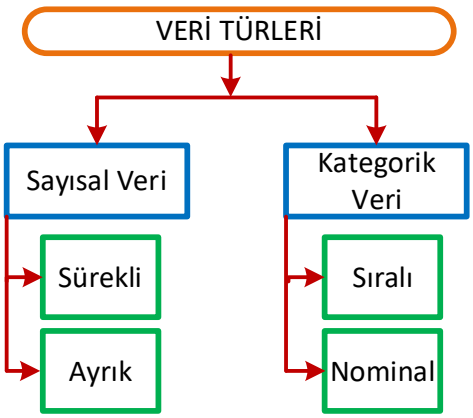
ML alanında en önemli kavram veridir. Bilgi ve iletişim teknolojilerinin hızla gelişmesiyle birlikte; web sayfaları, sosyal medya, çeşitli fiziksel büyüklükleri algılayan sensörler, ses ve görüntü kaydı yapan kameralar gibi farklı kaynaklardan büyük miktarda veri toplanmakta ve bu veriler ile veri tabanları (veri setleri) oluşturulmaktadır. Veri büyüklüğündeki artışa ek olarak, teknolojinin farklı veri türlerini birlikte işleyebilme yeteneği, veriye bakış açısını köklü bir şekilde değiştirmiştir. Artık veriler, yalnızca basit bilgi parçacıkları olmaktan öte, belirli yöntemler kullanılarak daha fazla katma değer üreten bir yapıya dönüşmüştür. Verinin bu evrimi, büyük bir dönüşüm sürecini temsil eder. Farklı formatlarda hızla güncellenen ve "Büyük Veri" olarak adlandırılan bu devasa veri yığınını karar alma süreçlerinde kullanmak, teknolojinin gelişmesine büyük fırsatlar sunmaktadır. ML, ham verinin bilgiye dönüştürülmesi sürecinde önemli roller oynamaktadır. Bu dönüşüm süreci, ham verilerde gizli olan davranışsal modelin bilgiye

dönüşmesini ifade eder. Bilgiye dönüşmeyen verinin bir değeri yoktur [108,112].

Bu bölümde sırasıyla makine öğrenmesinde veri türleri, öğrenme modeline göre makine öğrenmesi türleri, makine öğrenmesi ile uygulama geliştirme süreçleri, makine öğrenmesi sınıflandırma türleri ve sınıflandırma modellerinde performans değerlendirme ölçütleri konuları incelenmiştir.

5.1 Veri Türleri

Bir veri setinde her satır örnek, girdi sütunları öznitelik, çıktı sütunu ise hedef ya da sınıf olarak tanımlanır. Bir veri tabanındaki öznitelikler ve sınıf belirli bir düzen içerisinde bilgisayar sitemleri tarafından okunabiliyorsa etiketli veri olarak tanımlanır. Veri setindeki verileri etiketlemek çok büyük insan emeği gerektirmektedir. Özniteliklerden ya da sınıf değerlerinden herhangi birisinin bilgisayar sistemleri tarafından okunamadığı veriler ise etiketsiz veriler olarak isimlendirilir. Etiketsiz veriler insan emeği olmadan elde edilen veri türleridir. Fakat etiketsiz verilerin kullanıldığı sistemler daha karmaşık çözümler gerektirir [108,112]. Bir veri tabanındaki veri türleri Şekil 5.1'de görüldüğü gibi sayısal ve kategorik veriler olmak üzere ikiye ayrılır [112].



Şekil 5.1. Veri türleri şeması

5.1.1. Sayısal veri

Nicel veri, kantitatif veri olarak da adlandırılan sayısal veriler sürekli ve ayrık veriler olmak üzere iki gruba ayrılır. Sürekli veriler bir ölçeğe göre kesintisiz olarak artan sayısal veri türüdür. Sürekli veriler, ölçümler veya gözlemlerle elde edilen uzunluk, ağırlık, hacim

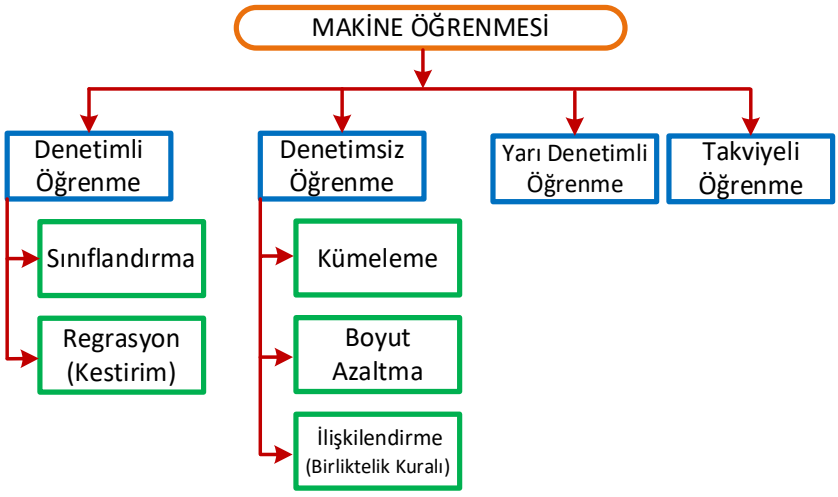
gibi değeri sonsuza giden verilerdir. Ayrık veriler ise birbirinden sayılarak ayrılan, sınırlı sayıdaki bir değeri sahip olan büyüklükleri ifade eder [112].

5.1.2. Kategorik veriler

Nitel veri, kalitatif veri olarak da adlandırılan ölçülemeyen, üzerinde matematiksel işlem yapılamayan nitel özellikleri belirten veri türüdür. Kategorik veriler sayısal olarak ifade edilemeyen, sözel olarak ifade edilebilen verilerdir. Sıralı ve nominal veri olmak üzere iki türü vardır. Sıralı veriler küçük, orta, büyük gibi kendi içerisinde bir sıraya göre ifade edilebilen etiketleri ifade eden verilerdir. Nominal veriler ise evli, bekar, dul gibi kendi içerisinde bir sıralama yapılmayan veri etiketlerini ifade eden verilerdir [112, 113].

5.2. Öğrenme Modeline Göre Makine Öğrenmesi Türleri

Makine öğrenmesi türleri öğrenme modeline göre denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve takviyeli öğrenme olmak üzere dört ana gruba ayrılmaktadır (Şekil 5.2) [108, 110, 112].



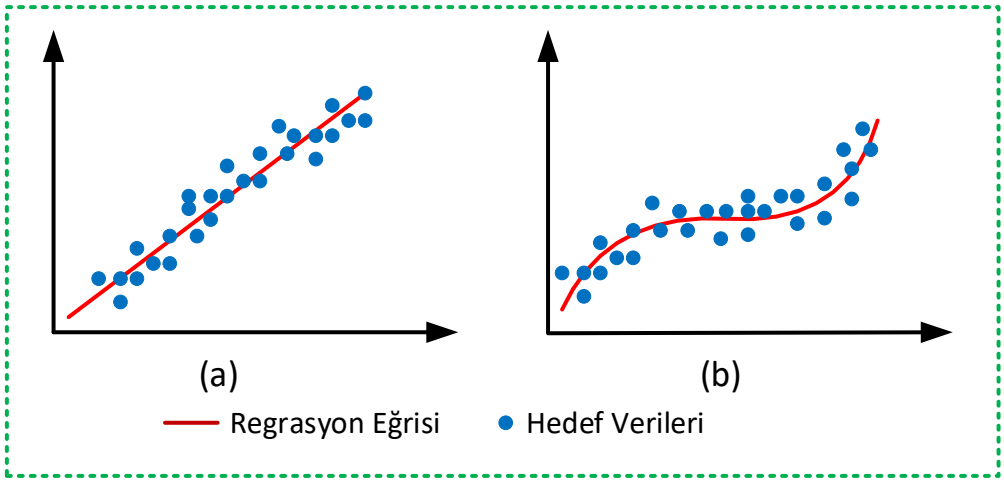
Şekil 5.2. Öğrenme modeline göre makine öğrenmesi türleri

5.2.1. Denetimli öğrenme

Etiketlenmiş veri setinin kullanıldığı ML türü denetimli öğrenme olarak isimlendirilir. Bu veri setinin bir kısmı seçilen modelin eğitim işlemi için ayrılır. Veri setinin geri kalanı ise

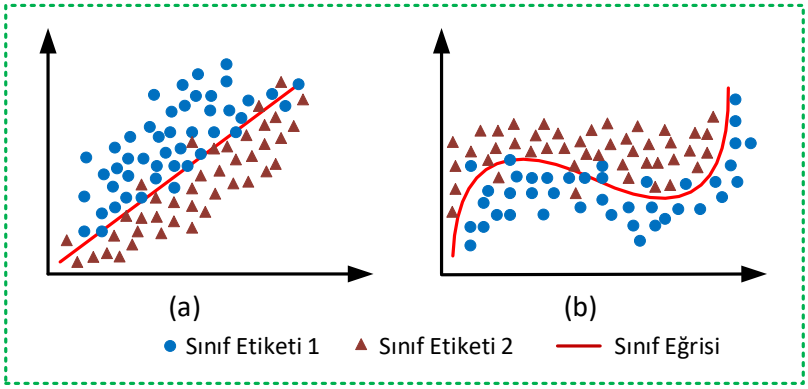
öğrenme modelinin yeni durumlarında test için ayrılır. Belirli bir kural olmamakla birlikte etiketli veri setinin uygulamada %80'i eğitim seti, %20'si ise test seti olarak ayrılması sıklıkla kullanılan bir durum haline gelmiştir [108, 109].

Denetimli öğrenme regrasyon ve sınıflandırma olmak üzere iki yönteme ayrılır. Regrasyon yönteminde veri setindeki her örneğin özniteliklerine karşılık gelen hedef değişkenin sürekli değerler almasıdır. Regrasyon yönteminde hedef değişkenin alabileceği sürekli (sayısal veri) değerin tahmin edilmesi beklenir. Regrasyon doğrusal ve doğrusal olmayan regrasyon olmak üzere ikiye ayrılır. Şekil 5.3 a'da verilen doğrusal regrasyonda öznitelikler ile hedef arasında doğrusal bir ilişki vardır. Şekil 5.3 b'de verilen doğrusal olmayan regrasyonda ise öznitelikler ile hedef arasında doğrusal olmayan bir ilişki vardır.



Şekil 5.3. Regrasyon eğrisi (a) Doğrusal regrasyon (b) Doğrusal olmayan regrasyon

Sınıflandırma yönteminde veri setindeki örnek verilerin öznitelikleri ile katagorik veri türüne sahip hedef değişkenin alabileceği değer tahmin edilir. Tahmin edilen değerler kümesinin elemanları bir sınıf etiketini temsil ettiğinden bu yöntem sınıflandırma olarak isimlendirilir. Sınıflandırma yönteminde, veri setindeki her örneğin hangi sınıfa ait olduğunun bilindiği veri setinin eğitilerek, yeni örneğin hangi sınıfa ait olduğunun tahmini gerçekleştirilir. Sınıflandırma yöntemleri, doğrusal ve doğrusal olmayan sınıflandırma şeklinde iki kategoride incelenir [109]. Şekil 5.4 a'da gösterildiği gibi aynı gruptaki veriler iki boyutlu düzlem üzerinde birbirinden doğrusal bir çizgi ile ayrılırsa doğrusal sınıflandırma olarak isimlendirilir. Şekil 5.4 b'de gösterildiği gibi aynı gruptaki veriler doğrusal olmayan bir yapıda birbirinden ayrılıyorsa doğrusal olmayan sınıflandırma olarak adlandırılır.

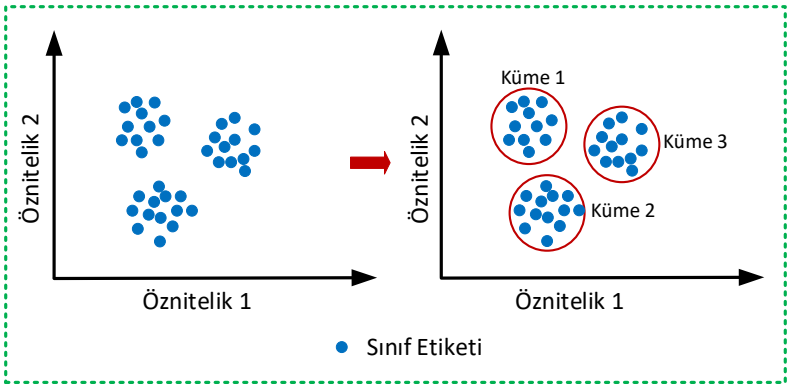


Şekil 5.4 Sınıflandırma eğrisi. (a) Doğrusal (b) Doğrusal olmayan

5.2.2. Denetimsiz öğrenme

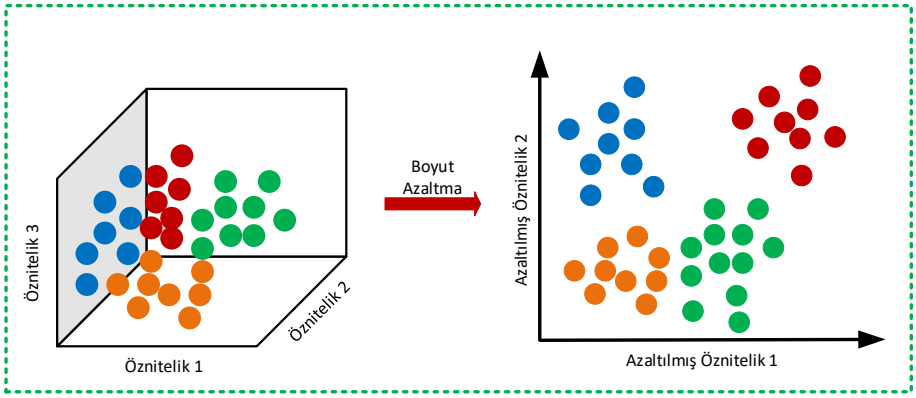
Bir veri setindeki örneklerin herhangi hedef değeri almadığı ve hedef sayısının bilinmediği durumda kullanılan öğrenme yöntemidir. Denetimsiz öğrenme yöntemi öznitelikler arasında bulunan gizli yapıdaki ilişkileri ortaya çıkarmayı amaçlayan öğrenme yöntemidir. Denetimsiz öğrenme kümeleme, boyut azaltma ve birliktelik kuralı olmak üzere üç kategoride incelenmektedir [108,109,112].

Literatürde en çok kullanılan denetimsiz öğrenme yöntemi, birbirine benzeyen örneklerin bir araya getirilerek gruplandırılmasını sağlayan kümeleme yöntemidir (Şekil 5.5). Kümeleme yöntemlerinde mesafeye dayalı teknikler, her bir kümenin merkez noktasını bulmaya dayalı teknikler ve dağılıma dayanan istatiksel teknikler kullanılır [109, 112]. Bir veri seti örnekleri arasındaki mesafeye dayalı benzerlik bulunmasında Öklid, Manhattan, Minkowski gibi mesafe metrikleri kullanılır [109].



Şekil 5.5. Kümeleme yöntemi ile veri setinin gruplandırılması

Denetimsiz öğrenme yöntemlerinden biri de boyut azaltma yöntemidir. Veri setleri, çok sayıda öznitelik içerebilir, bu da vektörler ve matrisler gibi yüksek hesaplama gücü gerektiren işlemleri daha karmaşık hale getirir. Bu durum, performansta belirgin düşüşlere yol açabilir. Ayrıca, birçok özniteliğe sahip veri setlerinde, öznitelikler arasında yüksek korelasyon bulunması da olasıdır, bu da modelin etkinliğini olumsuz etkileyebilir. Boyut azaltma işlemi, veri setindeki faydalı bilgileri koruyarak, veriyi daha düşük boyutlu bir uzaya dönüştürmeyi sağlar ve bu sayede hem hesaplama maliyetlerini azaltır hem de model performansını artırır (Şekil 5.6) [112].



Şekil 5.6. Bir veri setinde öznitelikler için boyut azaltma

Denetimsiz öğrenme yöntemlerinden bir diğeri de ilişkilendirme yöntemidir. İlişkilendirme, büyük veri setlerinde oluşturulan öğe kümeleri arasındaki ilişkileri keşfetmeye yönelik kural tabanlı bir ML yaklaşımıdır. Bu yöntem, veri tabanlarında güçlü ve anlamlı kuralların keşfedilmesini amaçlar, böylece veriler arasında gizli kalmış ilişkiler ortaya çıkarılabilir. İlişkilendirme analizinde kullanılan ölçütler, belirli öğelerin veya olayların birlikte ortaya çıkma olasılıklarını hesaplayarak, bu öğeler arasındaki ilişkileri tanımlar. İlişkilendirme yöntemi, özellikle pazar sepeti analizi gibi ticari uygulamalarda yaygın olarak kullanılır. Örneğin, bir perakende mağazasında müşterilerin sıklıkla birlikte satın aldığı ürünler arasındaki ilişkileri belirlemek için bu yöntem uygulanabilir. Bu sayede, market yöneticileri, hangi ürünlerin yan yana yerleştirilmesi gerektiği, hangi ürünlerin bir arada tanıtılması gerektiği veya çapraz satış stratejilerinin nasıl geliştirilmesi gerektiği gibi konularda daha bilinçli kararlar alabilirler. İlişkilendirme analizi, sadece ticaret alanında değil, tıbbi araştırmalar, biyoinformatik, sosyal ağ analizi ve güvenlik gibi çeşitli alanlarda da kullanılmaktadır. Örneğin, tıbbi araştırmalarda, hastalıklar ve semptomlar arasındaki ilişkileri keşfetmek için kullanılabilirken, sosyal ağ analizinde,

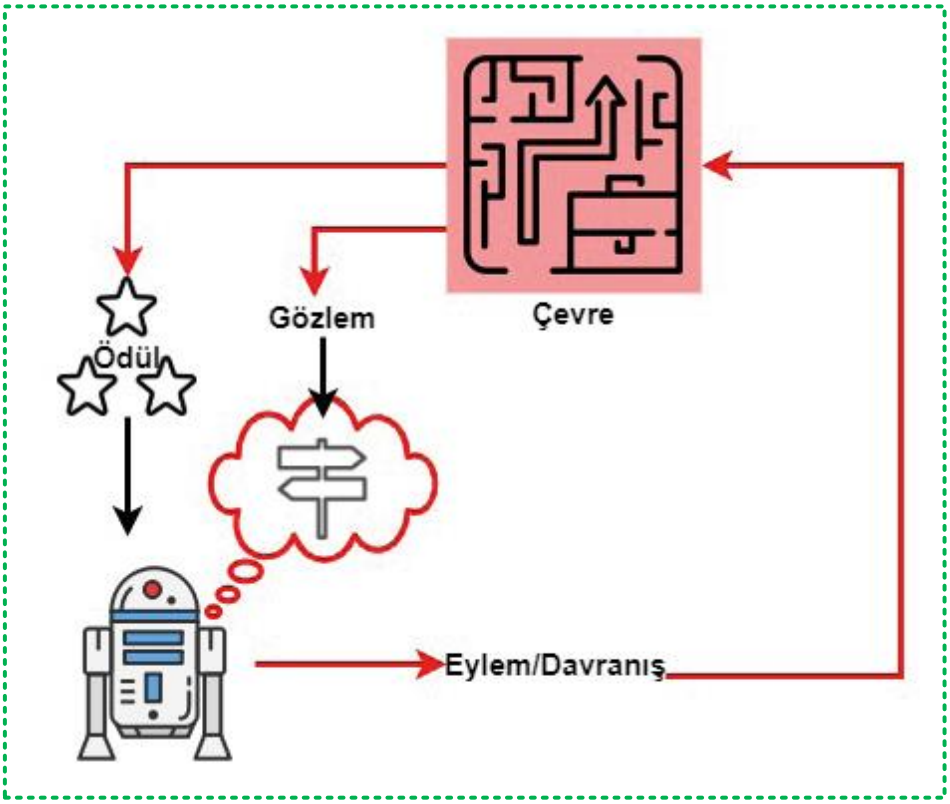
kullanıcılar arasındaki etkileşimleri anlamak için kullanılabilir. Güvenlik alanında ise, dolandırıcılık tespitinde veya siber saldırıların izlenmesinde bu yöntemden yararlanılabilir. Sonuç olarak, ilişkilendirme yöntemi, veri setlerindeki gizli kalmış ilişkileri ortaya çıkarmak için güçlü bir araçtır ve çok çeşitli uygulama alanlarında değerli içgörüler sunar. Bu yöntemin etkin kullanımı, sadece veri bilimi uzmanlarına değil, aynı zamanda iş stratejilerini ve operasyonel süreçleri optimize etmek isteyen profesyonellere de önemli avantajlar sağlar [108, 114, 115].

5.2.3. Yarı denetimli öğrenme

Yarı denetimli öğrenme, veri setinde hem etiketli hem de etiketsiz örneklerin bulunduğu bir öğrenme yöntemidir. Bu yaklaşımda, genellikle etiketsiz örneklerin sayısı etiketli örneklerden çok daha fazladır. Yarı denetimli öğrenmenin temel amacı, denetimli öğrenme yöntemi ile aynı olup, verinin yapısını daha iyi öğrenerek daha güçlü ve genelleştirilebilir bir model oluşturmaktır. Yarı denetimli öğrenmede, etiketsiz örneklerin kullanımı, ilk bakışta öğrenme sürecine belirsizlik ekliyormuş gibi görünebilir. Aslında bu örnekler, modelin genel veri dağılımını daha iyi anlamasına ve böylece daha doğru tahminler yapmasına yardımcı olur. Etiketsiz veriler, özellikle veri setinin yapısını ve temel örüntülerini öğrenmede kritik bir rol oynar, çünkü bu tür veriler modelin genel eğilimleri kavramasına olanak tanır. Etiketlenmemiş örneklerin eklenmesi, veri setinin olasılık dağılımını daha doğru bir şekilde yansıtmasına yardımcı olur. Bu ek bilgi, öğrenme algoritmasına rehberlik eder ve modeli daha sağlam hale getirir. Teorik olarak, yarı denetimli bir öğrenme algoritması, etiketsiz örneklerin öznitelikleri arasında gizli yapıdaki ilişkileri ortaya çıkarıp öğrenme sürecine dahil ederek öğrenme algoritmasının performansını artırmaktadır. Yarı denetimli öğrenme, özellikle büyük miktarda etiketsiz verinin mevcut olduğu ancak etiketlemenin zaman alıcı, maliyetli veya zor olduğu durumlarda avantajlıdır. Bu yöntem, tıbbi uygulamalar, görüntü tanıma, doğal dil işleme, biyoinformatik ve sosyal ağ analizi gibi geniş bir uygulama yelpazesinde kullanılabilir. Örneğin tıbbi görüntülemede, sadece birkaç etiketli görüntü üzerinden tüm veri kümesinin yapısını öğrenmek, modelin daha genel ve hassas sonuçlar üretmesine olanak tanır. Sonuç olarak, yarı denetimli öğrenme hem etiketli hem de etiketsiz verilerin gücünden yararlanarak, öğrenme süreçlerini optimize eder ve daha az etiketli veri ile yüksek performanslı modellerin geliştirilmesini sağlar. Bu yaklaşım, özellikle veri etiketlemenin zor veya maliyetli olduğu alanlarda büyük bir potansiyele sahiptir [113, 116, 117].

5.2.4. Takviyeli öğrenme

Takviyeli öğrenme, diğer adıyla pekiştirmeli öğrenme, bir sistemin çevresiyle etkileşimlerinden öğrenerek performansını artırmayı amaçladığı bir ML yöntemidir. Bu öğrenme süreci, ödül-ceza mekanizmasına dayalıdır. Takviyeli öğrenme algoritmaları, sistemin doğru kararlar aldığında ödüllendirilmesi ve yanlış kararlar aldığında ise cezalandırılması prensibi üzerine kuruludur. Amaç, bir ortamdaki en yüksek ödülü toplamak için gerekli stratejileri deneme-yanılma yoluyla öğrenmektir. Bu yaklaşım, sistemin çevresini gözlemleyerek ve farklı eylemleri deneyerek, uzun vadede en iyi sonuçları elde edecek davranışları belirlemesini sağlar. Örneğin, Şekil 5.7'de bir robotun bir labirentten çıkışı bulması durumunda, doğru yolda ilerlediğinde ödül alır ve bu ödüller, robotun çevreyi daha iyi anlamasını ve gelecekteki hareketlerini optimize etmesini sağlar [110]. Takviyeli öğrenmenin en belirgin özelliği, süreç boyunca herhangi bir gözetmenin veya sonuç etiketlerinin olmamasıdır. Bu yönüyle denetimli öğrenmeden ayrılır; çünkü model, dışarıdan verilen doğru-yanlış bilgiler yerine, kendi deneyimlerinden öğrenir. Takviyeli öğrenme, özellikle etiketli verinin az olduğu veya ortam hakkında yeterli bilginin bulunmadığı durumlarda etkili bir yöntemdir. Bu nedenle, robotik, oyunlar, kişisel öneri sistemleri gibi alanlarda yaygın olarak kullanılmaktadır. Örneğin, bir video oyununda bir yapay zekâ oyuncusunun, oyun ortamındaki ödülleri maksimize etmek için farklı stratejiler geliştirmesi ve bu stratejileri sürekli olarak iyileştirmesi, takviyeli öğrenme yönteminin bir uygulamasıdır. Robotik alanda ise, bir robotun çevresindeki engelleri aşarak hedefe ulaşması veya belirli görevleri yerine getirmesi takviyeli öğrenme ile sağlanabilir. Kişisel öneri sistemlerinde de kullanıcının geçmiş davranışlarına dayalı olarak kişiselleştirilmiş öneriler sunmak için bu öğrenme yöntemi kullanılabilir. Örneğin, bir film öneri sisteminde, kullanıcının izlediği ve beğendiği filmler üzerinden algoritma, kullanıcıya en uygun diğer filmleri önerir. Sonuç olarak, takviyeli öğrenme, ödül-ceza mekanizmasıyla bir sistemin çevresinden öğrenmesini sağlayan güçlü bir yöntemdir. Bu yöntem, özellikle karmaşık ve dinamik ortamlarda, sistemlerin bağımsız olarak öğrenmesi ve adapte olmasını mümkün kılar. Takviyeli öğrenme, gelecekte otonom sistemlerin geliştirilmesi ve yapay zekâ alanındaki ilerlemelerde önemli bir rol oynamaya devam edecektir [110, 112].



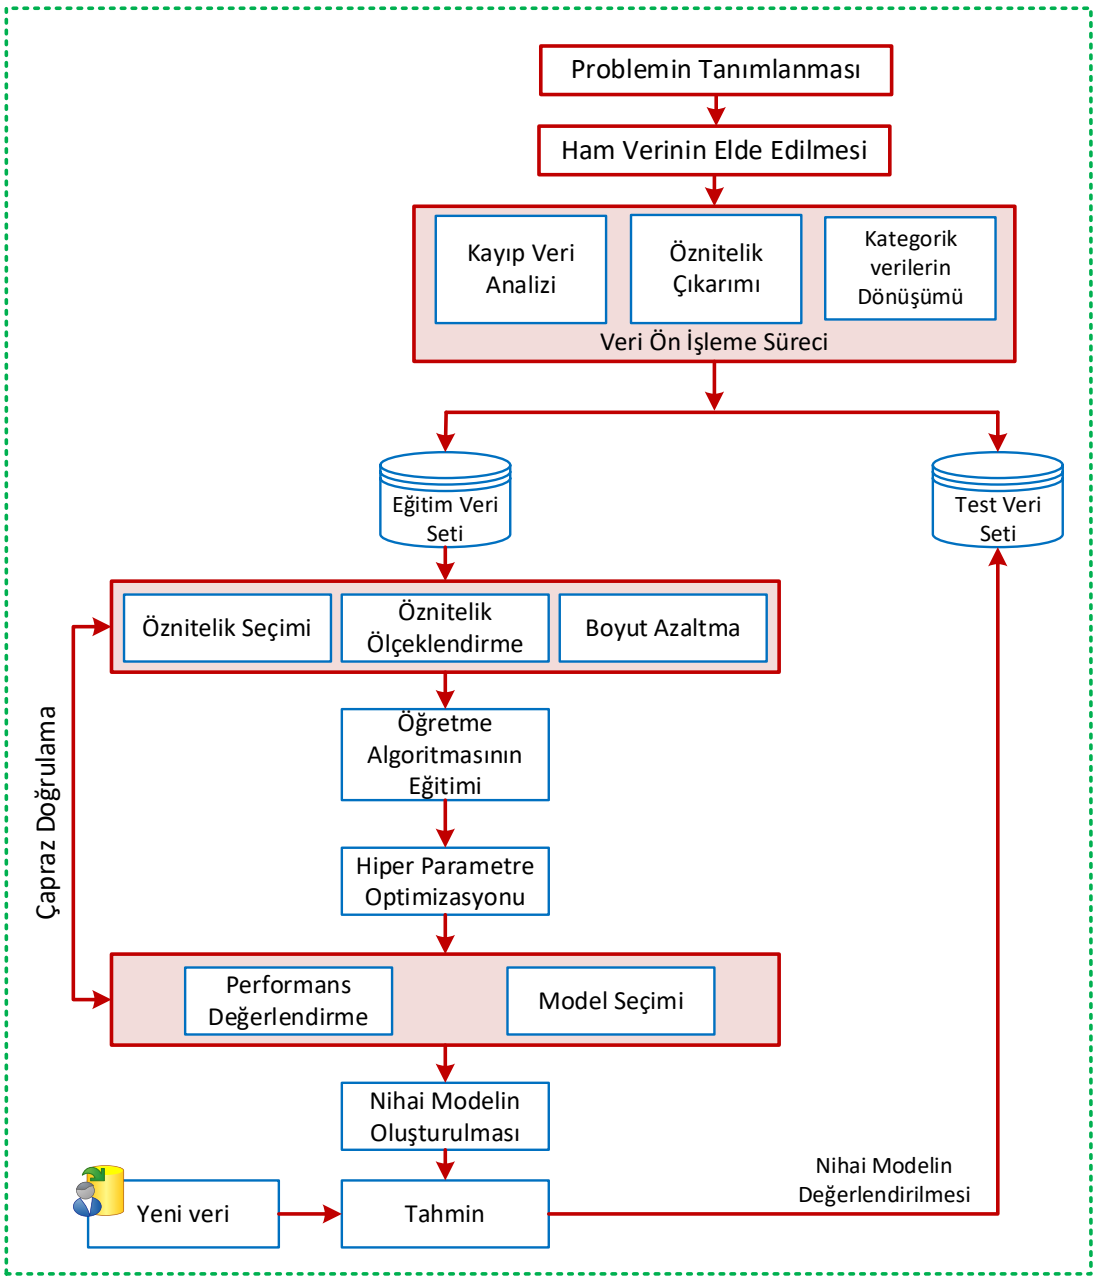
Şekil 5.7. Takviyeli öğrenme süreci örneği

5.3. Makine Öğrenmesi İle Uygulama Geliştirme Süreçleri

Denetimli öğrenme çeşitleri sınıflandırma veya regresyon uygulamaları geliştirmek için takip edilmesi gereken iş akışı, Şekil 5.8'de özetlenmiştir [112]. Bu tez çalışmasında EV'lerin V2G topolojisinde şebeke entegrasyonu sınıflandırma uygulaması olarak geliştirilmiştir.

5.3.1. Problemin tanımlanması

ML ile uygulama geliştirme sürecinin ilk adımında problemin tanımının yapılması gerekir. Problemin tanımının yapılması sistemde hangi parametrelerin kullanılacağının belirlenmesini sağlar. Belirlenen parametrelere göre veri toplama sistemi hazırlanır [109].



Şekil 5.8. Makine öğrenmesi ile uygulama geliştirme süreçleri

5.3.2. Ham verinin elde edilmesi

ML'nin temel amacı, bir karar destek siteminde belirli davranışlara ait tahminleri yüksek bir doğrulukla tahmin etmektir. ML algoritmalarının başarılı ve güvenilir tahmin modelleri üretebilmesi için, yüksek kaliteli verilere ihtiyaç vardır. Bu nedenle, ML sürecinin ilk adımı ham verinin toplanmasıdır. Verinin güvenirliği, sahip olduğu hacim kadar, modelin doğruluğu ve değer üretme süreci için de hayati önem taşır. Veri, ML tabanlı sistemlerin temel kaynağıdır. ML algoritmalarına ne kadar fazla ve kaliteli veri sağlanırsa, o kadar

yüksek performanslı ve genelleştirilebilir bir model oluşturmak mümkündür. Oluşturulan bu model, incelenen davranışları daha iyi tahmin edebilir ve karar destek sistemleri için daha güvenilir sonuçlar sunar. Bununla birlikte, verinin hem hacim hem de kalite açısından yetersiz olması durumunda, elde edilen tahminler doğru olsa bile modelin güvenilirliği konusunda soru işaretleri oluşabilir. Verinin eksikliği veya kalitesizliği, modelin önyargılı veya hatalı sonuçlar üretmesine neden olabilir. Dolayısıyla, ML sistemlerinin başarısı, doğrudan doğruya kullanılan verinin niteliği ile ilişkilidir. Sonuç olarak, ML süreçlerinde verilerin toplanması ve bu verilerin kalitesinin sağlanması, başarılı bir model geliştirmek için kritik öneme sahiptir. ML algoritmalarının performansı, eğitildikleri veri setlerinin kalitesiyle sınırlıdır; bu nedenle, doğru, güvenilir ve yeterli miktarda veri toplamak, yüksek performanslı ve güvenilir ML modelleri oluşturmanın ilk ve en önemli adımıdır [108, 112].

5.3.3. Veri ön işleme süreci

Veri ön işleme sürecinde kayıp verilerin analizi, öznitelik çıkarma ve kategorik verilerin dönüşümü adımları gerçekleştirilir. ML sürecinde, veri setleri genellikle eksik veya kayıp değerler içerebilir. Bu kayıp veriler, insan kaynaklı eksik veri girişi, veriye erişim zorlukları veya bir sensörden alınan verinin zamanında kaydedilememesi gibi çeşitli nedenlerden kaynaklanabilir. Veri setinde kayıp değerler bulunması, modelin performansını olumsuz etkileyebilir ve bu nedenle bu durumun dikkatlice ele alınması gereklidir. Kayıp verileri göz ardı etmek, yanlış veya eksik sonuçlar üretebileceğinden, bu yaklaşım genellikle doğru bir seçenek olarak görülmez. Kayıp verilerin bulunduğu örnekleri tamamen veri setinden çıkarmak mümkündür. Ancak, ML uygulamalarında daha fazla örnek ile çalışmak, genellikle modelin performansını artırır. Bu nedenle, örneklerin silinmesi, özellikle veri seti küçükse veya kayıp verilerin oranı yüksekse önerilen bir çözüm değildir. Yine de kayıp veri sayısı çok az ise ve bu eksiklik modelin genel performansını etkilemeyecekse, bu örneklerin veri setinden çıkarılması uygun bir çözüm olarak düşünülebilir. Kayıp veri analizi, ML süreçlerinde veri ön işleme adımının kritik bir parçasıdır. Kayıp verileri işlemek için çeşitli stratejiler uygulanabilir. Bu stratejilerden biri, eksik verilerin yerine istatistiksel merkezi eğilim ölçütleri kullanmaktır. Örneğin, aritmetik ortalama, mod veya medyan gibi değerler kayıp veri hücresine yazılabilir. Eğer aritmetik ortalama tercih edilirse, bu yaklaşımda kayıp verinin bulunduğu öznitelik veya örneğin ortalaması hesaplanır ve bu değer kayıp veri hücresine yerleştirilir. Bu işlem, terminolojide yaklaşık değer verme olarak adlandırılır. Yaklaşık değer verme, veri setinin tamamını

koruyarak, modelin eğitilmesi sırasında daha fazla bilgi kullanmasına olanak tanır. Ancak, bu yöntem her zaman en iyi çözüm olmayabilir; çünkü bazı durumlarda, kayıp verilerin tahmin edilmesi modelin önyargılı sonuçlar üretmesine neden olabilir. Bu nedenle, kayıp veri analizi yaparken, kullanılan stratejinin veri setinin yapısına ve modelin amacına uygun olması önemlidir. ML süreçlerinde kayıp veri analizi, modelin doğruluğunu ve genelleştirilebilirliğini artırmak için dikkatle yürütülmesi gereken bir adımdır. Doğru stratejiler kullanılarak kayıp verilerin işlenmesi, modelin performansını iyileştirebilir ve daha güvenilir tahminler elde edilmesini sağlayabilir.

Veri ön işleme sürecinde diğer bir adım öznitelik çıkarma adımıdır. ML sürecinde, veri setleri genellikle çeşitli kaynaklardan elde edilen ham verilerden oluşur. Ancak, bu veri setlerinde yer alan tüm öznitelikler, modelin performansı açısından anlamlı veya faydalı olmayabilir. Bu nedenle, ML'nin önemli adımlarından biri olan öznitelik çıkarma işlemi gerçekleştirilmelidir. Bu adım, veri setindeki gereksiz veya ilişkili öznitelikleri belirleyerek, modelin daha verimli ve doğru sonuçlar üretebilmesi için gerekli olan öznitelikleri seçme sürecidir. Öznitelik çıkarma, özellikle büyük ve karmaşık veri setleriyle çalışırken kritik bir rol oynar. Veri setinde yer alan bazı öznitelikler, örneğin kişinin adı, soyadı, T.C. kimlik numarası veya örneklerin sıra numarası gibi, modelin tahmin performansına katkıda bulunmayan bilgileri içerir. Bu tür öznitelikler, veri setinden çıkarılmalı ve modelin gereksiz bilgiyle yüklenmesi engellenmelidir. Bu süreç, modelin daha sade ve anlaşılır hale getirilmesini sağlar ve gereksiz bilgi işlem yükünü ortadan kaldırır. Öte yandan, veri setindeki bazı öznitelikler birbiriyle yakından ilişkili olabilir. Örneğin, bir veri setinde "yaş" ve "doğum yılı" gibi öznitelikler yüksek derecede korelasyon gösterebilir. Bu durumda, bu özniteliklerin tek bir öznitelik altında birleştirilmesi, veri setinin sadeleştirilmesi açısından faydalı olabilir. Bu, hem modelin daha verimli çalışmasını sağlar hem de aşırı öğrenme riskini azaltır. Ayrıca, ML algoritmalarının performansını artırarak, daha genel ve doğru tahminler yapılmasına olanak tanır. Öznitelik çıkarma işlemi, veri setini optimize etmek ve modelin performansını artırmak için çeşitli teknikler kullanır. Bunlar arasında öznitelik seçim yöntemleri, öznitelik ölçeklendirme ve boyut azaltma teknikleri yer alır. Bu teknikler, modelin eğitim sürecini hızlandırabilir, hesaplama maliyetlerini düşürebilir ve modelin genelleme yeteneğini artırabilir. Öznitelik çıkarma işlemi, ML sürecinde veri setlerinin optimize edilmesi ve modelin daha etkili hale getirilmesi için kritik bir adımdır. Doğru özniteliklerin seçilmesi, modelin genel performansını iyileştirir, daha hızlı ve daha doğru

sonuçlar elde edilmesini sağlar. Bu nedenle, ML projelerinde öznitelik çıkarma adımına gereken önem verilmelidir [108, 109, 112].

ML süreçlerinde, veri setleri genellikle hem sayısal hem de kategorik verilerden oluşur. Ancak, ML algoritmalarının sayısal verilerle çalıştığını göz önünde bulundurduğumuzda, kategorik verilerin bu algoritmalar tarafından işlenebilmesi için sayısal forma dönüştürülmesi gerekmektedir. Bu dönüşüm, veri ön işleme sürecinin kritik bir adımı olan kategorik verilerin dönüşümünü gerektirir. Kategorik veriler, niteliksel özellikleri temsil eder ve genellikle metin veya sınıf etiketleri şeklinde ifade edilir [112].

Örneğin, bir veri setinde "Renk" adlı bir öznitelik, "Kırmızı", "Mavi", "Yeşil" gibi kategorik değerlere sahip olduğunda bu tür veriler, doğrudan ML algoritmalarına girdi olarak sağlanamaz. Çünkü ML algoritmaları bu metinsel ifadeleri matematiksel işlemlerle anlamlandıramaz. Dolayısıyla, bu verilerin sayısal bir forma dönüştürülmesi zorunludur. Kategorik verilerin dönüşümü için yaygın olarak kullanılan birkaç yöntem bulunmaktadır.

Etiketleme (Label encoding)

Bu yöntemde, her kategorik değer bir tam sayı ile temsil edilir. Örneğin, "Kırmızı" 0, "Mavi" 1, "Yeşil" 2 olarak kodlanabilir. Ancak, bu yaklaşımda kategorik değerler arasında doğal bir sıralama veya hiyerarşi olmadığında, yanlış bir anlam çıkarımı riski vardır. Bu nedenle, bu yöntem yalnızca kategorik verilerin sıralı olduğu durumlarda tercih edilmelidir.

Tek sıcak kodlama (One-hot encoding)

Bu yöntemde, her kategorik değer için ayrı bir öznitelik oluşturulur ve ilgili kategorik değerin bulunduğu sütunda 1, diğerlerinde ise 0 değeri atanır. Örneğin, "Renk" özniteliği için "Kırmızı", "Mavi" ve "Yeşil" kategorileri ayrı sütunlar olarak eklenir ve her satırda ilgili kategorinin sütununa 1 değeri verilir. Bu yöntem, kategorik verilerin daha doğru bir şekilde temsil edilmesini sağlar ve kategoriler arasında yanlış sıralama ilişkisi kurulmasını engeller.

Sıcak etiket kodlama (Ordinal encoding)

Bu yöntem, kategorik verilerin sıralı olduğu durumlarda kullanılır. Her kategori, sıralı bir sayı ile temsil edilir. Örneğin, "Düşük", "Orta", "Yüksek" gibi kategoriler sırasıyla 1, 2, 3 olarak kodlanabilir. Bu yöntem, kategoriler arasındaki sıralı ilişkinin korunmasını sağlar.

Kategorik verilerin sayısal verilere dönüştürülmesi, ML modellerinin daha doğru ve verimli çalışmasını sağlar. Bu adım, veri setinin ML algoritmaları tarafından işlenebilir hale gelmesini ve modelin performansını artırmasını mümkün kılar. Yanlış bir dönüşüm yöntemi kullanıldığında, modelin önyargılı sonuçlar üretmesi veya performansının düşmesi gibi istenmeyen sonuçlar ortaya çıkabilir. Bu nedenle, kategorik verilerin dönüşüm sürecinde, veri setinin yapısı, kategorik özniteliklerin özellikleri ve modelin gereksinimleri dikkate alınmalıdır. Doğru yöntemler kullanılarak gerçekleştirilen kategorik verilerin dönüşümü, verilerin algoritmalar tarafından etkili bir şekilde işlenmesini sağlar ve modelin genel başarısını önemli ölçüde artırır.

5.4. Makine Öğrenmesi Sınıflandırma Türleri

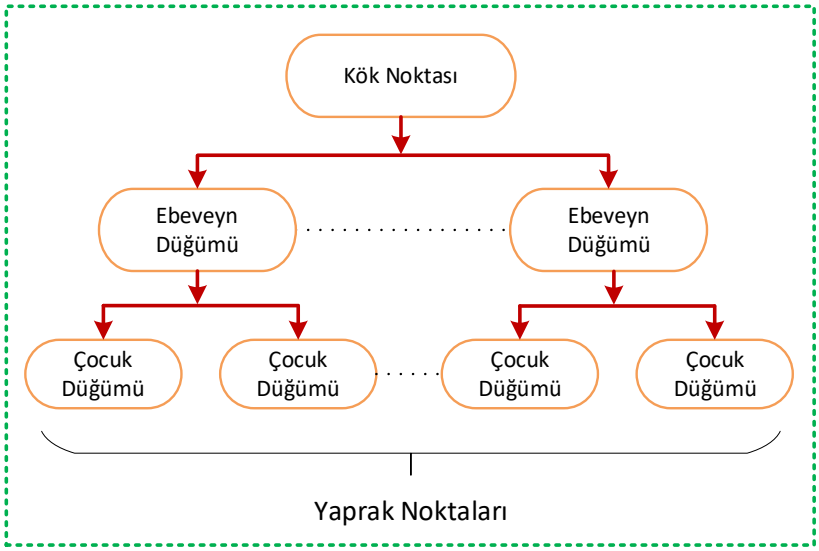
Sınıflandırma, denetimli öğrenmenin temel türlerinden biridir ve ML uygulamalarında yaygın olarak kullanılır. Bu yöntem, bir veri setindeki özniteliklerden yola çıkarak hedef değişkenin hangi sınıfa ait olduğunu tahmin etmeyi amaçlar. Hedef değişken kategoriktir; bu, hedefin belirli ve ayrık kategorilere (sınıflara) ait olduğu anlamına gelir. Sınıflandırma, sınıf etiketlerini doğru bir şekilde öngören tahmin modelleri oluşturmayı hedefler [108]. Bu tez çalışmasında V2G topolojisinde EV'lerin şebeke entegrasyonu ikili sınıflandırma problemi haline getirildi. Bu tez çalışmasında bir yerleşim yerindeki yirmi araç sürücüsünün davranışlarını modelleyen bir veri seti oluşturuldu. V2G topolojisi işletileceği esnada enerji akışının hangi araçların bataryaları ile sağlanması gerektiği bir ML sınıflandırma problemi haline getirildi. Sınıflandırma problemi ile enerji akış modeli için V2G topolojisi işletildiğinde şebekedeki güç kalitesi problemi giderilene kadar şebekeye bağlı kalma ihtimali en yüksek araç gurubunun tahmin işlemi gerçekleştirildi. Sınıflandırma probleminin çözümünde Çizelge 5.1'de verilen literatürde en sık kullanılan 22 adet ML yöntemi kullanıldı.

Çizelge 5.1. Tez çalışmasında kullanılan makine öğrenmesi sınıflandırma yöntemleri

Yöntem No	Makine Öğrenmesi Sınıflandırma Yöntemleri	
Yöntem 1	Karar Ağacı (Decision Tree)	İnce Ağaç (Fine Tree)
Yöntem 2		Orta Ağaç (Medium Tree)
Yöntem 3		Kalın Ağaç (Coarse Tree)
Yöntem 4	Lojistik Regresyon (Logistic Regression)	
Yöntem 5	Naive Bayes	Gauss Naive Bayes
Yöntem 6		Karnel Naive Bayes
Yöntem 7	Destek Vektör Makineleri (Support vector machine-SVM)	Doğrusal (Linear) SVM
Yöntem 8		Kuadratik (Quadratic) SVM
Yöntem 9		Kübik (Cubic) SVM
Yöntem 10		İnce Gauss (Fine Gaussian) SVM
Yöntem 11		Orta Gauss (Medium Gaussian) SVM
Yöntem 12		Kalın Gauss (Coarse Gaussian) SVM
Yöntem 13	Kollektif (Topluluk) Öğrenme (Ensemble Learning)	Güçlendirilmiş Ağaçlar (Boosted Trees)
Yöntem 14		Torbalanmış Ağaçlar (Bagged Trees)
Yöntem 15		RUS Güçlendirilmiş Ağaçlar (RUS Boosted Trees)
Yöntem 16	K-En Yakın Komşu (K-Nearest Neighbour-KNN)	İnce (Fine) KNN
Yöntem 17		Orta (Medium) KNN
Yöntem 18		Kalın (Coarse) KNN
Yöntem 19		Kosinüs (Cosine) KNN
Yöntem 20		Kübik (Cubic) KNN
Yöntem 21		Ağırlıklı (Weighted) KNN
Yöntem 22	Yapay Sinir Ağları (YSA)	

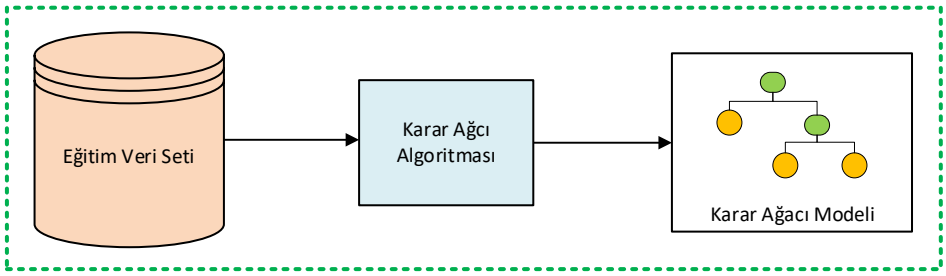
5.4.1. Karar ağacı

Karar ağacı öğrenimi ML sınıflandırma problemlerinde kullanılan tahminsel denetimli bir öğrenme yaklaşımıdır. Bağımlı değişken ile bağımsız değişken arasındaki ilişki bir ağaç yapısı ve onun dalları ile modellenir. Şekil 5.9'da gösterildiği gibi karar ağacı kök noktasından başlayarak yukarıdan aşağıya doğru yapıda ebeveyn-çocuk ilişkisi ile dallara ayrılır. Kök noktasından yaprak düğümüne kadar giden bir yol ile aşamalı olarak ilişkili bir karar ağacı gelişir. Hedef sonuç, yaprak düğümleri olan bir ağaç yapısıdır. Hedef değişkenin ayrık değerler aldığı sınıflandırma problemlerinde, karar ağacının yaprak noktaları sınıf etiketlerini temsil ederler. Bu yaprakların bağlı olduğu dallar ise bu sınıf etiketlerine karar verilen özelliklerin birleşimlerini temsil eden değerler kümesidir. Karar ağacının en büyük avantajı kullanıcıların öğrenme sürecinde çok fazla arka plan bilgisi bilmelerine gerek olmamasıdır [118-121].



Şekil 5.9. Karar ağacı genel yapısı

Karar ağaçları, çalışma süreci Şekil 5.10'da gösterildiği gibi basit bir şekilde açıklanabilen, çok yaygın olarak kullanılan bir sınıflandırma yöntemidir. Karar ağaçlarının birçok sınıflandırma yönteminde, temel farkları esas olarak karar ağaçları üretilirken farklı karar verme stratejilerinden, yani karar ağaçlarının sınıflandırma algoritmalarının farklılığından kaynaklanmaktadır.



Şekil 5.10. Karar ağacının çalışma süreci

Karar ağacında dallanmanın gerçekleşmesi için Gini indeksi (Gini's index), entropi ve çekme (towing) karar verme yöntemleri kullanılır. Düğüm noktalarında bölünmeye karar vermek için bu yöntemlerden birisi kullanılır. Eş. 5.1'de gösterilen Gini indeksi bölünme kuralı en sık kullanılan yöntemdir ve gürültülü verilerde oldukça başarılı sonuçlar vermektedir. Gini indeksi değeri 0 ile 1 arasında değişir. Gini indeksi 1'e eşit olması düğüm saflığını gösterir. Eş. 5.2'de verilen entropi bölünme kuralı ile bölünmenin saf bölünme mi yoksa saf olmayan bölünme mi olduğuna karar verilir. Saf bölünme olduğunda entropi 0'a eşittir, saf olmayan bölünme olduğunda ise maksimum olur ve 1'e yaklaşır. Eş.

5.3'de gösterilen çekme bölünme kuralının Gini indeksinden farkı, dallanma sağ ve sol olmak üzere iki yönde yapılır. Bu yöntem Gini indeksine göre daha dengeli ağaç yapıları oluşturulmasına rağmen yavaş çalışmaktadır [122-124].

$$G(S) = 1 - \sum_c [P(c|S)]^2 \quad (5.1)$$

$$E(S) = -\sum_c P(c|S)\, log_2\, P(c|S) \quad (5.2)$$

$$T(S) = P_L P_R [|P(c|S_L) - P(c|S_R)|]^2 \quad (5.3)$$

Bu eşitliklerde;

- *G(S)*: Gini İndeksi
- *E(S)*: Entropi
- *T(S)*: Çekme
- *S*: Karar Ağacındaki Düğüm Sayısı
- *P(c|S)*: S düğümündeki c sınıfına ait bağıl olasılık
- S_L: Karar ağacının solundaki düğüm sayısı
- S_R: Karar ağacının sağındaki düğüm sayısı
- P_L: Sola bölünme olasılığı
- P_R: Sağa bölünme olasılığı
- $P(c|S_L)$: S_L düğümündeki c sınıfına ait bağıl olasılık
- $P(c|S_R)$: S_R düğümündeki c sınıfına ait bağıl olasılıkdır.

Karar ağaçları, modelin dallanma derinliğine, düğüm sayısına ve bu düğümlerdeki veri dağılımına göre çeşitli türlere ayrılır. İnce ağaç, orta ağaç ve kalın ağaç bu türler arasında yer alır. Bu türler karar ağacı modelinin karmaşıklığını ve genel performansını belirlemek için kullanılır.

<u>İnce ağaç (Fine tree)</u>

Dallanma derinliği genellikle çok fazladır, yani ağaç daha fazla katman içerir. Çok sayıda düğüm bulunur, bu da ağacın her bir veri noktasını daha spesifik olarak sınıflandırmasına olanak tanır. İnce ağaçlar, yüksek doğruluk sağlayabilir ve veri setindeki ince ayrıntıları yakalayabilir. Özellikle çok karmaşık veri setlerinde hassas tahminler yapabilir. Aşırı öğrenme riski yüksektir. Bu durum, modelin eğitim verisine çok iyi uyum sağladığı ancak test verisine genelleme yapamadığı anlamına gelir. Ayrıca, ince ağaçların hesaplama maliyeti ve zaman gereksinimi yüksektir.

Orta ağaç (Medium tree)

Orta ağaç, ince ağaç ile kalın ağaç arasında bir karmaşıklığa sahiptir. Dallanma derinliği orta düzeydedir, yani ağaç ne çok yüzeysel ne de çok derindir. Düğüm sayısı da orta düzeydedir, bu da hem veri setinin detaylarını yakalayabilmeyi hem de aşırı öğrenme riskini azaltmayı amaçlar. Orta ağaç genellikle daha iyi bir denge sağlar; modelin hem eğitim hem de test verisinde iyi performans göstermesini sağlayabilir. Orta düzeydeki karmaşıklık, veri setinin önemli ayrıntılarını yakalarken gereksiz düğümleri ortadan kaldırır. Bazı durumlarda, ince ayrıntıları yakalayamayabilir ve bu nedenle çok karmaşık veri setlerinde doğruluk oranı ince ağaç kadar yüksek olmayabilir.

Kalın ağaç (Coarse tree)

Kalın ağaç, en basit ve en az karmaşık olan karar ağacıdır. Dallanma derinliği genellikle azdır, bu da ağacın daha az katmana sahip olduğu anlamına gelir. Düğüm sayısı azdır, dolayısıyla ağaç veri setini daha yüzeysel bir şekilde sınıflandırır. Kalın ağaç, genellikle aşırı öğrenme riskini en aza indirir ve daha hızlı çalışır. Küçük veya basit veri setleri için uygundur ve genelleme yeteneği yüksektir. Çok basit kaldığı için karmaşık veri setlerinde düşük doğruluk oranı gösterebilir. Veri setindeki ayrıntıları yakalayamayabilir ve bu durum modelin performansını olumsuz etkileyebilir.

Karar ağaçlarının türlerini matematiksel olarak anlamak, ağacın dallanma derinliği, düğüm sayısı, bilgi kazancı gibi metriklerle ilgilidir. Bilgi kazancı, bir bölme sonucunda düğümlerdeki entropi azalmasını ifade eder. Bir özelliğin bilgi kazancı Eş. 5.4'deki gibi ifade edilir. Gini indeksi, entropi ve bilgi kazancı karar ağaçlarının türlerinin belirlenmesinde kullanılır.

$$I_G(S) = E(S) - \sum_{v=1}^{A} \frac{|S_v|}{|S|} \times E(S_v) \quad (5.4)$$

Bu eşitlikte;

- $I_G(S)$: S düğümündeki bilgi kazancı
- $E(S)$: Entropi
- $E(S_V)$: Bir özniteliğe ait entropi değeri
- S: Karar Ağacındaki Düğüm Sayısı

- A: Veri setindeki öznitelik sayısı
- S_V: Bir özniteliğe sahip düğüm sayısıdır.

5.4.2. Lojistik regresyon

Lojistik regresyon, özellikle ikili sınıflandırma problemleri için yaygın olarak kullanılan bir yöntemdir. Bu yöntem, bağımlı değişkenin (hedef değişken) iki sınıf etiketinden birine ait olma olasılığını tahmin eder. Lojistik regresyonun temel amacı, bağımsız değişkenler (öznitelikler) ile bağımlı değişken arasında doğrusal bir ilişki kurmak ve bu ilişkiyi logit fonksiyonu (logaritmik dönüşüm) aracılığıyla modellemektir. Bu sayede, sınıflandırma problemlerinde kullanılabilecek olasılıklar elde edilir. Lojistik regresyon bağımlı değişkenin sürekli bir değer yerine iki olası değerden birine sahip olduğu durumlarda kullanılır. Bu iki değer genellikle "0" ve "1" olarak kodlanır. Ancak farklı sınıf etiketleri de kullanılabilir. Lojistik regresyon modeli, bağımlı değişkenin sınıf 1'e ait olma olasılığını hesaplar. Bu olasılık, 0 ile 1 arasında bir değer alır ve logit fonksiyonu kullanılarak doğrusal bir modelle ifade edilir [112, 125].

Lojistik regresyon modelinde, bağımlı değişkenin (Y) sınıf 1'e ait olma olasılığı $P(Y=1|X)$ şeklinde ifade edilir. Bu olasılık, bağımsız değişkenler (X) üzerinden hesaplanır ve Eş. 5.5'deki gibi ifade edilir.

$$P(Y = 1|X) = \frac{1}{1+e^{-(\beta_0+\beta_1X_1+\beta_2X_2+\cdots+\beta_nX_n)}} \tag{5.5}$$

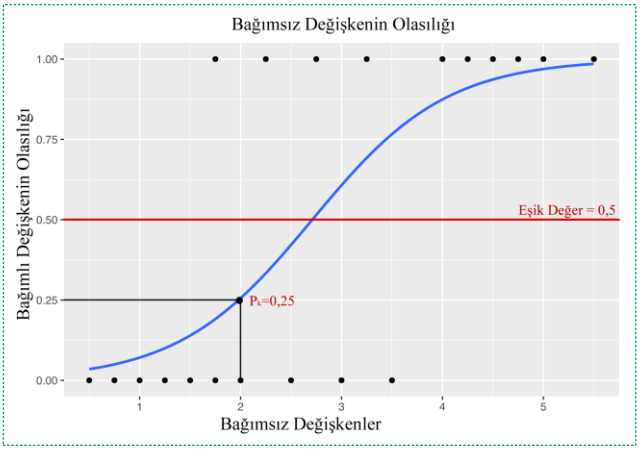
Bu eşitlikte;

- $P(Y=1|X)$: Bağımlı değişkenin sınıf 1'e ait olma olasılığı
- β_0: Kesim noktası
- $\beta_1, \beta_2, \ldots, \beta_n$: Bağımsız değişkenlerin katsayıları
- $X_1, X_2, \ldots, X_n$: Bağımsız değişkenlerdir.

Lojistik regresyon modelinde, bağımlı değişkenin (Y) sınıf 0'a ait olma olasılığı P(Y=0|X) şeklinde Eş. 5.6'daki gibi ifade edilir.

$$P(Y = 0|X) = 1 - P(Y = 1|X) \tag{5.6}$$

Bir makine öğrenmesi modeli ile, β parametrelerinin en iyilenmesi ile hataların karelerinin toplamını ifade eden hata fonksiyonunun minimum yapılması hedeflenmektedir. Lojistik regresyon modelinde de model eğitilerek β parametrelerinin en iyilenmesi sağlanır. Oluşturulan model eşik değerin üstündeki örnekler için yüksek olasılık, eşik değerin altındaki örnekler için ise düşük olasılık tahmin eder (Şekil 5.11).



Şekil 5.11. Lojistik regresyon sınıflandırma eğrisi

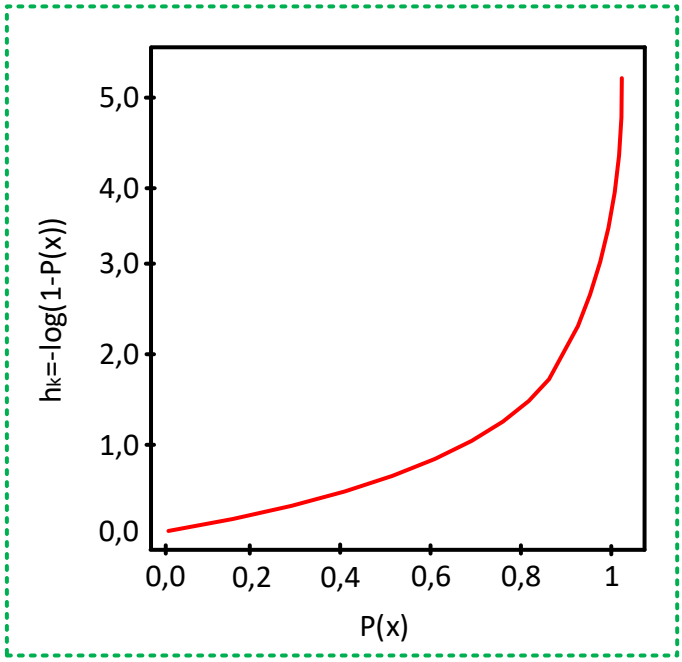
Hata fonksiyonunun (h_k) hesaplanabilmesi için Eş. 5.7'de görüldüğü gibi sigmoid fonksiyonunun logaritma dönüşüm işlemine tabi tutulması gerekmektedir. Bir k noktası için verilen X_k ve Y_k değerleri için tahmin olasılığı P_k'dır.

$$h_k = \begin{cases} -log(P_k) & ; \quad y = 1 \; ise \\ -log(1 - P_k) & ; \quad y = 0 \; ise \end{cases} \tag{5.7}$$

P_k Eş.5.8'deki gibi ifade edilir;

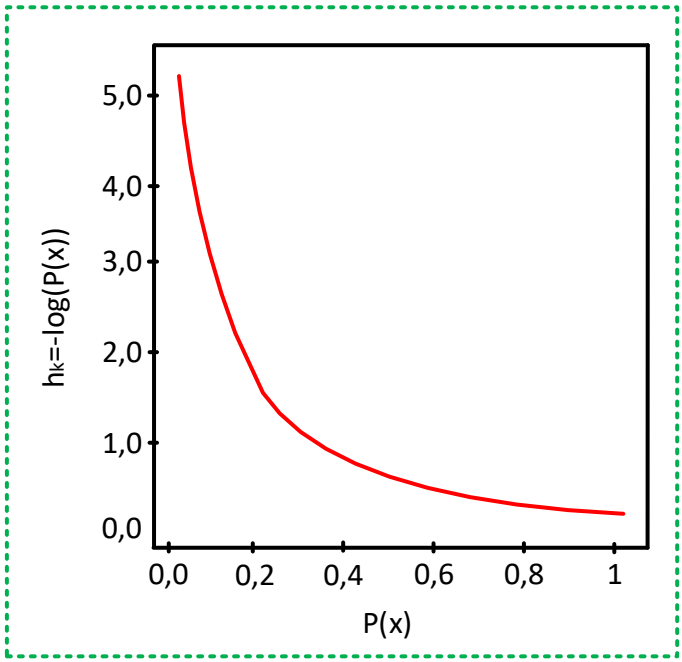
$$P_k = P(X_k) \tag{5.8}$$

Konunun daha iyi anlaşılması için bu logaritma dönüşümüne neden ihtiyaç duyulduğunun açıklanması gerekir. Şekil 5.12'de verilen sigmoid fonksiyonu incelendiğinde x değerinin $+\infty$ 'a giderken fonksiyonun 1'e yakınsadığı ve $-\infty$ 'a giderken fonksiyonun 0'a yakınsadığı görülmektedir. Sigmoid fonksiyonunda eğrinin iki adet dış bükey yapıya sahip olduğu görülmektedir. Sigmoid fonksiyonunun değerinin 1'den 0'a doğru değişiminde, hatanın 0'a yaklaştığı görülmektedir. Dolayısıyla sigmoid fonksiyonunun değeri küçüldükçe hata fonksiyonunun değeri de küçülmektedir [112].



Şekil 5.12. Sigmoid fonksiyonun logaritma dönüşümü (y=0 için)

Şekil 5.13'de ise sigmoid fonksiyonunun değerinin 0'dan l'e doğru değişiminde, hatanın sıfıra yaklaştığı görülmektedir. Dolayısıyla sigmoid fonksiyonunun değeri büyüdükçe hata fonksiyonunun değeri de küçülmektedir [112].



Şekil 5.13. Sigmoid fonksiyonun logaritma dönüşümü (y=1 için)

Tüm eğitim setindeki hata fonksiyonu Eş. 5.9'daki gibi genel bir ifade ile yazılabilir.

$$h(\beta) = \frac{1}{n}\sum_{i=0}^{n}(y_i - 1)\, log\big(1 - h(x_i)\big) - y_i\, log\big(h(x_i)\big) \tag{5.9}$$

Bu eşitlikte;

- *h(β)*: Kesim noktasındaki hatanın genel ifadesi
- *n*: Veri setindeki örnek sayısı
- x_i: i'ninci bağımsız değişken
- y_i: i'ninci bağımlı değişken
- $h(x_i)$: i'ninci bağımsız değişkenin hata oranıdır.

5.4.3. Naive Bayes

Naive Bayes, denetimli öğrenme kategorisinde yer alan ve olasılıksal yaklaşıma dayanan bir sınıflandırma algoritmasıdır. Adını 18. yüzyılda yaşamış İngiliz matematikçi Thomas Bayes'in geliştirdiği Bayes teoreminden alır. Bu algoritma, koşullu olasılık ilkesine dayanır ve sınıflandırma işlemini gerçekleştirirken veri setindeki bağımsız değişkenlerin birbirinden bağımsız olduğunu varsayar. Bu varsayım, gerçek dünyadaki verilerde nadiren tam olarak geçerli olsa da modelin basitliği ve verimli çalışması nedeniyle Naive Bayes algoritması birçok uygulamada etkili bir performans sergiler [108, 112].

Naive Bayes, her bir sınıf için gözlem altındaki özelliklerin koşullu olasılıklarını hesaplar ve Bayes teoremi aracılığıyla bu olasılıkları birleştirerek, yeni bir gözlemin hangi sınıfa ait olabileceğini tahmin eder. Bayes teoremi raslantısal bir sürece bağlı olarak ortaya çıkan rastgele bir A olayı ile diğer bir rastgele ortaya çıkan B olayı için koşullu olasılıklar ve marjinal olasılıklar arasındaki ilişkiyi tanımlar. Bu ilişki Eş. 5.10'daki gibi ifade edilir.

$$P(A|B) = \frac{P(B|A)P(B)}{P(A)} \tag{5.10}$$

Bu eşitlikte;

- *P(A)*: *A* olayının bağımsız olasılığı (Öncül Olasılık)
- *P(B)*: *B* olayının bağımsız olasılığı (Kanıt Olasılık)
- *P(B|A)*: *A* olayının olduğu bilindiğinde *B* olayının olasılığı (Şartlı Olasılık)
- *P(A|B)*: *B* olayının olduğu bilindiğinde *A* olayının olasılığı (Artçıl Olasılık) dır.

Bayes teoremi temel olarak incelendiğinde sınıflandırma problemlerinde özniteliklerden ve sınıf etiketlerinden oluşan bir veri seti için ağın daha önce görmediği bir örneğe ait sınıf etiketini doğru tahmin etmesi amaçlanmaktadır. Bir veri setinde *X*, *n* boyutlu öznitelikler vektörü ve *A* sınıf etiketlerinin bir kümesi olmak üzere *m* adet sınıf etiketi için *X* Eş. 5.11'deki gibi *A* ise Eş. 5.12'deki gibi tanımlanır [112].

$$X = (X_1, X_2, \cdots, X_n) \tag{5.11}$$

$$A = C_1, C_2, \cdots, C_m \tag{5.12}$$

Naive Bayes algoritması ile oluşturulan bir sınıflandırıcı, *X* özniteliğine ait değerler biliniyorken bu değerlerin hangi C_i, sınıfına ait olduğunu yani $P(C_i|X)$ koşullu olasılığını tahmin eder. Birden fazla sınıf etiketi ($P(C_1|X)$, $P(C_2|X)$, ...) olduğu için ve en yüksek olasılığa ait sınıf etiketi seçileceğinden dolayı, $P(C_i|X)$ değerinin en büyük olması yani en büyüklenmesi gerekir. Bayes teoremine göre, $P(C_i|X)$ ifadesi Eş. 5.13'deki gibi ifade edilir [112].

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \tag{5.13}$$

Bu eşitlikte $P(X)$, tüm sınıflar için sabittir ve ihmal edilebilir. Bu durumda $P(Ci|X)$ değerini en büyüklemek için $P(X|C_i)\ P(C_i)$ çarpımını en büyüklemek yeterli olacaktır. Eğer $P(Ci)$ olasılığının değerleri bilinmiyorsa bu sınıf olasılıklarının eşit olduğu varsayılır ve Eş. 5.14'deki gibi ifade edilebilir. Bu durumda geriye bir tek $P(X|C_i)$ olasılığı kalır ve bu değerin en büyüklenmesi aslında $P(C_i|X)$ değerini en büyüklemek anlamına gelecektir. $P(C_i|X)$ olasılığı Eş. 5.15'deki gibi ifade edilir ve eğitim veri setinden kolayca hesaplanabilir [112].

$$P(C_1) = P(C_2) = \cdots = P(C_m) \tag{5.14}$$

$$P(X|C_i) = \prod_{k=1}^{n} P(X_k|C_i) = P(X_1|C_i) \cdot P(X_2|C_i) \cdots P(X_n|C_i) \tag{5.15}$$

Son olarak *X* öznitelikler vektörünün sınıf etiketini tahmin etmek gerekmektedir. Bunun için Eş. 5.16'daki olasılık hesaplanmalıdır.

$$P(X|C_i) \cdot P(C_i), \forall C_i \tag{5.16}$$

Her sınıf etiketi için hesaplanan bu olasılığın en büyük değeri, tahmin edilen sınıf etiketidir. Genel olarak ise en olası sınıf (EOS) Eş. 5.17'deki gibi ifade edilir.

$$\underset{C_i \in A}{argmax}\, P(X|C_i) \cdot (PC_i) \rightarrow C_{EOS} = \underset{C_i \in A}{argmax}\, P(X_1, X_2, \cdots, X_n|C_i) \cdot P(C_i) \tag{5.17}$$

Naive Bayes algoritması, verilerin dağılımına ve yapısına göre çeşitli modellerde uygulanabilir. Bu modeller arasında Gauss Naive Bayes, Karnel Naive Bayes, çok terimli Naive Bayes ve Bernoulli Naive Bayes en yaygın kullanılanlarıdır.

Gauss Naive Bayes

Gauss Naive Bayes, sürekli özellikler içeren veri setleri için uygundur. Bu modelde, her sınıfın özelliklerinin normal (Gauss) dağılıma sahip olduğu varsayılır. Gaussian Naive Bayes, özellikle sürekli veri setlerinde kullanılır ve veri setindeki her bir özellik için olasılık değeri Eş. 5.18 kullanılarak hesaplanır [112].

$$P(X_n|C_i) = \frac{1}{\sqrt{2\pi\sigma_i^2}} exp\left(-\frac{(X_n-\mu_i)^2}{2\sigma_i^2}\right) \tag{5.18}$$

Bu eşitlikte;

- $P(X_n|C_i)$: Ci sınıfında X_n özelliğinin olasılığı
- μ_i: C_i sınıfının ortalaması
- σ_i^2: C_i sınıfının varyansı
- X_n: Gözlem altındaki özellik değeridir.

Çok terimli Naive Bayes

Çok terimli Naive Bayes, ayrık sayılabilir özellikler ve özellikle metin sınıflandırma gibi doğal dil işleme uygulamaları için uygundur. Bu modelde, özelliklerin kategorik ve sayılabilir oldukları kabul edilir. Bu model, özellikle belge veya kelime sayıları gibi sayılabilir verilerle çalışmak için uygundur. Çok terimli Naive Bayes Eş. 5.19'daki gibi ifade edilir [112].

$$P(X_n|C_i) = \frac{N_{C_i}^{X_n}+1}{N_{C_i}+n} \quad (5.19)$$

Bu eşitlikte;

- $P(X_n|C_i)$: C_i sınıfında X_n özelliğinin olasılığı
- $N_{C_i}^{X_n}$: Ci sınıfında Xn özelliğinin sayısı
- N_{C_i}: Ci sınıfındaki tüm özelliklerin sayısı
- n: Tüm özelliklerin sayısıdır.

Bernoulli Naive Bayes

Bernoulli Naive Bayes, ikili özelliklere sahip veri setleri için uygundur. Bu model, her özelliğin sadece iki değerden birini alabileceğini varsayar (örneğin, var/yok, doğru/yanlış). Bernoulli Naive Bayes Eş. 5.20' de gösterildiği gibi ifade edilir [112].

$$P(X_n|C_i) = P_i^{X_n} \cdot (1 - P_i)^{(1-X_n)} \quad (5.20)$$

Bu eşitlikte;

- $P(X_n|C_i)$: C_i sınıfında X_n özelliğinin olasılığı
- P_i: C_i sınıfında $X_n=1$ olma olasılığı
- *(1-Pi): Ci sınıfında $X_n=0$ olma olasılığı*
- X_n: Gözlem altındaki özellik değeri (0 veya 1)

Kernel Naive Bayes

Kernel Naive Bayes, Naive Bayes'in bir türevi olarak düşünülebilir. Ancak standart Gauss, çok terimli veya Bernoulli Naive Bayes modellerinden farklıdır. Kernel Naive Bayes, özelliklerin olasılık dağılımlarını modellemek için kernel yoğunluk tahminlerini kullanır. Klasik Naive Bayes modellerinde, özelliklerin olasılık dağılımları genellikle belirli bir dağılım varsayımı (örneğin, Gauss) ile modellenir. Kernel Naive Bayes'te ise, bu dağılım varsayımını yapmaz ve bunun yerine, özelliklerin olasılık yoğunluk fonksiyonlarını kernel fonksiyonları kullanarak tahmin eder. Kernel Naive Bayes, verilerin dağılımı hakkında belirli bir varsayımda bulunmaz, bu da onu daha esnek hale getirir. Kernel fonksiyonları, veri noktalarının yoğunluğunu tahmin etmek için kullanılır. Yaygın kernel fonksiyonları arasında Gauss, Epanechnikov ve Laplace kernel fonksiyonları bulunur. Kernel Naive Bayes, her bir sınıf için veri noktalarının olasılık yoğunluklarını tahmin eder ve bu

tahminlere dayalı olarak sınıflandırma yapar. Kernel Naive Bayes özellikle, özelliklerin olasılık dağılımlarının karmaşık veya bilinmeyen olduğu durumlarda kullanışlı olabilir. Bu durumda, kernel fonksiyonları, her bir özelliğin dağılımını daha doğru bir şekilde modelleyebilir ve bu sayede sınıflandırma performansı artırılabilir. Kernel Naive Bayes Eş. 5.21' de gösterildiği gibi ifade edilir [126]. Özetle, Kernel Naive Bayes, özelliklerin dağılımlarını kernel yoğunluk tahminleri ile modelleyerek, özellikle karmaşık veya bilinmeyen dağılıma sahip veri setlerinde performans artırmayı hedefleyen bir yöntemdir. Gauss, çok terimli ve Bernoulli Naive Bayes gibi daha yaygın modellerden farklı olarak, belirli bir dağılım varsayımı yapmadan, esnek bir yaklaşım sunar.

$$P(X_n|C_i) = \frac{1}{n_i}\sum_{a}^{n_i} K(X_n - X_{na}) \tag{5.21}$$

Bu eşitlikte;

- *K(X)*: Kernel fonksiyonu, örneğin Gaussian kernel
- n_i: C_i sınıfındaki veri noktalarının sayısı
- X_{na}: C_i sınıfındaki *n*'inci veri noktasının *a*'ıncı özelliğidir.

Kernel Naive Bayes, bu tahmin edilen yoğunlukları kullanarak, her sınıf için artçıl olasılığı hesaplar ve en yüksek olasılığa sahip sınıfı seçer.

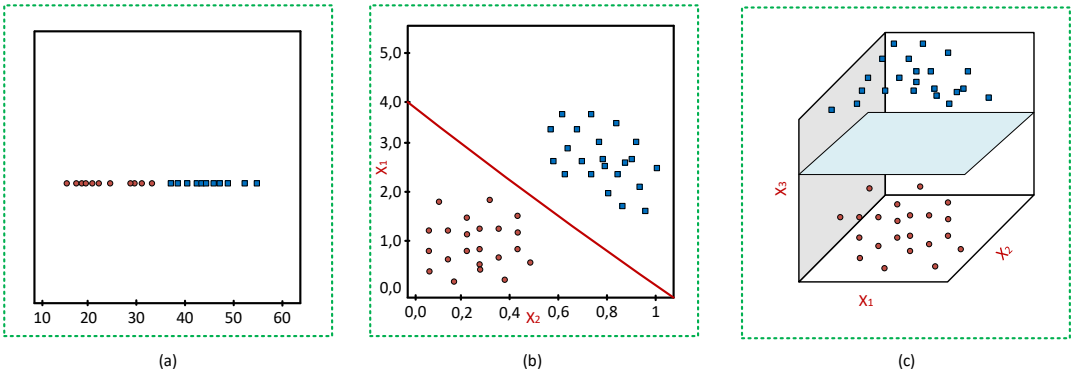
5.4.4. Destek vektör makineleri

Destek vektör makineleri (SVM) çok sık kullanılan popüler sınıflandırma tekniklerinden birisidir. SVM, kalkülüs, vektör geometrisi ve kısıtlı en iyileme gibi matematik konularına dayanan; doğrusal ve doğrusal olmayan sınıflandırma problemlerini gerçekleştirmeye olanak tanıyan bir ML sınıflandırma tekniğidir. SVM ile sınıflandırmanın temel amacı, iki boyutlu bir uzayda sınıflandırma yapmanın yanı sıra yüksek boyutlu öznitelikler uzayında da hiper düzlemlerin iyi bir şekilde ayrılarak en uygun sınıflandırmanın sağlanmasıdır. Bir diğer ifadeyle SVM ile sınıflandırmanın temel amacı, iki boyutlu bir uzayda sınıflandırma yapmanın yanı sıra yüksek boyutlu öznitelikler uzayında da hiper düzlemlerin iyi bir şekilde ayrılarak en uygun sınıflandırmanın sağlanmasıdır [112, 127].

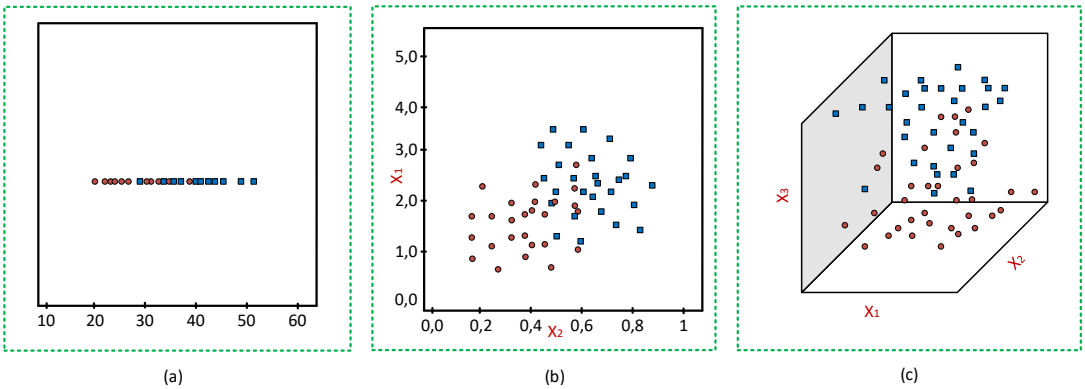
Veriler, bir boyutta nokta, iki boyutta doğru, üç boyutta düzlem ve daha yüksek boyutlu uzaylarda hiper düzlem kullanılarak ayrılabilir. Hiper düzlemler, vektör geometrisi üzerine

kuruludur ve doğrusal cebirin temel bir bileşeni olan vektörler bu düzlemlerin tanımlanmasında kritik bir rol oynar. Bu nedenle, yüksek boyutlu uzaylarda sınıflandırma problemlerini çözmek için vektör geometrisi ve hiper düzlem kavramları hakkında temel düzeyde bilgi sahibi olmak gereklidir [112, 127, 128].

SVM sınıflandırma problemleri doğrusal veya doğrusal olmayan şeklinde ikiye ayrılır. Bu problemler bir boyutlu olduğunda ayırıcı bir noktadır, iki boyutlu olduğunda ayırıcı bir doğrudur ve üç boyutlu problem olduğunda ise ayırıcı bir düzlemdir. Doğrusal ayırıcılar Şekil 5.14'de, doğrusal olmayan ayırıcılar ise Şekil 5.15'de verilmiştir [128].



Şekil 5.14. Doğrusal SVM (a) 1 boyutlu (nokta) ayırıcı (b) 2 boyutlu (çizgi) ayırıcı (c) 3 boyutlu (düzlem) ayırıcı

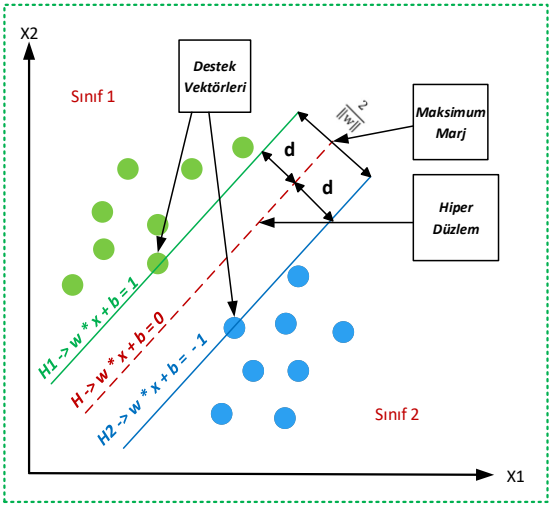


Şekil 5.15. Doğrusal olmayan SVM (a) 1 boyutlu ayırıcı (b) 2 boyutlu ayırıcı (c) 3 boyutlu ayırıcı

Doğrusal SVM'lerde bir hiper düzlem, *n* boyutlu bir uzay için *(n-1)* boyutlu bir alt uzaydır. Hiper düzlem veriyi ayıran bir sınır olarak düşünülebilir. Doğrusal SVM yöntemi bir eğitim kümesindeki giriş değerleri $x_i = (X_1, X_2, X_3, ..., X_n)$ ve sınıf etiketi $y = (-1, +1)$ değerlerini almaktadır. SVM, *p* noktasına ait X_i eğitim verisini -1 ya da 1 sınıfına atayacak

"maksimum marjlı hiper düzlemi" bulmayı amaçlar. Şekil 5.16'da görüldüğü gibi eğitim verileri doğrusal olarak ayırt edilebildiğinde, iki sınıfı ayıracak iki paralel hiper düzlem seçilir. Bu iki hiper düzlem arasındaki sınırlandırıcı bölgeye marj, ikisi arasındaki hiper düzleme ise maksimum marjlı hiper düzlem denilmektedir [129, 130].

Şekil 5.16'da Sınıf 1 ve Sınıf 2'ye ait verilerin H_1 ve H_2 hiper düzlemleri ile ayrıldığı görülmektedir. H_1 ve H_2 hiper düzlemleri üzerinde bulunan veri örnekleri, destek vektörleri olarak adlandırılır. Destek vektörleri bir sınır görevi görürler. Öyle iki destek vektörü seçilmelidir ki hem bu destek vektörlerden geçen H_1 ve H_2 hiper düzlemleri arasındaki mesafe en büyük olmalıdır hem de Sınıf 1 ve Sınıf 2'ye ait örnekler en iyi şekilde birbirinden ayrılabilmelidir. İşte tam olarak destek vektör makinelerinin gerçekleştirmek istediği temel amaç budur. H hiper düzlemi ile destek vektörleri arasındaki d mesafesinin en büyük uzunlukta olması istenmektedir. Bu mesafe marj (kenar payı) olarak da adlandırılır. Destek vektörlerine ait hiper düzlemler arasındaki marjın $2d$ uzunluğunda olduğu görülmektedir. Kenar payının en büyük uzunlukta olması ve sınıfların en iyi şekilde ayrılmasını sağlayan H hiper düzlemi de en uygun düzlem olarak ifade edilir [112, 128-130].



Şekil 5.16. SVM'de destek vektörleri, hiper düzlem ve marj

Matematiksel olarak H, H_1 ve H_2 hiper düzlemleri sırasıyla Eş. 5.22, Eş. 5.23 ve Eş. 5.24'deki gibi tanımlanabilir.

$$H \rightarrow w * x + b = 0 \tag{5.22}$$

$$H_1 \rightarrow w * x + b - d = 0 \quad (5.23)$$

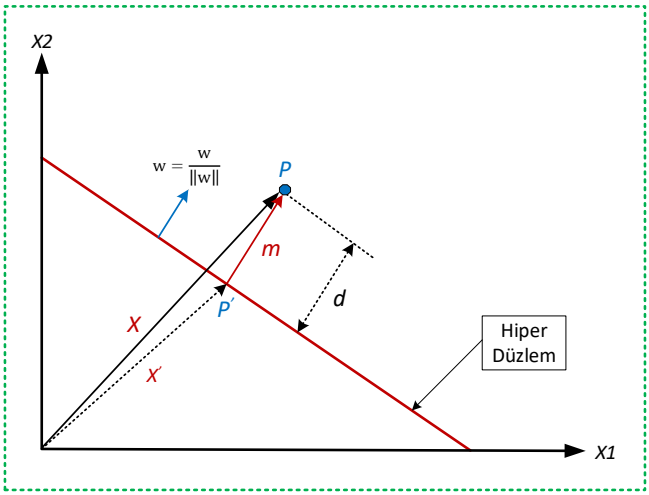
$$H_2 \rightarrow w * x + b + d = 0 \quad (5.24)$$

Bu eşitliklerde hesap kolaylığı açısından d mesafesi 1 birim olarak alınır. Bu durumda H_1 Eş 5.25'deki gibi ve H_2'de Eş. 5.26'daki gibi ifade edilir.

$$H_1 \rightarrow w * x + b = 1 \quad (5.25)$$

$$H_2 \rightarrow w * x + b = -1 \quad (5.26)$$

Şekil 5.17'de gösterildiği gibi marj uzunluğu (d) geometrik olarak bir veri örneği ile hiper düzlem arasındaki Öklid uzunluğudur [112].



Şekil 5.17. Marj (kenar payı) geometrik gösterimi

w birim vektörü Eş. 5.27'deki gibi ifade edilir. P' noktası ise P noktasının hiper düzlem üzerindeki dik izdüşümüdür. m ise w birim vektörü ile aynı yönde vektördür, normu ise d ile ifade edilir. m vektörü Eş. 5.28 ile ifade edilir [112].

$$w = \frac{w}{\|w\|} \quad (5.27)$$

$$m = d \cdot \frac{w}{\|w\|} = d \cdot w \quad (5.28)$$

Vektörlerin çıkarma özelliğinden yararlanılarak *x'* vektörü Eş. 5.29'daki gibi ifade edilir.

$$x' = x - m = x - \left(d \cdot \frac{w}{\|w\|}\right) \tag{5.29}$$

P' noktası hiper düzlem üzerinde olduğu için *P'* noktasının denklemi hiper düzlemin denklemini verecektir. Eş. 5.30 ile Eş. 5.33 arasında *x'* vektörü hiper düzlem denkleminde yazılmış ve gerçekleştirilen işlemler sonucunda marj değeri elde edilmiştir.

$$w * x' + b = 0 \rightarrow (w, x') + b = 0 \rightarrow (w, x) - d \cdot \frac{w}{\|w\|} + b = 0 \rightarrow \tag{5.30}$$

$$(w, x) - d \cdot \frac{w}{\|w\|} + b = 0 \rightarrow (w, x) - d \cdot \frac{(w,w)}{\|w\|} + b = 0 \rightarrow \tag{5.31}$$

$$(w, x) - d \cdot \frac{\|w\|^2}{\|w\|} + b = 0 \rightarrow (w, x) - d \cdot \|w\| + b = 0 \rightarrow \tag{5.32}$$

$$d = \frac{|(w,x)+b|}{\|w\|} = \frac{1}{\|w\|} \tag{5.33}$$

H_1 ve H_2 düzlemleri arasındaki mesafe *2d* olduğundan maksimum marj Eş. 5.34'deki gibi ifade edilir.

$$Maksimum\ Marj \rightarrow\ 2d = \frac{2}{\|w\|} \tag{5.34}$$

Doğrusal ayrılma problemlerinde H_1 ve H_2 düzlemleri arasında maksimum mesafe *2d* elde edilir. Doğrusal ayrılma problemlerindeki bu maksimum mesafe keskin marj olarak isimlendirilir. Ayrıca veri noktalarının kenara düşmesini engellemek için Eş. 5.35'deki kısıtlama kullanılır.

$$H(x_i) = \begin{cases} w * x_i + b \ \geq\ 1 & ; \quad y_i = 1 \\ w * x_i + b \ \leq -1 & ; \quad y_i = -1 \end{cases} \tag{5.35}$$

Eş. 5.35 genel bir ifade ile Eş. 5.36'daki gibi ifade edilebilir.

$$H(x_i) = sgn(w * x_i + b) \tag{5.36}$$

Bir veri setindeki veriler gürültülü veriler olabilir. Gürültülü veri setinde Sınıf 1'e ait bir veri Sınıf 2 içerisinde olabilir. Tersi bir durumda olabilir Sınıf 2'ye ait bir veri Sınıf 1 içerisinde olabilir. Bu durumda sınıfları tam doğrusal olarak ayırmak mümkün olamayacaktır. Hatırlanacağı gibi marjın en büyük olması SVM'lerin amaçlarından biriydi. Ancak bazı durumlarda Sınıf 1'e ait bir örnek Sınıf 2'ye çok yakın uzaklıkta olarak marjın çok küçük olmasına neden olabilir. Marj küçüldükçe sınıflandırma modelinin iyi genelleme yeteneği ortadan kalkacaktır. Bu yüzden farklı bir yaklaşım olan esnek marj kavramı geliştirilmiştir. 1995 yılında Cortes ve Vapnik tarafından geliştirilen esnek marj yaklaşımı, keskin kenar payındaki gibi sıfır sınıflandırma hatası yerine bazı örneklerin karşı sınıfta yer almasına izin verme mantığına dayanır [112].

Eş 5.35'deki *H(x)* fonksiyonu esnek değişken ξ_i kullanılarak Eş. 5.37'daki gibi tekrardan yazılabilir.

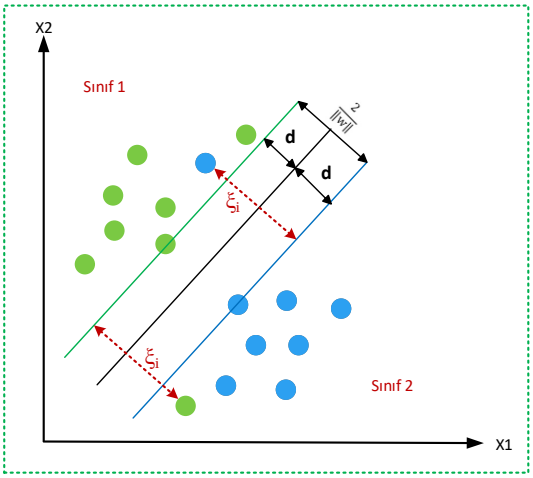
$$H(x_i) = \begin{cases} w * x_i + b \geq 1 - \xi_i & ; \quad y_i = 1 \\ w * x_i + b \leq -1 + \xi_i & ; \quad y_i = -1 \end{cases} \qquad \xi_i \geq 0, \forall_i \tag{5.37}$$

Eş. 5.37 genel bir ifade ile Eş. 5.38'deki gibi ifade edilebilir.

$$H(x_i) = w * x_i + b - 1 + \xi_i \geq 0, \qquad \xi_i \geq 0, \forall_i \tag{5.38}$$

Bu eşitlik ile destek vektör hiper düzleminin konumu değiştirilerek marjın değişmesi sağlanmıştır. Bu sayede sınıflar arasında daha esnek bir sınır oluşturulmuş olur. Şekil 5.18'de ise ξ_i değeri kullanılarak destek vektörleri değiştirilmiştir. Bu durumda bazı örnek noktaların diğer sınıfta yer aldığı görülmektedir. Böylece örneklerin hatalı sınıflandırılmasına müsaade edilerek daha esnek bir sınıflandırma sağlanmış ve gürültülü verilere daha uygun bir model elde edilmiştir. Bu sayede keskin kenar payı kullanılarak yapılan sınıflandırmaya göre daha iyi bir genellemeye sahip sınıflandırma gerçekleştirilerek aşırı öğrenme riski de azaltılmış olmaktadır. Esnek bir marj kullanımı, bazı veri noktalarının diğer sınıfa ait olmasına rağmen marj içinde yer almasına izin verir. Bu esnekliği sağlamak için, SVM modeline ξ_i (x_i) adı verilen hata terimleri eklenir. Bu terimler, verilerin hiper düzleme göre ne kadar "yanlış" sınıflandırıldığını gösterir. SVM

modelinde, bu hata terimlerinin toplamı minimize edilmeye çalışılırken, aynı zamanda marjın geniş tutulması hedeflenir [112].



Şekil 5.18. Esnek marj gösterimi

Maksimum marjın (*2d*) sağlanabilmesi için ||*w*|| değeri minimize edilmeli. Bu nedenle ||*w*|| ifadesinin türevi alınarak Eş. 5.39'daki gibi yazılabilir.

$$\frac{1}{2}\|w\|^2 = \frac{1}{2}(w,w) \tag{5.39}$$

Bu eşitlik optimize edilmiş hali kısıt fonksiyonu ile birlikte Eş. 5.40'daki gibi tekrardan yazılabilir.

$$\min_{w,b}\left(\frac{1}{2}(w,w)\right) \rightarrow \; kısıt \;\; y_i(w * x_i + b\,) \geq 1, \;\; \forall_i \;\; \text{için} \tag{5.40}$$

Esnek kenar için ise marjın optimize edilmiş hali Eş. 5.41'deki gibi yazılabilir.

$$\min_{w,b,\xi}\left(\frac{1}{2}(w,w) + c\sum_{i=1}^{n}\xi_i\right) \rightarrow \; kısıt \;\; y_i(w * x_i + b\,) - 1 + \xi_i \geq 0, \;\; \xi_i \geq 0, \forall_i \; \text{için} \tag{5.41}$$

Esnek marj yönteminde hatalı örnek sayısının da olabildiğince az olması istenen kriterlerden birisi olduğu için bir hiper parametre olan *c* değerlerinin hepsinin toplamının da en az olması istenir. O yüzden bu toplam değeri amaç fonksiyonuna eklenerek, minimize edilmesi istenen amaç fonksiyonu bu denklemdeki gibi ifade edilir. Burada dikkat edilmesi gereken bir nokta ise veri setinde negatif ξ_i değerlerinin güncellenen amaç

fonksiyonunu minimize edecek olmasıdır. Bu problemin aşılması için $\xi_i \geq 0$ kısıtı konulmuştur. Esnek kenar payı kullanılarak yapılan sınıflandırma ile aşırı öğrenmeye karşı bir tedbir alınmaktadır. c değeri ise esnek marj için bir hiper parametredir. Eğer c değeri küçük bir değer seçilirse yanlış sınıflandırılmış örneklere tolerans gösterilerek daha geniş bir marj oluşturulabilir. Aksine c değeri büyük bir değer seçilirse daha küçük marj bırakılır ve yanlış sınıflandırılmış örneklere tıpkı, keskin kenar payı yöntemindeki gibi tolerans gösterilmez. Her veri setinin kendine özgü bir yapısı vardır ve bir veri seti için en uygun parametre değeri, diğer veri setinde iyi sonuç vermeyebilir. Bu yüzden en uygun c değeri her veri seti için değişmektedir [112].

SVM'ler, kullanılan çekirdek (kernel) fonksiyonlarına göre çeşitli türlere ayrılır. Çekirdek fonksiyonu, verilerin orijinal uzaydan daha yüksek boyutlu bir uzaya dönüştürülmesini sağlayarak doğrusal olarak ayrılamayan verilerin ayırt edilebilmesini sağlar.

Doğrusal (Linear) SVM

En temel SVM türüdür, doğrusal bir ayrım hiper düzlemi kullanan. Eş. 5.42'deki gibi hiper düzlem, veri noktalarını doğrudan ayırabilen bir çizgi veya düzlem ile tanımlanır.

$$f(x) = w^T * x + b \tag{5.42}$$

Bu eşitlikte;

- w: Ağırlık vektörü, hiper düzlemin eğimi
- b: Hiper düzlemin konumu
- x: Doğrusal girdi özelliğidir.

Kuadratik (Quadratic) SVM

Kuadratik SVM, doğrusal olmayan bir ayrım sınırı kullanır ve ikinci dereceden bir polinom ile tanımlanır. Bu tür SVM, daha karmaşık sınırlara ihtiyaç duyan veri setleri için uygundur. Hiper düzlem Eş. 5.43'deki gibi tanımlanır.

$$f(x) = w^T * x^2 + b \tag{5.43}$$

Bu eşitlikte;

- *x2* : Kuadratik girdi özellikleridir.

Kübik (Cubic) SVM

Kübik SVM, üçüncü dereceden (kübik) polinomları kullanarak daha karmaşık ayrım sınırları oluşturur. Kübik SVM hiper düzlemi Eş. 5.44'deki gibi tanımlanır.

$$f(x) = w^T * x^3 + b \tag{5.44}$$

Bu eşitlikte;

- *x3* : Kübik girdi özellikleridir.

İnce Gauss (Fine Gaussian) SVM

İnce Gauss SVM, RBF (Radial Basis Function) kernel kullanarak sınıflandırma yapar. İnce Gaussian, küçük bir sigma (σ) değeri kullanarak daha ince ayrım yapar. RBF kernel fonksiyonu Eş. 5.45'deki gibi ifade edilir. Küçük σ değeri ince ayrım yapar.

$$K(x_i, x_j) = exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \tag{5.45}$$

Bu eşitlikte;

- σ : Kernel genişlik parametresidir.

Orta Gauss (Medium Gaussian) SVM

Orta Gauss SVM'de RBF kernel kullanır ancak orta büyüklükte bir σ değeri ile çalışır. Bu, dengeli bir ayrım sağlar. RBF kernel fonksiyonu aynıdır, ancak σ değeri orta büyüklüktedir.

Kalın Gauss (Coarse Gaussian) SVM

Kalın Gauss SVM, büyük σ değeri ile geniş bir ayrım yapar. Bu durumda, ayrım sınırı daha pürüzsüz ve daha az hassas olur.

Bu tür SVM'lerin her biri, farklı karmaşıklık ve veri yapısına sahip problemlere uyacak şekilde tasarlanmıştır. Linear SVM, doğrusal olarak ayrılabilen veri setleri için idealdir. Kuadratik ve kübik SVM'ler, daha karmaşık sınıflandırma gerektiren durumlarda kullanılırken, Gauss SVM'ler, özellikle doğrusal olmayan ayırımlar için uygundur ve kernel fonksiyonunun genişliğine bağlı olarak ince, orta veya geniş bir ayrım yapabilir.

5.4.5. Topluluk (Kolektif) öğrenme

Topluluk (Ensemble) öğrenme modeli güçlü bir öğrenme algoritması üretmek için birden fazla zayıf öğrenme algoritmasını birleştiren güçlü bir ML yöntemidir. Bu yöntem, tek bir modelin sınırlamalarını aşarak daha sağlam ve genelleştirilebilir sonuçlar elde etmeyi hedefler. Topluluk öğrenme modeli, torbalama (Bagging), güçlendirme (Boosting) ve istifleme (Stacking) olmak üzere üç kategoriye ayrılır [131, 132]. Topluluk öğrenme yönteminin yüksek tahmin oranına sahip olması iki önemli faktör varyans ve biasa (Yanlılık) ile sağlanır. Topluluk öğrenimi ile varyansın azaltılması ve biasın artımının önlenmesi sağlanır. Böylece tahmin performansının artırması amaçlanmaktadır. Eş. 5.46'da verilen varyans, sınıflandırıcıların değişkenliğinden kaynaklanan hata olarak tanımlanır. Sınıflandırıcıların aşırı uyumu varyansın artmasına neden olur. Eş. 5.47'de verilen bias ise sınıflandırıcıların beklenen tahmin değeri ile gerçek değeri arasındaki farktan kaynaklanan hata olarak tanımlanır ve yetersiz uyum biasın artmasına neden olur [133-135].

$$Var[x] = Var\left[\frac{1}{N}\sum_{i=1}^{N} x_i\right] \tag{5.46}$$

Bu eşitlikte;

- x: Bağımsız değişken
- $Var[x]$: Bağımsız değişken x'in varyansıdır.

$$\mathbb{E}[y] = \mathbb{E}\left[\frac{1}{N}\sum_{i=1}^{N}(y_i^* - y_i)\right] \tag{5.47}$$

Bu eşitlikte;

- yi: Sınıflandırıcının gerçek değeri
- yi^*: Sınıflandırıcının tahmin değeri
- $\mathbb{E}[y]$: y'nin biasıdır.

Topluluk öğrenme yöntemlerinde en önemli konulardan biriside birden fazla öğrenme modeli ile elde edilen tahminlerin birleştirilmesidir. Topluluk öğrenme modellerini birleştirmek için çoğunluk oylaması ve ağırlıklı çoğunluk oylaması kullanılır [131].

Çoğunluk oylaması

Çoğunluk oylaması en basit oylama stratejisidir. Birden fazla modelin (sınıflandırıcının) her biri bir hedef değişken için bir tahmin yapar. Bu hedef sınıf için, bu tahminlerden en çok tahmin edilen sınıf, nihai karar olarak seçilir. Örneğin *M* adet sınıflandırma modeline ait *x* bağımsız girdisine karşılık y_i hedef fonksiyonuna ait tahminler Eş. 5.48'deki gibi gerçekleştirilir. Hedef fonksiyonuna ait bu tahmin kümesindeki nihai sınıf tahmini, Eş. 5. 49'da gösterildiği gibi en fazla oyu alan sınıf olacaktır.

$$P_{mv}(c|y) = \sum_{i=1}^{M} I(y_i \in c) \tag{5.48}$$

$$\hat{y}_{mv} = \sum_{i=1}^{M} \underset{c}{\operatorname{argmax}}\, P_{mv}(c|y_i) \tag{5.49}$$

Bu eşitliklerde;

- $P_{mv}(c|y)$: *c*'nci sınıfa verilen toplam oy sayısı
- *M*: Toplam sınıflandırma model sayısı
- *c*: Sınıf sayısı
- $I(y_i \in c)$: i'nci modelin c'nci sınıfı tahmin edip etmediğini kontrol eden gösterge fonksiyonu.
- $\hat{y}_{\text{mv}}$: Çoğunluk oyu ile tahmin edilen sınıfıdır.

Ağırlık çoğunluk oylaması

Birden fazla sınıflandırma modelinin her biri bir hedef değişken için bir tahmin yaparken her bir sınıf etiketi için ağırlık değeri üretilir. Bu ağırlık değerleri 0 ile 1 arasındadır. Sınıf etiketlerine ait ağırlıkların toplamı 1'e eşittir. Bir hedef değişkenin sınıflandırılmasında her sınıf etiketi için bu modellerin ağırlık değerleri toplanır ve en yüksek değere sahip sınıf etiketi nihai karar olarak seçilir. Bu yöntemde, her modelin güvenirliğini veya doğruluğunu dikkate alarak nihai kararı verirken daha isabetli tahminler yapılmasını sağlar. Örneğin *M* adet sınıflandırma modeline ait *x* bağımsız girdisine karşılık y_i hedef fonksiyonuna ait ağırlıklı tahminler Eş. 5.50'deki gibi gerçekleştirilir. Hedef fonksiyonuna ait tahmin

kümesindeki nihai sınıf tahmini, Eş. 5.51'de gösterildiği gibi ağırlık değerleri toplanır ve en yüksek değeri alan sınıf etiketi seçilir.

$$P_w(c|y) = \sum_{i=1}^{M} w_i \, I(y_i \in c) \tag{5.50}$$

$$\hat{y}_w = \sum_{i=1}^{M} \underset{c}{\operatorname{argmax}} P_w(c|y_i) \tag{5.51}$$

Bu eşitliklerde;

- $P_w(c|y)$: c'nci sınıfa verilen toplam ağırlıklı oy
- M: Toplam sınıflandırma model sayısı
- c: Sınıf sayısı
- $I(y_i \in c)$: i'nci modelin c'nci sınıfı tahmin edip etmediğini kontrol eden gösterge fonksiyonu.
- $\hat{y}_w$: Toplam ağırlıklı oyu ile tahmin edilen sınıfıdır.

Torbalama yöntemi

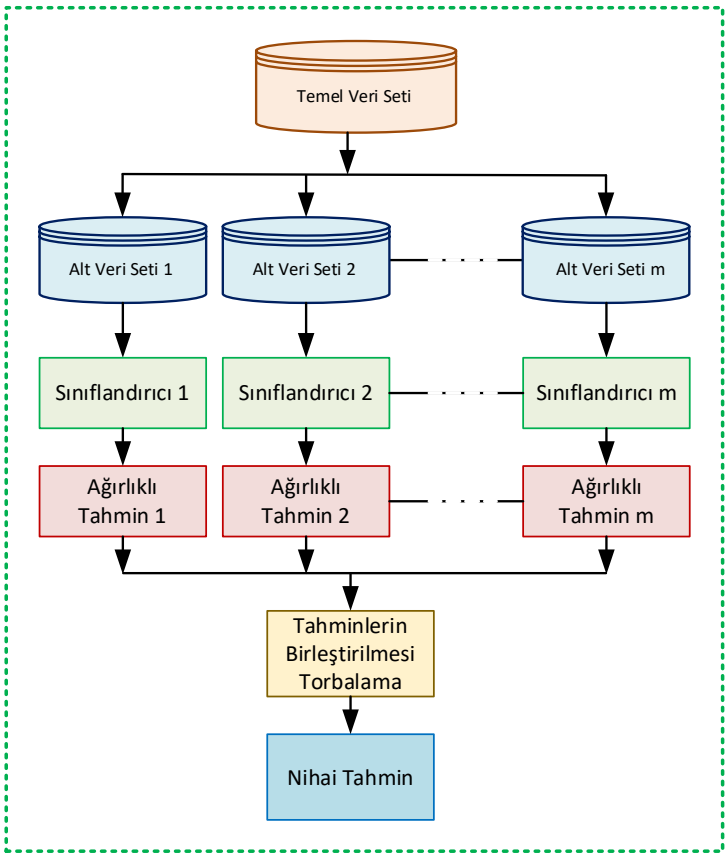
Torbalama topluluk öğrenme yöntemi Breiman tarafından tanıtılmıştır. Torbalama başarılı, etkili ve basit bir topluluk öğrenme yöntemidir [136]. Torbalama, temel olarak aynı modelin birden fazla versiyonunu farklı veri alt kümelerinde eğiterek bu modellerin tahminlerinin ortalamasını veya çoğunluk kararını kullanır. Şekil 5.19'da gösterildiği gibi M adet eğitim alt veri seti (Bootstrap) her biri N adet üyeden oluşan temel veri setinden rastgele örneklem yolu ile her seferinde değiştirilerek oluşturulur. Bu durum her sınıflandırıcının eğitiminde rastgelelik meydana getirir. Eğitimden sonra tüm sınıf tahminleri birleştirilerek variance azaltılmış olur ve bias artması engellenmiş olur [131,132]. Bu nedenle bu yöntem, özellikle değişkenliği yüksek modellerde kullanılır ve genellikle aşırı öğrenmeyi azaltmak için etkilidir.

Torbalama yönteminde n adet hedef fonksiyonu olan bir temel veri setinden (D) rastgele örneklem yoluyla M adet alt veri seti oluşturur. Bu alt veri setlerinde (Dm) eğitilen modellerin çıktıları birleştirilir. Alt veri seti Eş. 5.52'deki gibi ifade edilir.

$$D_m = \{(x_1, y_1), (x_2, y_2), \cdots, (x_n, y_n)\}, m = 1, 2, \cdots, M \tag{5.52}$$

Bu eşitlikte elde edilen M adet alt veri seti ayrı ayrı eğitilir ve her tahmin sınıfı (y_n) için M adet değer elde edilir. Eş. 5.53'de ifade edildiği gibi torbalama işleminde her bir hedef değişken $P(y)$ için tahminlerin ortalaması alınarak hesaplama yapılır ve tahmin sınıfı (c) belirlenir.

$$P(c|y) = \frac{1}{M} \sum_{i=1}^{M} P(c|y_i) \tag{5.53}$$

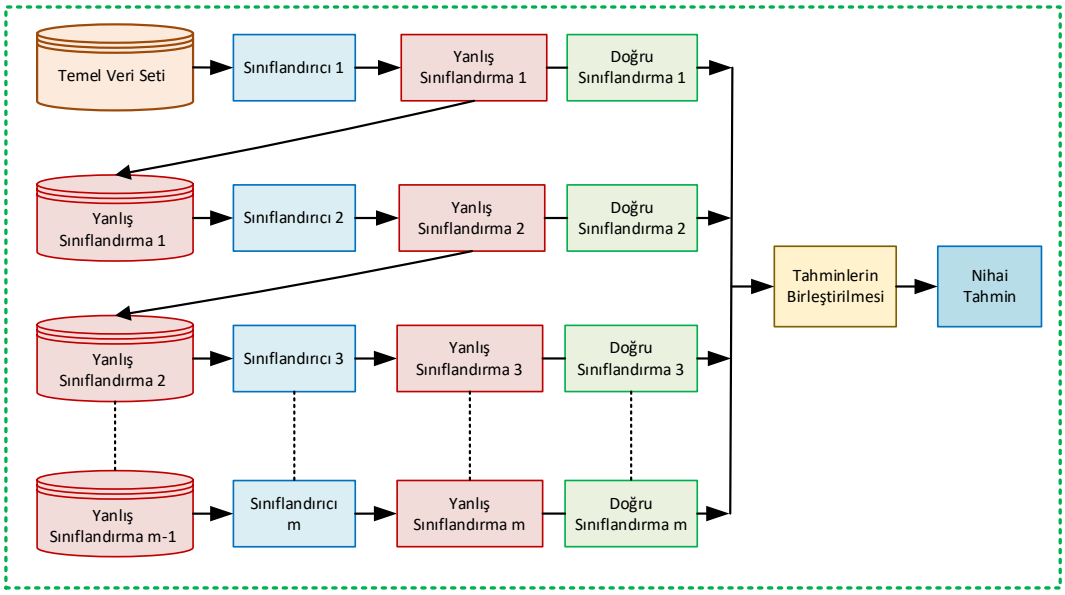


Şekil 5.19. Torbalama yöntemi mimarisi

Güçlendirme (Artırım) yöntemi

Güçlendirme (Artırım) yöntemi ilk olarak Schapire tarafından tahmin doğruluğunu artırmak amacıyla önerilmiştir. Bu yöntem, torbalama yöntemi gibi güçlü bir model oluşturmayı hedefler, ancak izlediği yol farklıdır. Güçlendirme yönteminde, sınıf etiketi olan bir veri setinde her bir örneğe başlangıçta eşit ağırlık değeri atanır. Bu sayede, her örneğin ilk modelin eğitilmesinde kullanılma olasılığı eşit olur. İlk modelde, her örnek için ağırlıklar başlangıçta eşittir. İlk model eğitildikten sonra, modelin hatalı tahmin ettiği örneklerin ağırlıkları artırılırken, doğru tahmin edilen örneklerin ağırlıkları azaltılır. Bu

işlem, hatalı tahmin edilen örneklerin, sonraki modelin eğitilmesinde daha fazla dikkate alınmasını sağlar. Ağırlıkları güncellenmiş örneklerle yeni bir model eğitilir. Bu süreç, her yeni modelin, önceki modelin hatalarını telafi etmesine olanak tanır. Böylece, her yeni model, önceki modellerin performansından etkilenir ve bir sonraki modelin eğitiminde kullanılacak veri seti, önceki modelin başarı veya başarısızlığına bağlı olarak güncellenir [137]. Şekil 5.20'de bu süreçleri gösteren güçlendirme yönteminin mimarisi verilmiştir. Tüm modeller eğitildikten sonra, sınıflandırma için oylama yöntemleri ile modeller birleştirilerek nihai sonuç elde edilir. Bu yöntemin amacı, hataların ve biasın azaltılmasını sağlamaktır.



Şekil 5.20. Güçlendirme (Artırım) yöntemi mimarisi

Güçlendirme yöntemi, her adımda yöntemin tahmin hatalarını vurgular ve bu hataları minimize etmeye çalışır. Bu nedenle güçlendirme yöntemi için AdaBoost, CatBoost gibi algoritmalar geliştirilmiştir. Bu tez çalışmasında güçlendirme yöntemi için AdaBoost algoritması kullanılmıştır.

Güçlendirme yönteminin ilk aşamasında bir veri setindeki her örnek x için bir ağırlık değeri w_i belirlenir. N adet örneğe sahip bir veri setinde her bir örnek için ağırlık değeri Eş. 5.54'de verildiği gibi belirlenmiştir.

$$w_i = \frac{1}{N}, \quad i = 1, 2, \cdots, N \tag{5.54}$$

Bu eşitlikten verildiği gibi başlangıçta tüm ağırlıklar eşit olarak belirlenir. Ağırlıklar belirlendikten sonra zayıf öğretici P_m olan temel veri seti eğitilerek hatalı sınıfların ağırlıkları artırılır. Bu işlem *M* defa tekrar edilir. Her adımda Eş. 5.55'de verilen hata oranı $\in_m$ hesaplanır.

$$\in_m = \sum_{i=1}^{N} w_i \, I\left(y_i \neq P_m(x_i)\right) \tag{5.55}$$

Hesaplanan hata oranı $\in_m$ ile Eş. 5.56'da verilen modelin güven skoru α_m hesaplanır.

$$\alpha_m = \frac{1}{2}\ln\left(\frac{1-\in_m}{\in_m}\right) \tag{5.56}$$

Güven skoru α_m ile ağırlıklar Eş. 5.57'deki gibi güncellenir.

$$w_i = w_i \times e^{-\alpha_m y_i P_m(x_i)} \tag{5.57}$$

Nihai model, zayıf öğrenicilerin ağırlıklı toplamı olarak Eş. 5.58'deki gibi ifade edilir

$$P(c|y_i) = sgn\left(\sum_{m=1}^{M} \alpha_m P_{m(x_i)}\right), \quad i = 1, 2, \cdots, N \tag{5.58}$$

Yığınlama (İstifleme) yöntemi

Yığınlama yöntemi ilk olarak Wolpert tarafından 1992 yılında önerilmiştir. Torbalama ve güçlendirme yöntemleri aynı ML yönteminin sonuçlarını birleştirirken yığınlama yöntemi farklı ML yöntemlerini birleştirmek için kullanılır. Şekil 5.21'de verildiği gibi yığınlama yöntemi, farklı ML yöntemlerinin bir araya getirilmesiyle oluşturulan bir topluluk öğrenme yöntemidir. Yığınlama yönteminde *M* adet farklı ML yöntemi tarafından temel veri seti eğitilir. Bu eğitimlerin sonuçları birleştirilerek yeni veri seti oluşturulur. Meta sınıflandırıcı oluşturulan bu yeni veri setinin eğitilmesi için kullanılan bir ML yöntemidir. Meta sınıflandırıcı nihai tahmini yapar [131, 137].

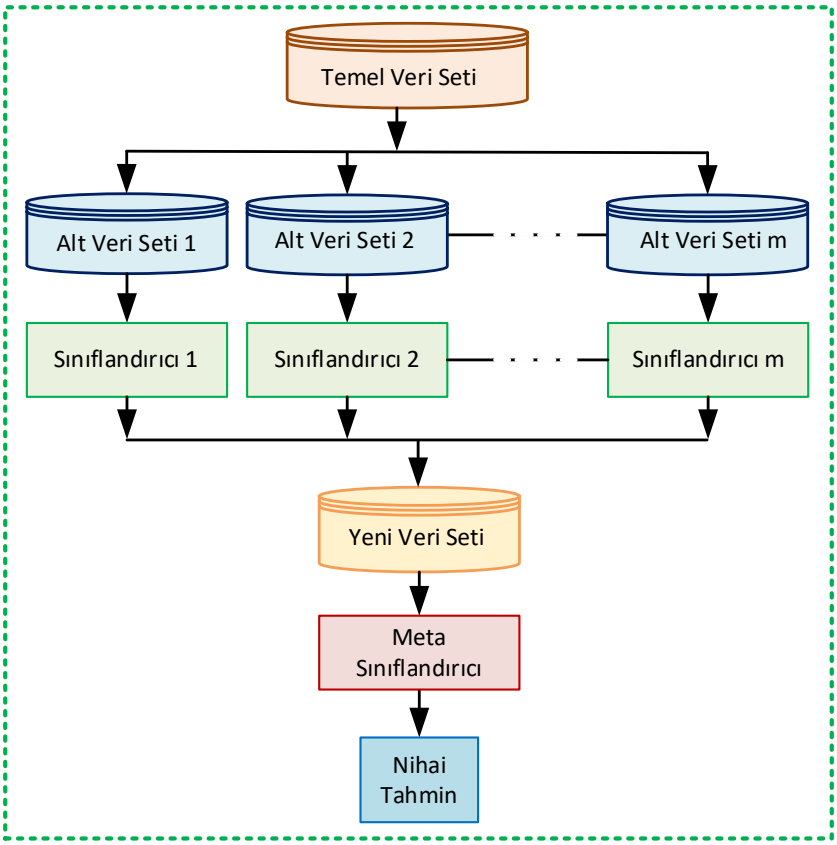
Yığınlama yönteminde *N* adet örneğe sahip temel veri seti farklı *M* adet ML yöntemi ile sınıflandırılır ve $P_m(x)$ çıktıları birleştirilir ve Eş. 5.59'daki gibi yeni bir özellik matrisi oluşturulur.

$$Z(x_i) = [P_1(x_i), P_2(x_i), \cdots, P_m(x_i)\,], i = 1,2, \cdots, N \quad (5.59)$$

Oluşturulan yeni özellik matrisi (yeni veri seti) meta sınıflandırıcı *g(Z)* ile eğitilerek Eş. 5.60'da ifade edildiği gibi nihai tahmin işlemi gerçekleştirilir.

$$\hat{P}(x_i) = \sum_{i=1}^{N} g\big(Z(x_i)\big) \quad (5.60)$$

Yığınlama genellikle doğrusal regresyon, lojistik regresyon veya daha karmaşık modelleri meta-model olarak kullanır.



Şekil 5.21. Yığınlama (İstifleme) yöntemi mimarisi

Bu tez çalışmasında güçlendirilmiş ağaçlar (Boosted trees), torbalanmış ağaçlar (Bagged Trees) ve RUS güçlendirilmiş ağaçlar (RUS boosted trees) topluluk öğrenme yöntemleri kullanılmıştır. Bu üç topluluk öğrenme yönteminde sınıflandırıcı olarak karar ağaçları kullanılmıştır. RUS güçlendirilmiş ağaçlar yönteminin normal güçlendirilmiş ağaçlar yönteminden farkı alt veri setleri oluşturulurken RUS (Random Under Sampling) seçim algoritması kullanılır.

RUS algoritması bir veri setindeki çoğunluk olan verileri azaltarak azınlık verilerle eşitlemeyi amaçlar. *N* adet örneğe ait bir veri setinde çoğunluk verilerin sayısı n_{ma} azınlık verilerin sayısı n_{mi} eşitlenmek istenir. Yeni çoğunluk veri sayısını n'_{ma} olarak tanımlarsak Eş. 5.61'de ifade edildiği gibi azınlık veri sayısı, yeni çoğunluk veri sayısına eşit olur.

$$n'_{ma} = n_{mi} \tag{5.61}$$

Çoğunluk sınıfındaki n_{ma} örneğinden, n'_{ma} sayıda örnek rastgele seçilir. Bu işlem, her örneğin seçilme olasılığı eşit olacak şekilde yapılır. Eş. 5.62'de ifade edildiği gibi çoğunluk sınıfından (C_{ma}) rastgele seçilen yeni çoğunluk örneği S_{RUS} olarak tanımlanır.

$$S_{RUS} = \text{Random}\left(C_{ma}, n'_{ma}\right) \tag{5.62}$$

Azınlık sınıfı örnekleri (C_{mi}) ile rastgele örneklenen çoğunluk sınıfı (S_{RUS}) örnekleri birleştirilir ve yeni bir dengelenmiş veri kümesi oluşturulur. Yeni dengelenmiş veri seti D_{RUS} olarak tanımlanır ve Eş. 5.63'deki gibi ifade edilir.

$$D_{RUS} = C_{mi} \cup S_{RUS} \tag{5.63}$$

Eş. 5.64' de ifade edildiği gibi bu yeni veri kümesinde, çoğunluk ve azınlık sınıfı örneklerinin sayıları eşittir.

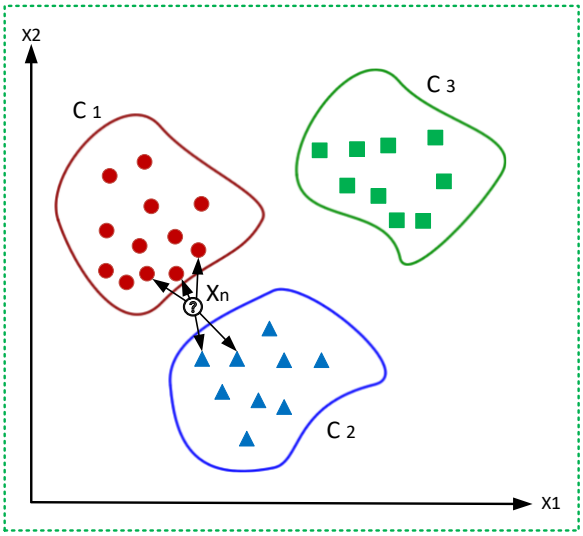
$$|C_{mi}| = |S_{RUS}| = n'_{ma} = n_{mi} \tag{5.64}$$

RUS algoritması basit ve hızlı bir yöntemdir. Veri kümesindeki dengesizliği azaltarak sınıflandırıcıların daha dengeli bir performans göstermesini sağlar. Ancak çoğunluk sınıfından rastgele örnekler çıkarıldığı için bazı önemli örnekler kaybolabilir. Bu ise modelin genelleme yeteneğini olumsuz etkileyebilir. Azınlık sınıfı ile sınırlı veri üzerinde çalışan model, aşırı uyuma daha yatkın hale gelebilir.

5.4.6. K-En Yakın Komşu

K-En Yakın Komşu (KNN), en basit ve en yaygın kullanılan sınıflandırma yöntemlerinden biridir. KNN yönteminde bir veri setindeki örnekler sınıf etiketine sahip öznitelik vektörlerinden oluşmaktadır. KNN yönteminin eğitim aşamasında öznitelik vektörleri ve hedef değişkenin sınıf etiketleri kullanılır [111]. Veri setine yeni bir örnek eklendiğinde tüm veri seti kullanılarak eğitim işlemi gerçekleştirilir ve özellik vektörleri belirlenir. Bu sınıflandırma algoritmasının temelinde, veri setinden oluşturulan örnek uzayda birbirine yakın olan örnekler muhtemelen aynı sınıfa aittir düşüncesi yer almaktadır. Sınıflandırma aşamasında kullanıcı tarafından K sabiti tanımlanır, yeni örneğin bulunduğu konuma en yakın K adet örneğin arasında en sık görülen sınıf etiketi yeni örneğin sınıfı olarak belirlenir. KNN algoritması, eğitim veri setindeki örneklerin sınıflandırılmasında yakınlık ilkesini kullanır. Bir veri noktasının hangi sınıfa ait olduğunu belirlemek için, bu veri noktasına en yakın K adet veri noktasının sınıfları incelenir ve çoğunluk sınıfı seçilir [111, 138].

Şekil 5.22'de bir veri setinin yeni örneği x_n için KNN sınıflandırma modeli verilmiştir. Bu veri setinde C_1, C_2 ve C_3 olmak üzere üç sınıf vardır. K değeri ise 5 olarak belirlenmiştir. C_1, C_2 ve C_3 sınıflarındaki en yakın beş komşu belirlenmiştir. Bu en yakın 5 komşudan 3'ü C_1 sınıfında, 2 tanesi ise C_2 sınıfında bulunmaktadır. Çoğunluk ilkesi gereği yeni örnek x_n C_1 sınıfına dahil edilir [139].

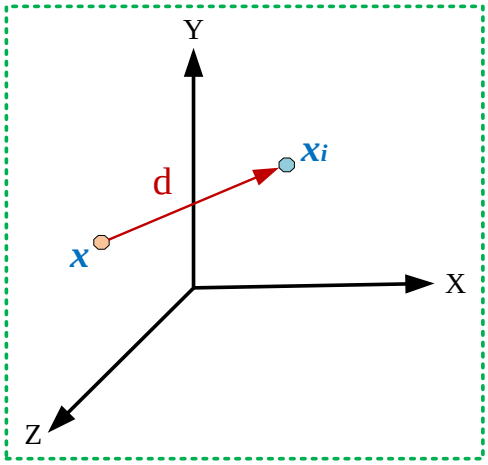


Şekil 5.22. KNN sınıflandırma modeli

Bunun gibi yeni yapılan sınıflandırma işlemlerinde *K* adet en yakın örnek noktası belirlenirken iki nokta arazındaki mesafe Öklid (Euclidean) mesafesi, Manhattan mesafesi, Minkowski mesafesi, Chebyshev mesafesi ve kosinüs benzerliği gibi en yaygın kullanılan mesafe metrikleri ile belirlenir [111,139].

Öklid mesafesi

Şekil 5.23'de gösterilen Öklid mesafesi iki nokta arasındaki mesafenin ölçümü için en sık kullanılan mesafe ölçüsüdür. Öklid mesafesi Eş. 5.65'de gösterildiği gibi ifade edilir [111,139].



Şekil 5.23. İki nokta arasındaki Öklid mesafesi

$$d(x, x_i) = \sqrt{\sum_j^n (x_j - x_{ij})^2} \tag{5.65}$$

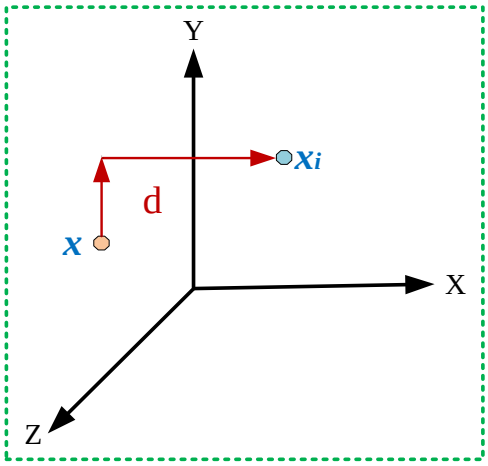
Bu eşitlikte;

- $x=(x_1,x_2,\ldots,x_n)$ test veri noktası (yeni örnek)
- $x_i=(x_{i1},x_{i2},\ldots,x_{in})$ eğitim veri setindeki veri noktası(mevcut örnekler)
- n: veri setindeki örnek sayısı
- $d(x, x_i)$: Test veri noktası x ile eğitim veri setindeki x_i arasındaki mesafe.

Manhattan mesafesi

Adını birbirini dik kesen cadde yapılaşmasına sahip Manhattan şehrinden almıştır. Manhattan şehrinde iki nokta arasında yatay ve dikey yollar takip edilerek gidilmektedir.

Bu mantıktan hareketle iki nokta arasındaki Manhattan mesafesi Şekil 5.24 de verilmiştir. İki nokta arasındaki mesafe Eş. 5.66'da verildiği gibi sadece yatay ve dikey uzaklıkların mutlak değer toplamlarına bakılarak hesaplanır [111, 139].

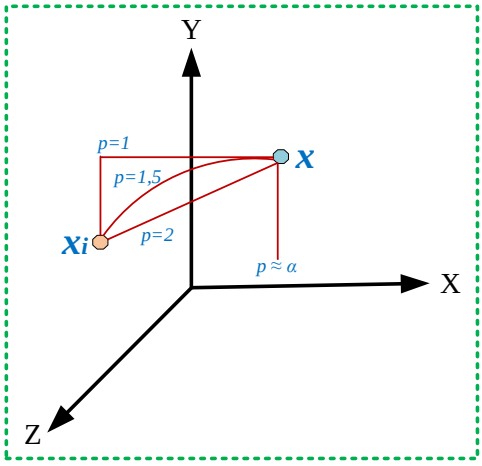


Şekil 5.24. İki nokta arasındaki Manhattan mesafesi

$$d(x, x_i) = \sum_{j=1}^{n} |x_j - x_{ij}| \quad (5.66)$$

Minkowski mesafesi

Şekil 5.25'de verilen Minkowski mesafesi (p) ölçümü örnek sayısı n olan bir veri setinin aynı boyuttaki diğer bir veri setinin örnekleri ile bire bir mesafelerinin ölçümüne dayanır. Minkowski mesafe ölçümü, iki veri noktası arasındaki mesafeyi, bu noktalar arasındaki farkların mutlak değerlerinin bir kuvvetiyle hesaplar. Eş. 5.67'de verilen formülde kuvvet p parametresi ile belirtilir. Daha sonra, bu kuvvetin toplamı alınır ve bu toplamın p'inci kökü hesaplanır. $p=1$ olduğunda, Minkowski mesafesi Manhattan mesafesine dönüşür. Bu durumda, iki nokta arasındaki mesafe, mutlak farkların toplamı olarak hesaplanır. Yani, koordinat düzlemi üzerindeki yolun uzunluğu gibi düşünülebilir. $p=2$ olduğunda ise Minkowski mesafesi Öklid mesafesine dönüşür. Bu durumda, iki nokta arasındaki mesafe, farkların karelerinin toplamının karekökü olarak hesaplanır. Yani, düz bir çizgi boyunca olan en kısa mesafe gibi düşünülebilir. p değeri daha büyük olduğunda, Minkowski mesafesi daha büyük farklara daha fazla ağırlık verir. p sonsuza yaklaştığında, bu mesafe, Chebyshev mesafesi olarak bilinen maksimum farkı temsil eder.

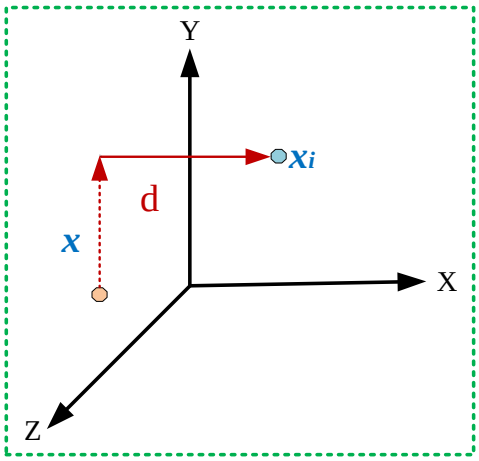


Şekil 5.25. İki nokta arasındaki Minkowski mesafesi

$$d(x, x_i) = \left(\sum_{j=1}^{n} \left|x_j - x_{ij}\right|^p\right)^{\frac{1}{p}}, \quad p \geq 1 \tag{5.67}$$

Chebyshev mesafesi

Chebyshev mesafesi satranç tahtasında herhangi bir yerdeki şahın gidebileceği yerin mesafesinin hesaplanmasına dayanmaktadır. Şekil 5.26'da verilen Chebyshev mesafesi ise iki nesne koordinatları arasındaki farkın mutlak büyüklüğünü dikkate alır. Bu uzaklık ölçüsüne maksimum değer uzaklığı da denir. Bu uzaklık metriği hem sıralı hem de niceliksel değişkenler için kullanılabilir. Eş. 5.68'deki gibi ifade edilir [111,139].

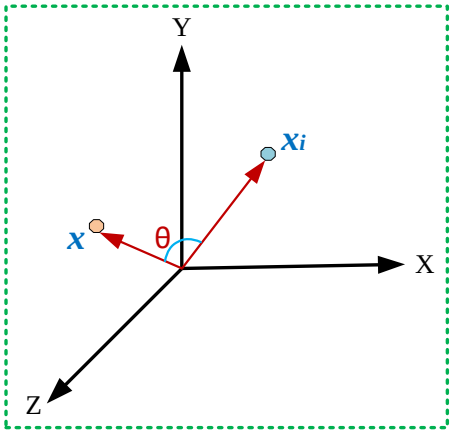


Şekil 5.26. İki nokta arasındaki Chebyshev mesafesi

$$d(x, x_i) = \max_{1 \leq j \leq n} \left|x_j - x_{ij}\right| \tag{5.68}$$

Kosinüs benzerliği

Kosinüs benzerliği bir mesafe ölçütü olarak değil, iki vektör arasındaki açıyı ölçer. Bu nedenle, Kosinüs benzerliği, mesafe yerine benzerlik ölçütü olarak kullanılır. Şekil 5.27'de bir veri setindeki örneğin vektörü ile yeni örneğin vektörü arasındaki θ açısı gösterilmektedir. Kosinüs benzerliği bu θ açısı kullanılarak Eş. 5.69'daki gibi hesaplanır.



Şekil 5.27. Kosinüs benzerliği modeli

$$\cos\theta = \cos(x, x_i) = \frac{\sum_{j=1}^{n} x_j \cdot x_{ij}}{\sqrt{\sum_{j=1}^{n} x_j{}^2} \cdot \sqrt{\sum_{j=1}^{n} x_{ij}{}^2}} \tag{5.69}$$

Kosinüs benzerliği, [−1,1] aralığında bir değer alır. Sonucun 1 olması, iki vektörün tamamen aynı olduğu anlamına gelir; sonucun -1 olası ise tam ters yönde oldukları anlamına gelir.

Bu tez çalışmasında KNN yönteminin türlerinden ince KNN, orta KNN, kalın KNN, kosinüs KNN, kübik KNN ve ağırlıklı KNN kullanılmıştır.

İnce (Fine) KNN

K değeri küçük olan KNN türüdür. Genellikle *K* değeri 1'e eşittir. Bu nedenle de mesafe metriği olarak genellikle Öklid mesafe yöntemi kullanılır. Bu tez çalışmasında *K* değeri 1 olarak alınmıştır, mesafe metriği olarak da Öklid mesafe yöntemi kullanılmıştır.

Orta (Medium) KNN

K değeri orta büyüklükte olan KNN türüdür. Genellikle *K* değeri 10'a eşittir. Mesafe Metriği olarak genellikle Öklid mesafe veya Manhattan mesafe yöntemleri kullanılır. Bu tez çalışmasında *K* değeri 10 olarak alınmıştır, mesafe metriği olarak da Öklid mesafe yöntemi kullanılmıştır.

Kalın (Coarse) KNN

K değeri büyük olan KNN türüdür. Genellikle *K* değeri 100'e eşittir. Mesafe Metriği olarak genellikle Öklid mesafe yöntemleri kullanılır. Bu tez çalışmasında *K* değeri 100 olarak alınmıştır, mesafe metriği olarak da Öklid mesafe yöntemi kullanılmıştır.

Kosinüs (Cosine) KNN

Kosinüs benzerliğini kullanan KNN türüdür. Bu tez çalışmasında *K* değeri 10 alınarak gerçekleştirilmiştir.

Kübik (Cubic) KNN

Minkowski mesafe metriğinde p değeri 3 alınarak gerçekleştirilen KNN türüdür. Eş. 5.70'deki gibi ifade edilir. Bu tez çalışmasında *K* değeri 10 olarak alınmıştır.

$$d(x, x_i) = \sqrt[3]{\sum_{j=1}^{n} \left| x_j - x_{ij} \right|^3}, p \geq 1 \tag{5.70}$$

Ağırlıklı (Weighted) KNN

Komşuların sınıflandırma işlemlerinde farklı ağırlıklar kullanılır. Ağırlık fonksiyonu Eş. 5.71'de verilmiştir. Ağırlık değerleri özellik vektörleri arasındaki mesafe ile ters orantılı olarak verilir. Bu tez çalışmasında *K* değeri 10 olarak alınmıştır, mesafe metriği olarak da Öklid mesafe yöntemi kullanılmıştır.

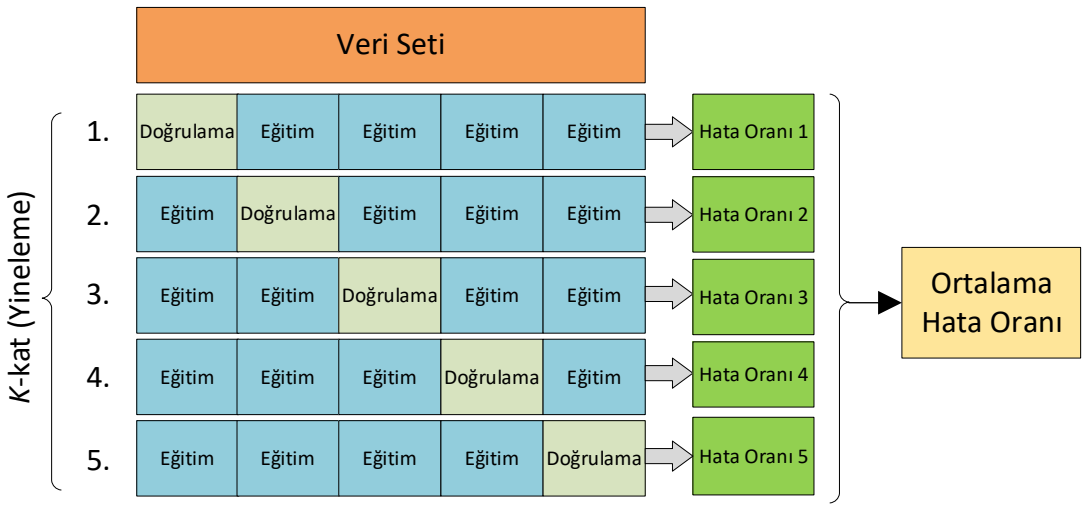
$$\hat{y} = \underset{1 \le i \le K}{\operatorname{argmax}} \sum_{j=1}^{n} \frac{y_i}{d(x_j, x_{ij})} \tag{5.71}$$

Bu eşitlikte;

- $\hat{y}$: Tahmin edilen sınıf etiketi
- y_i: komşuların sınıf etiketleridir.

5.4.7. K-katlı çapraz doğrulama

K-kat çapraz doğrulama (*K*-fold cross validation), ML modellerinin genelleme yeteneğini değerlendirmek için yaygın olarak kullanılan bir doğrulama yöntemidir. Bu yöntem, veri setini farklı alt kümelere bölerek her bir alt küme için modelin performansını ölçmeye olanak tanır. Çapraz doğrulamada, veri seti *k* ile ifade edilen sayı kadar parçaya ayrılır. Daha sonra her adımda *k-1* adet parça ML algoritmasında eğitim verisi olarak kullanılır ve kalan *1* parça ise doğrulama verisi olarak kullanılır. Bu işlem *k* kez tekrar edilir. Her adımda doğrulama verisi için veri setinin daha önce kullanılmamış bir kısım seçilir. Her adım sonunda elde edilen hata değerlerinin ortalaması alınarak, modelin toplam hata değeri elde edilir. Şekil 5.28 incelendiğinde *k* değerinin *5* seçildiği ve veri setinin *5* parçaya ayrıldığı görülmektedir. Her adımda farklı bir parçanın test seti olarak kullanıldığı ve Eş. 5.72'de elde edilen hataların ortalaması toplam hatayı (*E*) yani performansı vermektedir. Eş. 5.73'de gösterildiği gibi sistemin doğruluk oranı (A_c) bu hatadan elde edilir.



Şekil 5.28. *K*-kat çapraz doğrulama

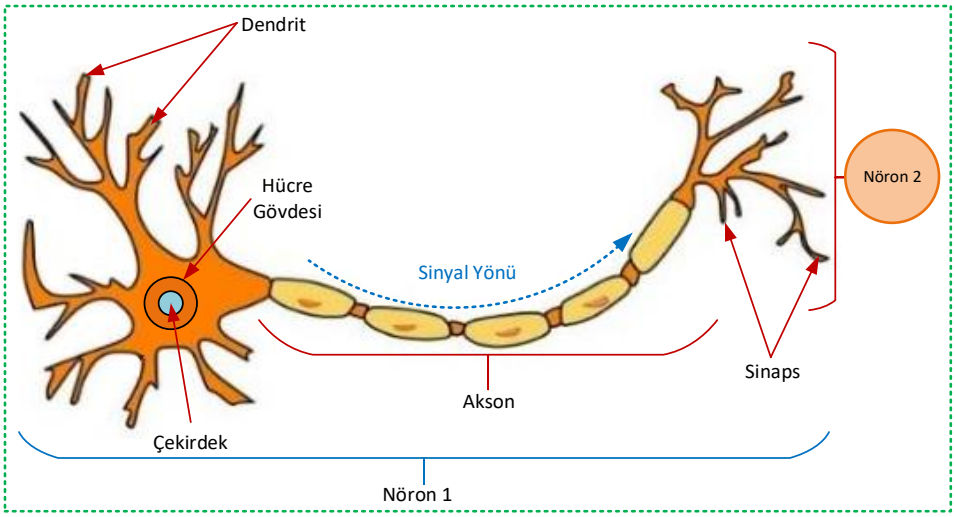
$$E = \frac{1}{K}\sum_{i=1}^{K} E_i \tag{5.72}$$

$$Ac = 1 - E \tag{5.73}$$

K-kat çapraz doğrulama, modelin eğitim ve doğrulama aşamalarında nasıl performans gösterdiğini daha doğru bir şekilde değerlendirmek için kullanılan güçlü bir yöntemdir. Bu yöntem, modelin farklı veri alt kümeleri üzerindeki performansını ölçerek, aşırı uyum ve yetersiz uyum gibi problemlerin önüne geçmeyi hedefler. Daha önce anlatılan ve bu tez çalışmasında kullanılan ML yöntemlerinde 5-kat çapraz doğrulama yöntemi seçilmiştir [112, 140,141].

5.4.8. Yapay sinir ağları

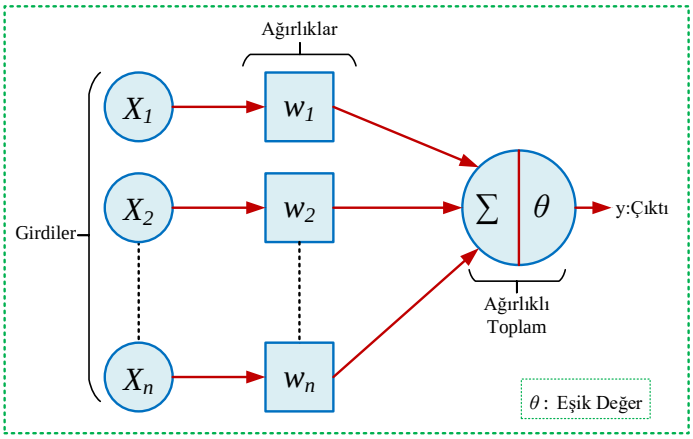
Yapay sinir ağları (YSA), insan beyninin biyolojik sinir ağlarının çalışma prensibini matematiksel olarak modellemeyi amaçlayan ML algoritmasıdır. Bu ağlar, biyolojik sinir ağlarının öğrenme, hatırlama, genelleme ve karar verme kabiliyetlerini taklit ederek, önceden öğrenilmiş veya sınıflandırılmış veri setlerini kullanarak yeni bilgiler üretebilir ve karar verebilir. Biyolojik sinir ağları, yapay sinir ağlarının temel ilham kaynağıdır. Beyindeki sinir ağlarının temel birimi, nöronlardır. Şekil 5.29'da gösterilen biyolojik nöronlar dendritler, hücre gövdesi, akson ve sinapslar gibi bileşenlerden oluşur [110, 142-144].



Şekil 5.29. Biyolojik nöronun şematik gösterimi

Dendritler, diğer nöronlardan gelen kimyasal ve elektriksel sinyalleri alır. Bu sinyaller yeterince güçlü olduğunda ve belirli bir eşik değerini aştığında, nöron aktive olur ve akson aracılığıyla bu sinyali yayar. Sinapslar, bu sinyali diğer nöronlara aktarır. YSA'da ise bu süreç, ağırlık adı verilen faktörlerle çarpılan ve nöronun aktivasyonunu belirleyen matematiksel fonksiyonlarla basitleştirilmiş bir şekilde modellenir. İnsan beyninde olduğu gibi, YSA da birbirine bağlı binlerce düğümden (veya nörondan) oluşur. Bu düğümler, öğrenme sürecinde elde edilen verilerin analiz edilmesi ve bir görevin yerine getirilmesi için kullanılır. Yapay nöronlar, gerçek nöronlardan esinlenerek geliştirilmiş hesaplamalı modellerdir, ancak biyolojik nöronların karmaşıklığı oldukça azaltılarak basit bir matematiksel modelle temsil edilirler. Sonuç olarak, YSA, insan beyninin biyolojik sinir ağlarının işleyişini temel alan güçlü bir ML yöntemidir. Bu ağlar, verilerin analiz edilmesi ve sınıflandırılması için kullanılmaktadır [142-144].

Eşik değer modeli (Threshold Logic Unit), YSA'nın en temel formu olarak kabul edilir ve 1943 yılında Warren McCulloch ve Walter Pitts tarafından geliştirilmiştir. Bu model, biyolojik sinir hücrelerinin çalışma prensibini taklit eden basit modeldir. Şekil 5.30'da verilen eşik değer modeli, basit bir doğrusal sınıflandırıcıdır. Bu modelde veri seti, örneklerini temsil eden girdi vektörleri (x_1, x_2, ..., x_n) ve bu girdi vektörlerine ait ağırlıklar (w_1, w_2, ..., w_n) ile tanımlanır. Bu model, Eş. 5.74'de verildiği gibi bir ağırlıklı toplamı hesaplar ve sonucu bir θ eşik değeri ile karşılaştırarak sınıflandırma yapar. Eşik değer modeli, doğrusal bir aktivasyon fonksiyonu kullanır ve bu fonksiyon sonucu 0 ve 1 olmak üzere sadece iki sınıfa ayırır. Sonuç eşik değerden büyük eşit ise çıktı 1, küçük ise çıktı 0'a eşit olur [112].



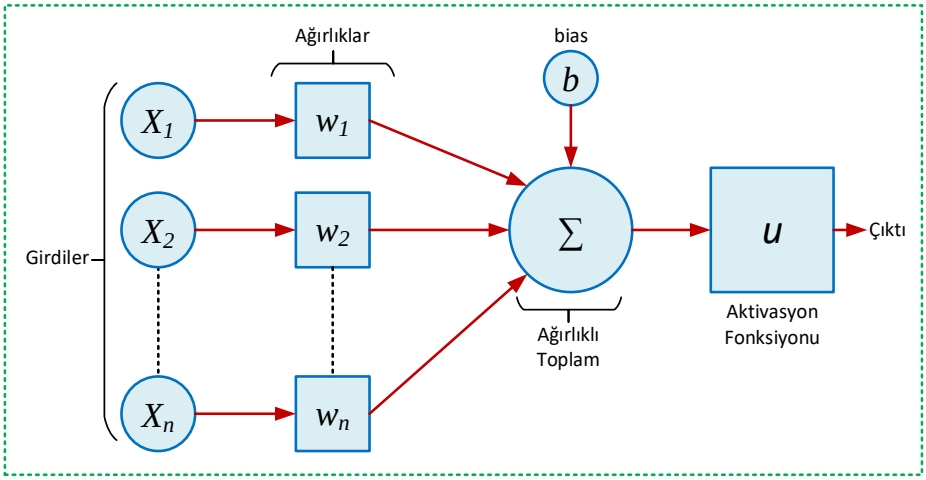
Şekil 5.30. YSA eşik değer modeli

$$y = \begin{cases} 1 & ; \quad \sum_{i=1}^{n} w_i \cdot x_i \geq \theta \; ise \\ 0 & ; \quad \sum_{i=1}^{n} w_i \cdot x_i < \theta \; ise \end{cases} \tag{5.74}$$

Bu eşitlikte;

- y: Çıktı (sınıf etiketi)
- x: Girdi vektörü
- w: Ağırlık vektörü
- θ: Eşik değeridir.

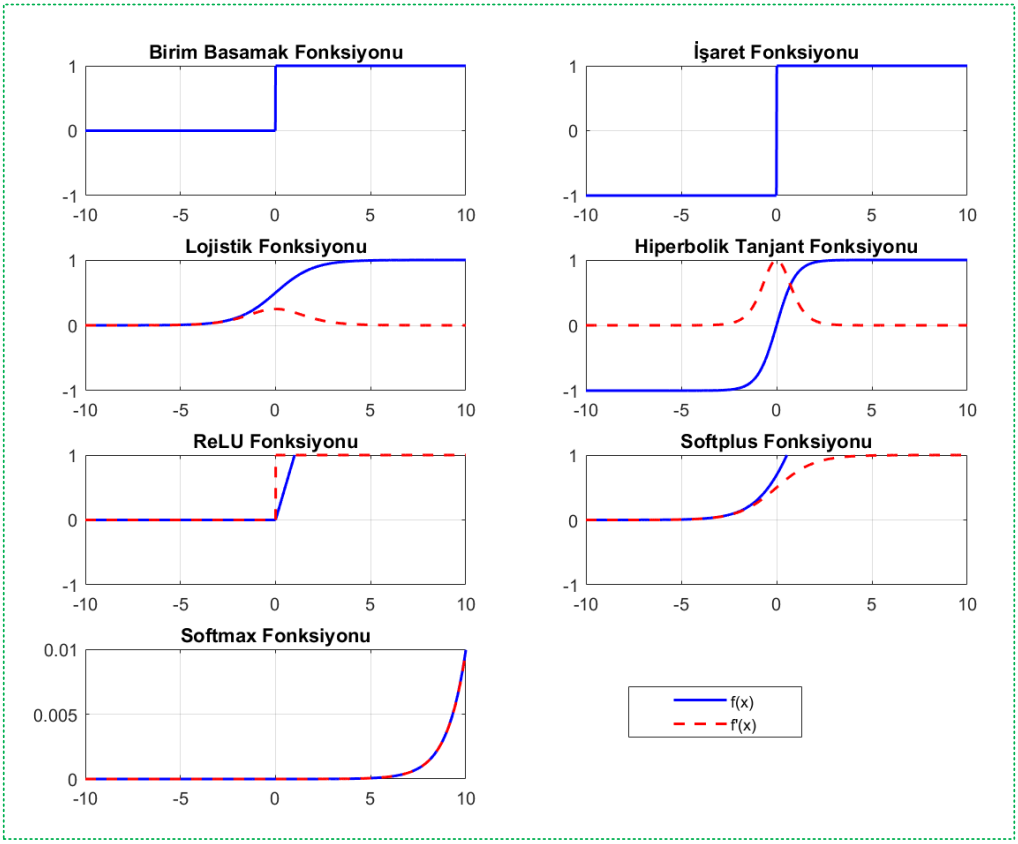
Donald Hebb'in 1949 yılındaki biyolojik nöronlar hakkındaki tezine göre iki nöron arasındaki bağlantı her iki tarafındaki nöronlar aynı anda etkileşirse nöronlar arasındaki bağ güçlenir. Bu aktivite öğrenme ve hafıza için gerçekleşen sürecin önemli bir parçasını oluşturmaktadır. Biyolojik nöronlar hakkında Hebb tarafından ortaya atılan bu tez, Rosenblatt tarafından, eşik değer modelinde kullanılmıştır ve Perceptron modeli geliştirilmiştir. Şekil 5.31'de verilen Perceptron modeli öğrenen bir yapay sinir ağı modelidir. Perceptron modelinde, öncelikle ağırlıklı toplamın hesaplanması gereklidir. Bunun için girdiler (x) ve girdilere ait ağırlıkların (w) çarpımları toplanır ve bu toplama bias (b) değeri ilave edilerek Eş. 5.75'de gösterildiği gibi ağırlıklı toplam u elde edilir. Daha sonra bu toplam değeri bir aktivasyon fonksiyonundan ($f(u)$) geçirilir. Aktivasyon fonksiyonunun temel görevi ağırlıklı toplam değerini belirlenen eşik değerine göre sınıflandırmaktır [112].



Şekil 5.31. Perceptron YSA modeli

$$u = \sum_{i=1}^{n} w_i \cdot x_i + b \tag{5.75}$$

Aktivasyon fonksiyonu ağırlıklı toplam değeri belirlenen eşik değere göre sınıflandırmak için kullanılır. Sınıflandırma problemlerinde Şekil 5.32'de gösterilen aktivasyon fonksiyonları kullanılır.



Şekil 5.32. YSA sınıflandırma modelleri için aktivasyon fonksiyonları ve türevleri

Birim basamak aktivasyon fonksiyonu

Eş. 5.76'da verilen birim basamak aktivasyon fonksiyonu ikili sınıflandırma uygulamalarında sıklıkla kullanılır. Gizli katmanlarda basamak fonksiyonun türevi öğrenme değeri olmadığı için kullanılması tavsiye edilmez. Özellikle bir girişin belirli bir eşik değerini geçip geçmediğini belirlemek için tek katmanlı Perceptron uygulamalarında kullanılır [110].

$$f(u) = \begin{cases} 1 & ; \quad u \geq 0 \; ise \\ 0 & ; \quad u < 0 \; ise \end{cases} \tag{5.76}$$

Birim basamak aktivasyon fonksiyonunun türevi, sürekli olmadığı için belirli bir formu yoktur. Genellikle basit sınıflandırma problemlerinde kullanılır.

İşaret aktivasyon fonksiyonu

Bu fonksiyonun türevi de sürekli olmadığı için belirli bir formu yoktur. Pozitif ve negatif değerlerin ayrımını yapan uygulamalarda kullanılmaktadır. Eş. 5.77'de işaret aktivasyon fonksiyonu verilmiştir.

$$f(u) = \begin{cases} 1 & ; \quad u > 0 \quad ise \\ 0 & ; \quad u = 0 \quad ise \\ -1 & ; \quad u < 0 \quad ise \end{cases} \tag{5.77}$$

Lojistik (Sigmoid) aktivasyon fonksiyonu

Sigmoid olarak da isimlendirilen bu aktivasyon fonksiyonu özellikle iki sınıflı sınıflandırma problemlerinde kullanılır ve aldığı değerleri 0 ve 1 arasında tutar ve bu fonksiyon doğrusal değildir. Türevlenebilir bir fonksiyon olması sebebiyle yüksek bir değer geldiğinde 1'e yakın olurken, düşük bir değer geldiğinde 0'a yakın olur. Bu durumda 1'i ve 0'ı geçen bir değer almaz [110]. Eş. 5.78'de lojistik aktivasyon fonksiyonu, Eş. 5.79'da ise bu fonksiyonun türevi verilmiştir.

$$f(u) = \frac{1}{1+e^{-u}} \tag{5.78}$$

$$f'(u) = f(u)\big(1 - f(u)\big) \tag{5.79}$$

Hiperbolik tanjant aktivasyon fonksiyonu

Hiperbolik tanjant aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonuna çok benzer. İki aktivasyon fonksiyonunda da sıkıştırma bulunur fakat *tanh* fonksiyonu oluşan değerleri [-1,1] aralığında tutar. Hiperbolik tanjant aktivasyon fonksiyonunda Sigmoid aktivasyon fonksiyonuna göre 0 odaklı olduğundan daha iyi sonuçlar elde edilebilir. Sigmoid fonksiyonuna göre avantajı ise türevinin daha yüksek değerler almasıdır. Bu durum daha hızlı öğrenme ve sınıflama işlemi için daha geniş aralığa sahip olmasına neden olur. Geniş aralığa sahip olması daha verimli olmasını sağlar [110]. Eş. 5.80'de hiperbolik tanjant aktivasyon fonksiyonu, Eş. 5.81'de ise bu fonksiyonun türevi verilmiştir.

$$f(u) = tanh(u) = \frac{e^{u}-e^{-u}}{e^{u}+e^{-u}} \tag{5.80}$$

$$f'(u) = 1 - tanh^{2}(u) \tag{5.81}$$

ReLU aktivasyon fonksiyonu

ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, ML modellerinde en yaygın kullanılan aktivasyon fonksiyonlarından biridir. En önemli özelliği, biyolojik nöronların çalışma prensibine benzer olmasıdır. ReLU aktivasyon fonksiyonu, giriş değerinin pozitif veya negatif olup olmadığını kontrol eder. Eğer giriş değeri negatifse, çıktı sıfır olur; pozitifse, değeri olduğu gibi geçirir, yani herhangi bir sıkıştırma veya değişiklik uygulamaz. ReLU'nun bu basitliği, onu hiperbolik tanjant veya lojistik aktivasyon fonksiyonlarına kıyasla bilgisayarlar için çok daha hızlı hesaplanabilir hale getirir. Bu fonksiyon, nöronun sadece pozitif veya negatif olup olmadığını kontrol eder, karmaşık hesaplamalara gerek duymaz. Bu nedenle, ReLU fonksiyonu hesaplama açısından oldukça verimlidir ve bu nedenle sıkça tercih edilir. ReLU, genellikle iyi bir tahmin edici olarak çalışır; ancak, "nöron ölümü" adı verilen bir problem de meydana gelebilir. Bu durumda, nöronun çıktısı sürekli olarak sıfır olur ve bu nöron işlevini yitirir. Bununla birlikte çok katmanlı yapılarda sıklıkla tercih edilmektedir [110]. Eş. 5.82'de ReLU aktivasyon fonksiyonu, Eş. 5.83'de ise bu fonksiyonun türevi verilmiştir.

$$f(u) = \begin{cases} u & ; \quad u \geq 0 \quad ise \\ 0 & ; \quad u < 0 \quad ise \end{cases} \tag{5.82}$$

$$f'(u) = \begin{cases} 1 & ; \quad u > 0 \quad ise \\ 0 & ; \quad u \leq 0 \quad ise \end{cases} \tag{5.83}$$

Softmax aktivasyon fonksiyonu

Sınıflayıcı olarak kullanıldığında oldukça iyi bir performans sergiler. En önemli özelliği ikiden fazla sınıflama yapılması gereken durumlarda sıklıkla tercih edilirler. 0-1 aralığında değerler üreterek girdinin belirli sınıfa ait olma olasılığının belirlenmesini sağlar. Böylece olasılıksal bir yorumlama gerçekleştirir [110]. Eş. 5.84'de softmax aktivasyon fonksiyonu, Eş. 5.85'de ise bu fonksiyonun türevi verilmiştir.

$$f(u) = \frac{e^u}{\sum_{i=1}^{C} e^{ui}} \tag{5.84}$$

$$f'(u) = f(u) \cdot (1 - f(u)) \tag{5.85}$$

Softplus aktivasyon fonksiyonu

Softplus fonksiyonu, sigmoid fonksiyonuna benzer ve ReLU'nun yumuşatılmış bir versiyonudur. Genellikle, negatif girdiler için sıfır olmayan, ancak pozitif bir eğime sahip bir çıktı sağlar. Softplus ReLU'dan farklı olarak türevlenebilirliği sağlamak için kullanılan bir fonksiyondur. Softplus, girdiyi yumuşak bir şekilde pozitif değere taşır. ReLU'dan farklı olarak, türevi her zaman pozitiftir, bu da küçük gradyan sorunlarını azaltır. Eş. 5.86'da softplus aktivasyon fonksiyonu, Eş. 5.87'de ise bu fonksiyonun türevi verilmiştir.

$$f(u) = \log(1 + e^u) \tag{5.86}$$

$$f'(u) = \frac{1}{1+e^{-u}} \tag{5.87}$$

Hata oranı

Perceptron YSA modelinde ağırlıklı toplam değerleri aktivasyon fonksiyonuna uygulandıktan sonra ağın ürettiği hata değeri hesaplanır. Modelin yaptığı tahminler ile gerçek etiketler arasındaki fark hesaplanır. Bu fark, hata olarak adlandırılır. Hata fonksiyonu, modelin ne kadar doğru tahmin yaptığını gösterir. Sınıflandırma problemlerinde en sık kullanılan hata fonksiyonu Eş. 5.88'de gösterilen çapraz entropi hata fonksiyonudur.

$$L = -\sum_{i=1}^{n} y_i \cdot \log(\hat{y}_i) \tag{5.88}$$

Bu eşitlikte;

- L: Ağın hata oranı
- y_i: Gerçek sınıf etiketi (1 veya 0)
- $\hat{y}_i$: Tahmin edilen olasılıkdır.

Geri yayılım

Geri yayılım, hata oranının her bir ağırlığa katkısını hesaplamak için kullanılır. Geri yayılım süreci, ağırlık ve bias değerlerinin nasıl güncelleneceğini belirlemek için gradyanların (duyarlılık) hesaplanmasını içerir [142]. Geri yayılım işlem dört adımda gerçekleşir

- İleri yayılım: Girdiler ağın katmanlarından geçer ve her nöronda aktivasyon fonksiyonları uygulanarak çıktı hesaplanır.
- Hata oranı hesaplama: Çıktı katmanındaki hata oranı, hata fonksiyonu kullanılarak hesaplanır.
- Gradyan hesaplama: Hata fonksiyonunun her bir ağırlığa göre türevleri hesaplanır. Bu türevler, hata fonksiyonunun ağırlıklara duyarlılığını (gradyanını) gösterir.
- Geri yayılım: Hesaplanan gradyanlar, zincir kuralı kullanılarak geri yayılır. Yani, her bir katmandaki hata, bir önceki katman için hesaplanır ve bu süreç, giriş katmanına kadar devam eder.

Ağırlık Güncellemesi

Gradyanlar hesaplandıktan sonra, ağırlıklar gradyan inişi algoritması kullanılarak güncellenir. Gradyan inişi, hata fonksiyonunu minimize etmek için ağırlıkları küçük adımlarla günceller. Bu adımlar, öğrenme oranı (γ) adı verilen bir parametre ile kontrol edilir. Öğrenme oranı ağırlıkların ne kadar güncelleneceğini belirleyen sabit bir değerdir. Küçük bir öğrenme oranı yavaş ama daha stabil bir öğrenme sağlar, büyük bir öğrenme oranı ise daha hızlı ama dengesiz bir öğrenme sağlayabilir. Eş. 5.89'da ağırlık güncelleme fonksiyonu verilmiştir [142].

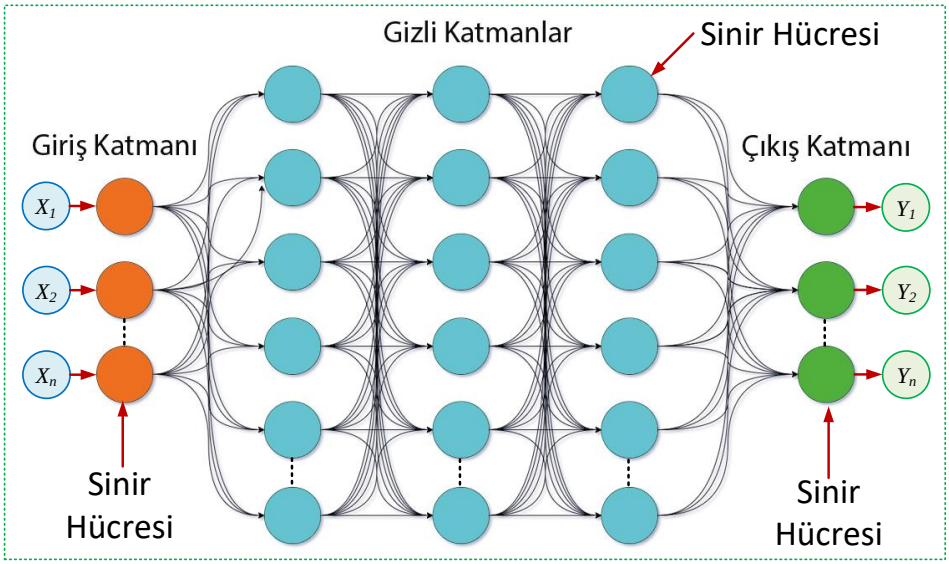
$$w_i \leftarrow w_i - \gamma \frac{\partial L}{\partial w_i} \tag{5.89}$$

Bu eşitlikte;

- w_i: Güncellenen ağırlık
- γ: Öğrenme oranı
- $\frac{\partial L}{\partial w_i}$: Hata fonksiyonunun w_i ağırlığına göre gradyanıdır (türevidir).

Ağırlıklar, her bir ileri ve geri yayılım adımından sonra güncellenir. Bu süreç, eğitim verisindeki tüm örnekler için tekrarlandığında, modelin ağırlıkları optimum değerlere yakınsar. Bu işlem, belirli bir epoch (tüm veri seti üzerinden geçiş) sayısı boyunca tekrarlanır. Bu süreç, modelin hata fonksiyonunu minimize ettiği nokta olan optimum ağırlıkları bulana kadar devam eder. Ağırlıkların bu şekilde güncellenmesi, modelin öğrenmesini ve veri üzerindeki performansının artırmasını sağlar. Ağırlık güncelleme süreci, yapay sinir ağlarının öğrenmesinin merkezinde yer alır. Hata hesaplama, geri yayılım ve gradyan inişi kullanılarak yapılan bu güncellemeler, modelin hata fonksiyonunu minimize ederek daha doğru tahminler yapmasını sağlar. Bu sürecin doğru bir şekilde uygulanması, modelin başarısında kritik bir rol oynar.

YSA katman sayılarına göre de kategorize edilebilir. Sadece giriş katmanı ve çıkış katmanından meydana gelen yapay sinir ağı modelleri tek katmanlı sinir ağları olarak ifade edilebilir. Girdi katmanı ve çıktı katmanı arasına gizli katmanlar eklendiğinde oluşan yapay sinir ağı mimarisi, çok katmanlı sinir ağları olarak ifade edilir. Eğer sadece bir tane gizli katman var ise basit sinir ağları adını alırken iki veya daha fazla gizli katman var ise son zamanlarda ön plana çıkan derin sinir ağları adını alır. Şekil 5.33'de derin sinir ağı mimarisi görülmektedir [110].

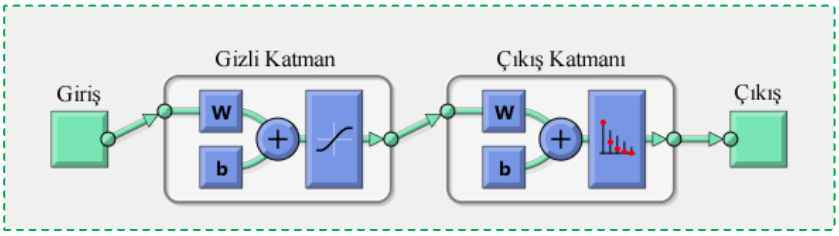


Şekil 5.33. Derin sinir ağı mimarisi

Bu mimari giriş katmanı, gizli katman ve çıkış katmanı olmak üç katmandan oluşur ve bu katmanlar yapay sinir hücrelerinin birbirine bağlanmasıyla oluşur. Bir veri setini temsil

eden sinyaller giriş katmanından YSA modeline uygulanır. Bu katmanda verilerin giriş değerleri başlangıç ağırlık değerleri ile birlikte gizli katmana uygulanır. Gizli katmanda, algoritmanın hata payı minimum olana kadar ağırlıklarda ince ayar yapılır. Veriler uygun ağırlık değerleri ile çıkış katmanına uygulanır. Çıkış katmanında gizli katmandan gelen veriler ile aktivasyon fonksiyonu çalıştırılır ve çıktılar oluşturularak eğitim durur [110, 112, 143].

Şekil 5.34'de gösterildiği gibi bu tez çalışmasında gizli katman 10 katmanlı olarak seçildi. Gizli katmanda sigmoid aktivasyon fonksiyonu çıkış katmanında ise softmax aktivasyon fonksiyonu kullanılmıştır. Veri seti üç gruba ayrıldı, %70'i eğitim, %15'i doğrulama ve %15'i test için kullanıldı.

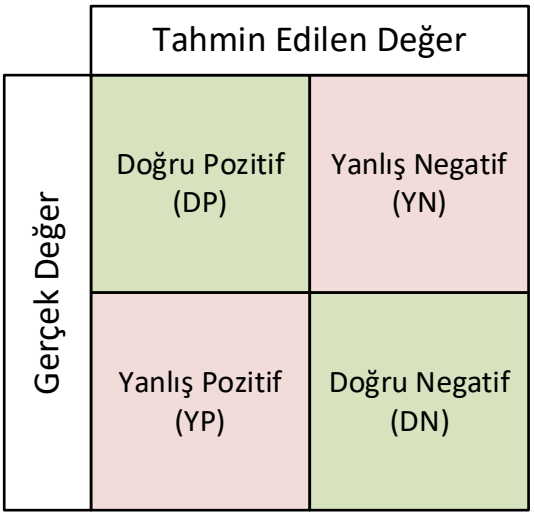


Şekil 5.34. Gerçekleştirilen YSA modeli

Eğitim verisi, eğitim süresince ağa verilir ve ağ bu verilerin hata oranlarına göre ayarlanır. Doğrulama verileri ağ genellemesini ölçmek için kullanılır ve genelleme iyileşmeyi durdurduğunda eğitimi durdurur. Test verilerinin ise eğitim üzerinde hiçbir etkisi yoktur ve eğitim sırasında veya sonrasında ağ performansının bağımsız bir ölçüsünü sağlar.

5.5. Sınıflandırma Yöntemlerinde Performans Değerlendirme Ölçütleri

ML sınıflandırma yöntemlerinin performanslarının karşılaştırılmasında en yaygın kullanılan araç Şekil 5.35'de gösterilen hata matrisidir (Karışıklık matrisi). Hata matrisi bir ML sınıflandırma yönteminin farklı sınıf etiketlerini ne ölçüde sınıflandırabildiğini gösteren bir analiz yöntemidir. Bu matris, modelin tahmin ettiği sınıflarla gerçek sınıflar arasındaki ilişkiyi gösterir. Hata matrisi, genellikle iki sınıflı sınıflandırma problemleri için kullanılır, ancak çok sınıflı problemler için de genişletilebilir. Bir veri seti için sınıflandırma etiketi *k* adet ise hata matrisi *k x k* boyutludur.



Şekil 5.35. Hata matrisi

Hata matrisinin parametreleri şu şekilde açıklanabilir;

- Doğru Pozitif (DP): ML sınıflandırıcı yöntemi tarafından doğru olarak belirlenmiş pozitif sınıf etiketidir.
- Doğru Negatif (DN): ML sınıflandırıcı yöntemi tarafından doğru olarak belirlenmiş negatif sınıf etiketidir.
- Yanlış Pozitif (YP): ML sınıflandırıcı yöntemi tarafından yanlış olarak belirlenmiş pozitif sınıf etiketidir.
- Yanlış Negatif (YN): ML sınıflandırıcı yöntemi tarafından yanlış olarak belirlenmiş negatif sınıf etiketidir.

Hata Matrisi kullanılarak hesaplanan performans ölçüm değerleri şunlardır [112, 122, 124, 135, 145].

5.5.1. Doğruluk

Eş. 5.90'da verilen doğruluk ML sınıflandırıcı yöntemi tarafından yapılan doğru sınıflandırma sayısının tüm veri seti sayısına bölümüdür. 0 ile 1 arasında değer alır. Beklenen değerin 1'e yakın olması istenir 1 değeri %100 doğruluğu gösterir.

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \tag{5.90}$$

5.5.2. Kesinlik

Eş. 5.91'de verilen kesinlik pozitif olarak yapılan sınıflandırmanın içerisindeki doğru yapılan sınıflandırmanın oranıdır. 0 ile 1 arası değerler alır. Beklenen değerin 1'e yakın olması istenir.

$$Kesinlik = \frac{DP}{DP + YP} \tag{5.91}$$

5.5.3. Duyarlılık

Eş. 5.92'de verilen duyarlılık doğru olarak tahmin edilen pozitif değerlerin (*DP*) tüm tahmin değerlerine oranıdır. Mümkün olduğunca yüksek olması istenir ve 0 ile 1 arası değerler alır.

$$Duyarlılık = \frac{DP}{DP + YN} \tag{5.92}$$

5.5.4. Özgüllük

Eş. 5.93'de verilen özgüllük doğru olarak tahmin edilen negatif değerlerin (*DN*), gerçek negatiflere oranıdır. Yüksek olması istenir ve değerin 1 olması beklenir.

$$Özgüllük = \frac{DN}{DN + YP} \tag{5.93}$$

5.5.5. F1 skoru

Eş. 5.94'de verilen *F1* skoru duyarlılık ve kesinlik değerlerinin harmonik ortalamasıdır. Dengesiz veri setleri için daha yüksek performanslı bir ölçüm yöntemidir.

$$F1\ Skoru = 2 \times \frac{Duyarlılık \times Kesinlik}{Duyarlılık + Kesinlik} \tag{5.94}$$

5.5.6. ROC eğrisi ve AUC değeri

ROC (Receiver Operator Characteristic) eğrisi dengeli dağılama sahip olmayan veri setlerinde performans değerlendirilmesi için kullanılan bir grafik türüdür. Bu eğrinin X ekseni yanlış pozitif (*YP*) oranını Y ekseni ise doğru pozitif (*DP*) oranını Gösterir. ROC eğrinin altında kalan alanın değeri *AUC* (Area of Under Curve) performans ölçüsü olarak kullanılır. İdealde bu alanın ölçüsünün 1 olması beklenir.

5.5.7. Cohen'in Kappa Katsayısı (κ)

İki sınıf etiketi arasındaki karşılaştırmalı uyuşmanın güvenirliğini ölçen bir yöntemidir. κ ölçüsü bu uyuşmanın bir şans eseri olabileceğini de ele aldığı için basit yüzde orantı olarak bulunan uyuşmadan daha güçlü bir sonuç verdiği kabul edilir. Değeri -1 ile 1 arasında değişir. $\kappa<0$ olduğu değerlerde hiç uyuşma olamadığı kabul edilir. $\kappa>0$ olduğunda uyuşma başlar ve $\kappa=1$ olduğunda mükemmel uyum vardır [145]. Eş. 5.95'de κ katsayısının formülü verilmiştir. Eş. 5.96 ve Eş. 5.97'de ise κ katsayısının parametreleri verilmiştir.

$$\kappa = \frac{P_{obs}-P_{exp}}{1-P_{exp}} \tag{5.95}$$

$$P_{obs} = \frac{DP+DN}{DP+DN+YP+YN} \tag{5.96}$$

$$P_{exp} = \frac{(DP+YN)(DP+YP)+(YP+DN)(YN+DN)}{\sqrt{(DP+DN+YP+YN)}} \tag{5.97}$$

Bu eşitliklerde;

- P_{obs} = Değerlendiriciler arasında gözlemlenen göreceli uyum
- P_{exp} = Şans anlaşmasının varsayımsal olasılığı

5.5.8. Eğitim Süresi

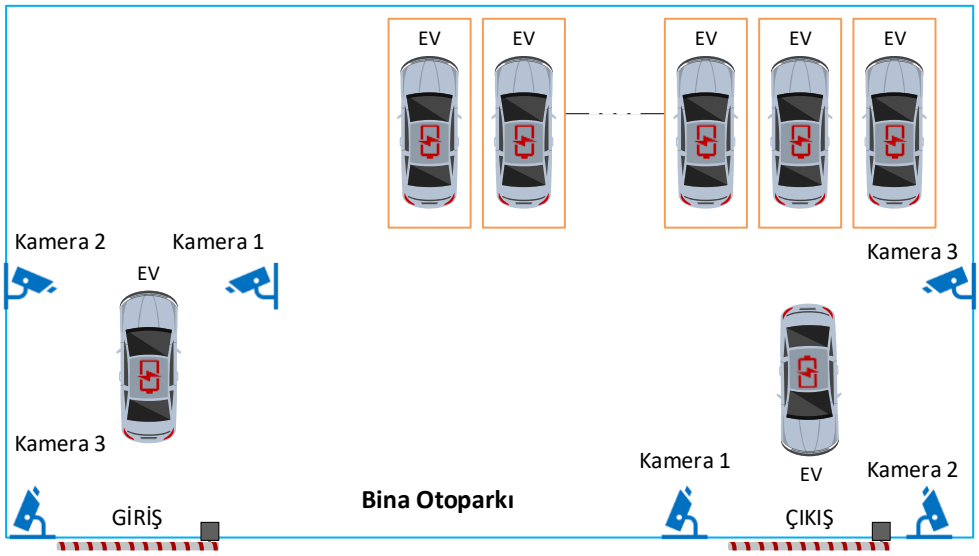
Diğer bir performans değerlendirme aracıda ML yönteminin eğitim süresidir. Saniye olarak ML yöntemlerinin eğitim süreleri, ML yönteminin gerçek uygulamalarda kullanılıp kullanılamayacağının belirlenmesinde önemli bir performans göstergesidir.

6. UYGULAMA ÇALIŞMALARI VE SONUÇLAR

Bu bölümde tez çalışmasındaki V2G topolojisinde ML tabanlı enerji akış modeli için uygulama çalışmaları gerçekleştirildi. Uygulama çalışmaları iki ayrı aşamada gerçekleştirildi. İlk aşamada ML uygulaması için veri toplamakla işe başlandı. Daha sonra ham veriler ön işleme süreci ile veri setine dönüştürüldü. Oluşturulan veri setinin 22 farklı ML yönteminde analizleri yapıldı. En başarılı yöntemin topluluk öğrenme yöntemlerinden torbalama yöntemi olduğu tespit edildi ve torbalama yönteminde karar ağaçları (Bagged Trees) kullanıldı. Tasarlanan sistemin algoritması çıkarılarak ML uygulama çalışmaları gerçekleştirildi. ML uygulama çalışmalarında parametreler adım adım denenerek hiperparametre optimizasyonu ile belirlenmiştir. İkinci aşamada ise V2G topolojisinin simülasyonları ve uygulaması gerçekleştirildi. Simülasyon çalışmalarında iki ayrı çalışma yapıldı. İlk çalışmada V2G topolojisinde enerji akış yönetimi için çift yönlü DC-DC dönüştürücü ve tek fazlı şebeke bağlantılı evirici simülasyonları gerçekleştirildi. İkinci çalışmada ise SVPWM anahtarlamalı üç fazlı şebeke bağlantılı evirici simülasyonları gerçekleştirildi. Simülasyon çalışmalarından sonra tek faz şebeke bağlantılı evirici ile bir batarya grubundan ana şebekeye enerji aktarılarak performans ölçümleri gerçekleştirildi.

6.1. Makine Öğrenmesi Uygulama Çalışmaları

Tez çalışmasına ilk olarak veri toplama işlemi ile başlandı. Türkiye'nin başkenti Ankara'da bir bina ve bu binadaki 20 araç sahibinin araçlarının EV olduğu kabul edilerek, bu yirmi aracın 1 Ocak 2022 ile 31 Aralık 2022 tarihleri arasında bir yıl boyunca binanın otoparkına giriş-çıkış saat ve tarihlerinin bilgileri kaydedildi. Veri kaydı için Şekil 6.1'de gösterildiği gibi üç adet kamera kullanan plaka tanıma sistemi ile araç bilgileri kaydedildi. Birinci ve ikinci kamera araç plakasını sırayla önden okumaktadır üçüncü kamera ise araç plakasını aracın arkasından okumaktadır. Birinci ve üçüncü kameradaki plaka tanıması örtüşürse aracın giriş-çıkış saat ve tarih bilgisi kaydediliyor. Eğer bu iki kameranın okuduğu plaka bilgileri örtüşmez ise ikinci kamera tarafından okunan plaka bilgisi ile doğrulama işlemi gerçekleştirilerek kayıt işlemi gerçekleştirilmektedir. Bu üçlü kamera sistemi otoparkın giriş ve çıkışına ayrı ayrı kurulmuş olup toplamda altı ayrı kamera ile kayıt işlemleri gerçekleştirilmiştir.



Şekil 6.1. Araç plaka tanıma sistemi

6.1.1. Araç sürücü bilgileri ve ham verinin toplanması

Araç seçiminde araç sürücülerinin meslekleri ve cinsiyetleri dikkate alındı. Araç sürücüleri 10'u kadın 10'u erkek olmak üzere toplamda 20 kişi tespit edildi. Meslek seçiminde ise 20 araç sürücüsünün meslekleri tamamen farklı meslek gruplarından seçildi. Araç sahiplerinin meslek, cinsiyet ve hanedeki araç sayısı dağılımları Çizelge 6.1'de gösterildiği gibi yapıldı. Veri seti oluşturulurken araç sürücü davranışını anlamlandırabilmek için araç ve sahipleri hakkında şu bilgiler derlendi.

Araç 1, fabrika sahibi bir yöneticiye ait. Hanede 2 araç var, bu araç sadece işe gidip gelmek için kullanılıyor. Haftanın yedi günü çalışıyor. Pazar günleri sadece akşamüzeri fabrikaya gidip geliyor. Resmî tatil/milli bayramlar ve dini bayramlar da çalışmıyor. *Araç 2,* ev hanımı tarafından kullanıyor ve çocukları okula götürüp getiriyor. Hanede 2 araç var. Hafta sonları ve okul tatillerinde araç otoparkta bulunuyor. Bu günlerde nadirde olsa araç kullanılıyor. *Araç 3,* bir bankacıya ait ve hanede 3 araç var. Araç bankanın açık olduğu günlerde işe gidip gelmek için kullanılıyor. Resmî tatil/milli bayramlar, dini bayramlar ve izin günlerinde araç otoparkta bulunuyor. *Araç 4,* bir hastaya ait ve hanedeki araç sayısı 3. Bu araç çarşamba ve perşembe günleri tedaviye gidip gelmek için kullanılıyor. Bunun dışında acil durumlar için sürekli otoparkta bekletiliyor. Hasta acil hastaneye gitmesi gerekiyorsa sadece onu hastaneye götürüp getiriyor. *Araç 5,* sahibi doktor. 1 hafta gündüz 1 hafta gece çalışıyor. Resmî tatil ve bayramlarda da çalışabiliyor. Hanedeki araç sayısı 2.

Araç 6, sahibi bir eğitim kurumunda idareci. Hanedeki araç sayısı 2. Hafta sonları ve tatil günlerinde araç otoparkta kalma eğiliminde. *Araç 7,* sahibi emekli bir sürücü ve hanedeki araç sayısı 2. Sürücü aracını sadece cuma günleri camiye gitmek arkasından da alışverişe gitmek için kullanıyor. Temmuz ayından sonra da hafta sonları hobi bahçesine gidip gelmek için kullanıyor. Bunların dışında araç otoparkta kalma eğiliminde. *Araç 8,* sahibi özel sektörde memur hanedeki araç sayısı 1. Araç hanedeki tek taşıt olduğundan araba gerektiren her işte kullanılma eğiliminde. *Araç 9,* dükkân sahibi bir kuaföre ait. Pazartesi günleri çalışmıyor. Hanedeki araç sayısı 2. Resmî tatillerde/milli bayramlarda çalışıyor. Dini bayramlarda ilk günler çalışmıyor. *Araç 10,* lokanta sahibi bir şef aşçıya ait. Günde 2 defa lokantaya gidip geliyor. Tüm yıl çalışıyor. *Araç 11,* sahibi esnaf, hafta içi dört gün çalışıyor. Hanedeki araç sayısı 3. Tatil günü her hafta 1 gün kayıyor. Hafta sonları, resmî tatil/milli bayramlar ve dini bayramlarda araç kullanılmıyor. *Araç 12,* üniversite öğrencisine ait. Sadece hafta sonu çalıştığı işe gidip gelmek için kullanıyor. Hanedeki araç sayısı üç. *Araç 13,* sahibi bir devlet dairesinde memur. Hanedeki araç sayısı 2. Aracı sadece hafta içi işe gidip gelmek için kullanıyor. Tatillerde araç otoparkta kalma eğiliminde. *Araç 14,* sahibi bir fabrikanın üretim bandında mühendis. Hanedeki araç sayısı 2. Çift vardiya çalışıyor. Birinci vardiyada sabahtan öğleye kadar, ikinci vardiyada ise öğleden geceye kadar çalışıyor. Hafta sonları ve tatillerde araç otoparkta kalma eğiliminde. *Araç 15,* sahibi ise emniyet çalışanı. Hanedeki araç sayısı 2. Bir ay gündüz, bir ay gece çalışıyor. 24/24 saat usulüne göre çalışıyor. Hafta sonları, resmî tatil/milli bayramlar ve dini bayramlarda da çalışıyor. *Araç 16,* pastane sahibi bir pasta ustasına ait. Hanedeki araç sayısı 2. Cumartesi ve pazar günleri hariç yılın her günü çalışıyor. Sabah 4 civarı gidip öğlen 10'a kadar çalışıyor daha sonra akşam üzeri saat 6 civarı gidip bir sonraki günün hazırlığını yapıyor. *Araç 17,* sahibi mali müşavir ve hanedeki araç sayısı 2. Hafta içi ve Cumartesi yarım gün çalışıyor. Resmî tatil/milli bayramlar ve dini bayramlarda araç otoparkta kalma eğiliminde. *Araç 18,* sabahçı bir öğretmene ait. Hanedeki araç sayısı 2. Hafta sonları ve dini bayramlarda çalışmıyor. Milli bayramlarda ise çalışıyor. Araç genelde otoparkta kalma eğiliminde. *Araç 19,* sahibinin elektrik malzemesi satan bir dükkânı var. Pazartesi günleri hariç haftanın diğer günleri çalışıyor. Sadece dini bayramlarda çalışmıyor. Hanedeki araç sayısı 3. *Araç 20,* sahibi adliye çalışanı ve hanedeki araç sayısı 1. Makam aracı olduğundan aracını hafta sonları şehir dışına ailesinin yanına gidip gelmek için kullanıyor. Diğer zamanlarda araç otoparkta duruyor.

Çizelge 6.1. Araç sürücü meslek, cinsiyet ve hanedeki araç sayısı dağılımları

Sürücü	Cinsiyeti	Mesleği	Hanedeki Araç Sayısı
Sürücü 1	ERKEK	Yönetici (Fabrika Sahibi)	2
Sürücü 2	KADIN	Ev Hanımı	2
Sürücü 3	KADIN	Bankacı	3
Sürücü 4	ERKEK	Emekli-Hasta	3
Sürücü 5	KADIN	Doktor	2
Sürücü 6	KADIN	İdareci (Eğitim Kurumu)	2
Sürücü 7	ERKEK	Emekli	2
Sürücü 8	ERKEK	Memur	1
Sürücü 9	ERKEK	Kuaför	2
Sürücü 10	ERKEK	Şef Aşçı	2
Sürücü 11	KADIN	Esnaf	3
Sürücü 12	KADIN	Üniversite Öğrencisi	3
Sürücü 13	KADIN	Memur	2
Sürücü 14	ERKEK	Mühendis	2
Sürücü 15	ERKEK	Emniyet Çalışanı	2
Sürücü 16	KADIN	Pasta Ustası	2
Sürücü 17	KADIN	Mali Müşavir	2
Sürücü 18	KADIN	Öğretmen	2
Sürücü 19	ERKEK	Esnaf	3
Sürücü 20	ERKEK	Adliye Çalışanı	1

6.1.2. Veri setinin oluşturulması

Kamera kayıt sistemi ile 20 aracın anlık olarak giriş-çıkış tarih ve zamanları kaydedilerek 2022 yılına ait 1 yıllık ham veri elde edildi. Elde edilen ham veriler kullanılarak veri seti oluşturuldu. Çizelge 6.2'de gösterildiği gibi veri seti için girişleri (bağımsız değişkenler) ve çıkış (sınıf etiketi) sırasıyla EV kullanıcısı (Ku), Tarih (T), Haftanın Günü (Hg), Gün Tipi (Gt), Periyod (P) ve EV'nin otoparkta bulunma durumu (S) olarak belirlendi.

Çizelge 6.2. Veri seti öznitelikleri ve sınıf etiketleri

Veri Seti Öznitelikleri		Öznitelik Değerleri		
		20 Adet Sınıflandırma Yöntemi	KNN Yöntemi	YSA Yöntemi
Girdiler	EV Kullanıcısı (Ku)	Ku1, Ku2, …, Ku20	1, 2, 3, …, 20	1, 2, 3, …, 20
	Tarih (T)	1, 2, 3, 4, …, 364, 365	1, 2, 3, 4, …, 364, 365	1, 2, 3, 4, …, 364, 365
	Haftanın günü (Hg)	Pazartesi, Salı, …, Pazar	1, 2, 3, 4, 5, 6, 7	1, 2, 3, 4, 5, 6, 7
	Gün tipi (Gt)	1, 2, 3, 4, 5, 6, 7	1, 2, 3, 4, 5, 6, 7	1, 2, 3, 4, 5, 6, 7
	Periyot (P)	1, 2, 3, 4, … ,47, 48	1, 2, 3, 4, … ,47, 48	1, 2, 3, 4, … ,47, 48
Çıktı	EV'nin otoparkta bulunma durumu (S)	VAR, YOK	VAR, YOK	1, 0

Veri seti için belirlenen değişkenlere 22 ML yönteminde değerler verildi. Ku girişine 1'den 20'ye kadar Ku1, Ku2, …, Ku20 şeklinde değer verildi. KNN ve YSA yöntemlerinde ise Ku girişine 1'den 20'ye kadar sayısal olarak değer verildi. T girişine ise 1 Ocak 2022 tarihi "1" olmak üzere 31 Aralık 2022 tarihine kadar 365'e kadar sayısal değer verildi. Hg girişine yılın o günkü tarihine göre haftanın ilk günü pazartesi son gün pazar olacak şekilde değer verildi. KNN ve YSA yöntemlerinde ise Hg girişine ilk günü Pazartesi son gün Pazar olmak üzere 1'den 7'ye kadar sayısal değer verildi. Gt girişi için 7 farklı gün tipi belirlenerek 1'den 7'ye kadar Çizelge 6.3'de gösterildiği gibi değer verildi.

Çizelge 6.3. Gün tipi değişkenine ait değerler

Gün Tipi (Gt)	Değer
Hafta İçi	1
Hafta Sonu	2
Resmî Tatil/Milli Bayramlar	3
Dini Bayramlar	4
Okul Tatili	5
Ramazan Ayı	6
İdari İzin	7

Ham verilerde araçların giriş ve çıkışları saat ve dakika seviyelerinde kaydedildi. Ham veri üzerinde kayıp veri analizi yapıldı. Veri seti oluşturulurken üçlü kamera kayıt sistemindeki kontrol mekanizmasından dolayı kayıp veri olmadığı tespit edildi. Kullanıcı giriş-çıkış verileri dakika olarak belirlendiğinde bir kullanıcı için günlük olarak veri miktarı 1440 satır olmaktadır. Bu nedenle günlük giriş çıkış saatlerinin tespitinde 30 dakikalık aralıklar kullanılmasına karar verildi. Veri setinde bir gün saat 00:00'dan 23:59'a kadar 30 dakikalık 48 periyoda bölünerek P girişine 1'den 48'e kadar değer verildi. Burada öznitelik ölçeklendirme işlemi yapılarak veri setinin boyutu azaltılmış oldu. Veri seti sınıf etiketi için EV'nin otoparkta bulunma durumuna (S) bakıldı. Her bir araç için günün her periyodunda otoparkta bulunup bulunmadığına bakılarak araç otoparkta ise sınıfı etiketi VAR olarak araç otoparkta değilse YOK olarak etiketlendi. YSA modelinde ise araç otoparkta ise 1 otoparkta yoksa 0 olarak etiketlendi. Veri seti 5 giriş ve 1 çıkış olmak üzere 350400 örnekten (20 EV x 365 gün x 48 periyot) oluşmaktadır.

6.1.3. Veri setinin makine öğrenmesi yöntemleri ile analizi

Veri seti 22 adet ML yöntemi ile eğitildi ve sınıflandırma işlemleri gerçekleştirildi Sınıflandırma işlemleri MATLAB 2020b programında gerçekleştirildi. MATLAB 2020b uygulamaları işlemcisi i5-8300H @ 2.30GHz CPU ve RAM'i 32GB olan bir bilgisayarda gerçekleştirildi. 22 adet ML yönteminin performansı sırasıyla doğruluk, kesinlik, duyarlılık, özgüllük, F1 skoru, AUC, κ katsayısı ve eğitim süresi olmak üzere sekiz farklı performans kriteri ile değerlendirildi. ML yöntemlerinin performans değerleri Çizelge 6.4'de verilmiştir.

Çizelge 6.4. ML yöntemlerinin performans değerleri

ML Yöntemi			Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1	AUC	κ	Eğitim Süresi (Saniye)
1	Karar Ağacı (Decision Tree)	Fine Tree	0,848	0,891	0,890	0,751	0,890	0,920	1,000	8,65
2		Medium Tree	0,810	0,845	0,890	0,627	0,867	0,840	1,000	6,28
3		Coarse Tree	0,770	0,816	0,865	0,555	0,840	0,760	1,000	5,30
4	Lojistik Regresyon		0,714	0,745	0,894	0,302	0,813	0,750	1,000	24,76
5	Naive Bayes	Gaussian Naive Bayes	0,776	0,788	0,928	0,428	0,852	0,800	1,000	4,36
6		Karnel Naive Bayes	0,795	0,813	0,916	0,516	0,861	0,830	1,000	13137
7	SVM	Linear SVM	0,709	0,725	0,938	0,186	0,818	0,720	1,000	15457
8		Quadratic SVM	0,863	0,907	0,894	0,791	0,901	0,900	1,000	50540
9		Cubic SVM	0,895	0,930	0,917	0,843	0,924	0,940	1,000	72234
10		Fine Gaussian SVM	0,921	0,949	0,937	0,884	0,943	0,970	1,000	20919
11		Medium Gaussian SVM	0,901	0,935	0,922	0,852	0,928	0,950	1,000	13763
12		Coarse Gaussian SVM	0,829	0,863	0,896	0,676	0,880	0,890	1,000	18711
13	Topluluk Öğrenme	Boosted Trees	0,856	0,881	0,917	0,716	0,899	0,920	1,000	72,50
14		Bagged Trees	0,950	0,966	0,961	0,923	0,964	0,990	1,000	132,49
15		RUSBoosted Trees	0,803	0,913	0,792	0,828	0,849	0,890	1,000	80,31
16	KNN	Fine KNN	0,876	0,910	0,911	0,795	0,911	0,850	1,000	34,81
17		Medium KNN	0,925	0,933	0,962	0,842	0,947	0,980	1,000	43,73
18		Coarse KNN	0,818	0,838	0,917	0,593	0,875	0,980	1,000	98,25
19		Cosine KNN	0,892	0,905	0,945	0,773	0,924	0,960	1,000	3608,30
20		Cubic KNN	0,920	0,929	0,959	0,832	0,944	0,980	1,000	380,29
21		Weighted KNN	0,912	0,938	0,936	0,857	0,937	0,980	1,000	43,79
22	YSA		0,856	0,885	0,911	0,730	0,898	0,890	1,000	27,00

Veri seti her bir ML yöntemi ile 10 defa eğitilerek maksimum ve minimum değerleri elde edildi. Performans kriterlerinin ölçümü maksimum ve minimum değerlerin aritmetik ortalaması alınarak gerçekleştirildi. Örneğin ortalama doğruluk (Ac_m) performans değeri Eş. 6.1'deki gibi maksimum doğruluk (Ac_{mak}) ve minimum doğruluk (Ac_{min}) değerlerinin ortalaması ile hesaplanmıştır.

$$Ac_m = \frac{Ac_{mak} + Ac_{min}}{2} \tag{6.1}$$

En yüksek doğruluk (*Ac*) oranına sahip ML yöntemi Bagged Trees'de 10 denemedeki *Ac* oranları Çizelge 6.5'de gösterildiği gibi elde.

Çizelge 6.5. Bagged Trees Ac değeri ölçüm sonuçları

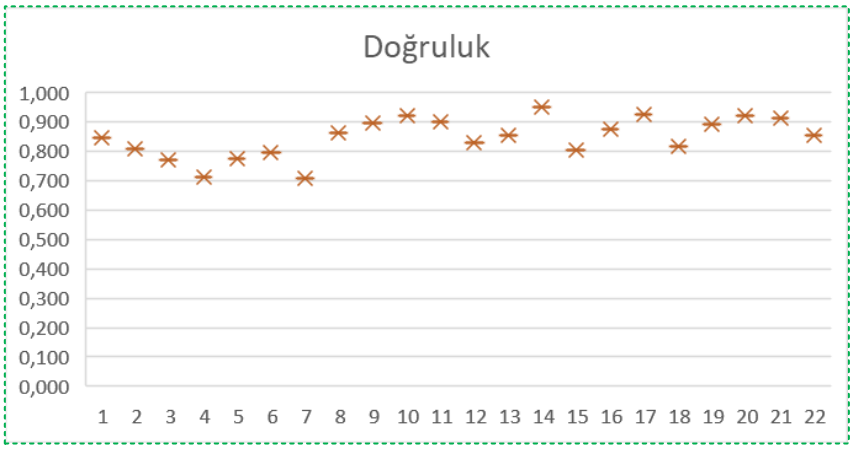
Deneme Numarası	Bagged Trees Doğruluk (Ac) Oranları
1	94,90%
2	95,00%
3	95,10%
4	95,00%
5	95,00%
6	95,15%
7	95,00%
8	94,85%
9	95,10%
10	95,00%

Bagged Trees yönteminim performans kriterleri doğruluk, kesinlik, duyarlılık, özgüllük, F1 skoru ve AUC değerleri sırasıyla 0,95, 0,966, 0,961, 0,923, 0,964 ve 0,990 olarak belirlenmiştir. Bu değerler diğer 21 ML yönteminden yüksektir. Ayrıca κ değeri 1 olarak belirlenmiştir. Veri setindeki sınıfların uyumunun mükemmel olduğunu göstermektedir. Ayrıca Bagged Trees eğitim süresi minimum 112,58 saniye ve maksimum saniye 152,40 ölçüldü. Ortalama eğitim süresi ise 132,49 saniye olarak hesaplandı bu değerin geliştirdiğimiz model ve gerçek uygulamalar için kabul edilebilir bir süre olduğu tespit edildi. Bagged Trees yönteminin performans kriterlerinin ölçüldüğü bir hata matrisi Çizelge 6.6'da verilmiştir.

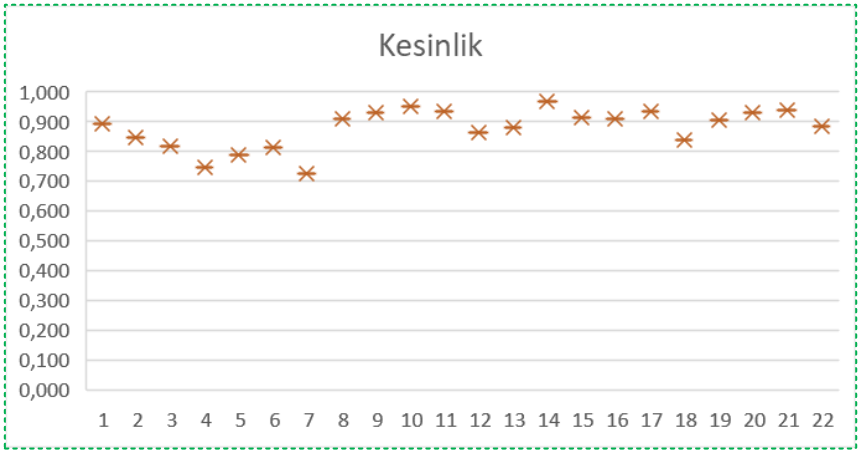
Çizelge 6.6. Bagged Trees hata matrisi

		Tahmin		
		VAR (1)	YOK (0)	Toplam
Gerçek	VAR (1)	234383	9431	243814
	YOK (0)	8206	98380	106586
	Toplam	242589	107811	350400

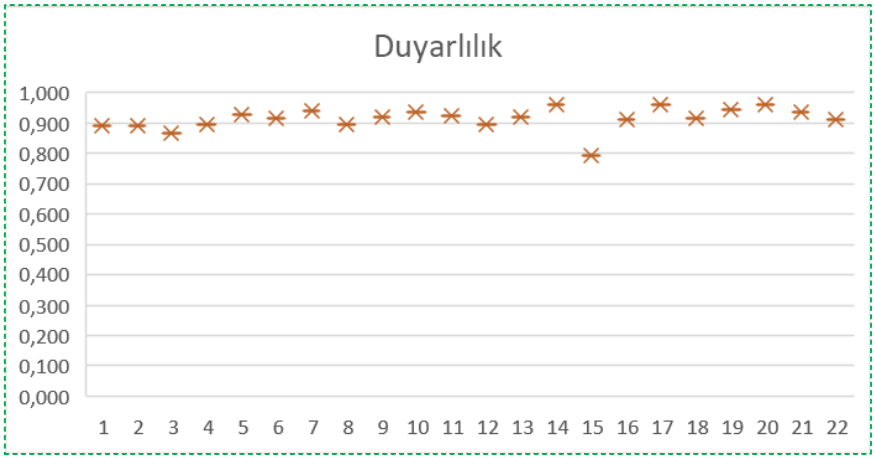
ML yöntemlerinin performans kriterleri doğruluk, kesinlik, duyarlılık, özgüllük, F1 skoru, AUC ve eğitim süreleri için grafikleri sırasıyla Şekil 6.2 ile Şekil 6.8 arasında verilmiştir. Bu grafiklerde yatay eksen 1-22 arasında kullanılan ML yönteminin numarasını, dikey eksen ise 0-1 aralığında ML yönteminin ilgili performansını temsil etmektedir. Bu grafiklerde de en başarılı ML yöntemin 14 numaralı Bagged Trees olduğu görülmektedir.



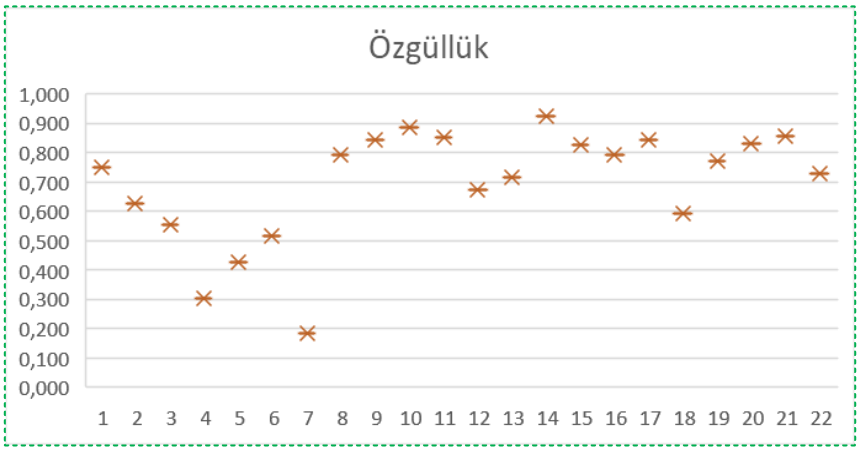
Şekil 6.2. ML yöntemlerinin doğruluk grafiği



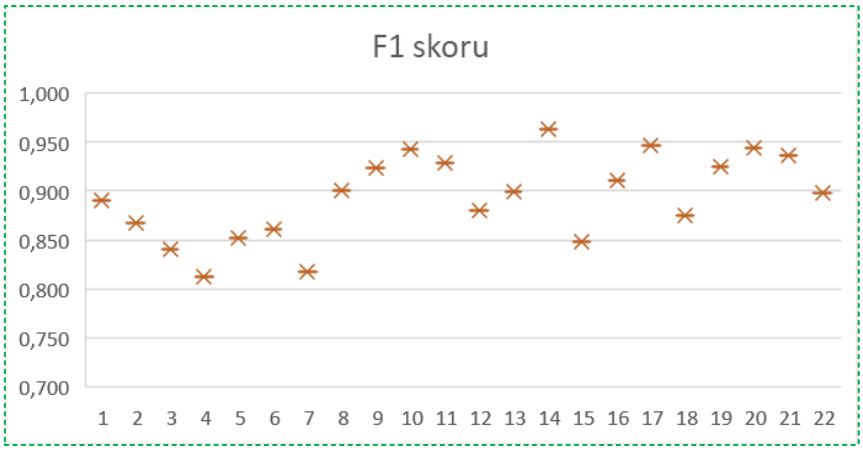
Şekil 6.3. ML yöntemlerinin kesinlik grafiği



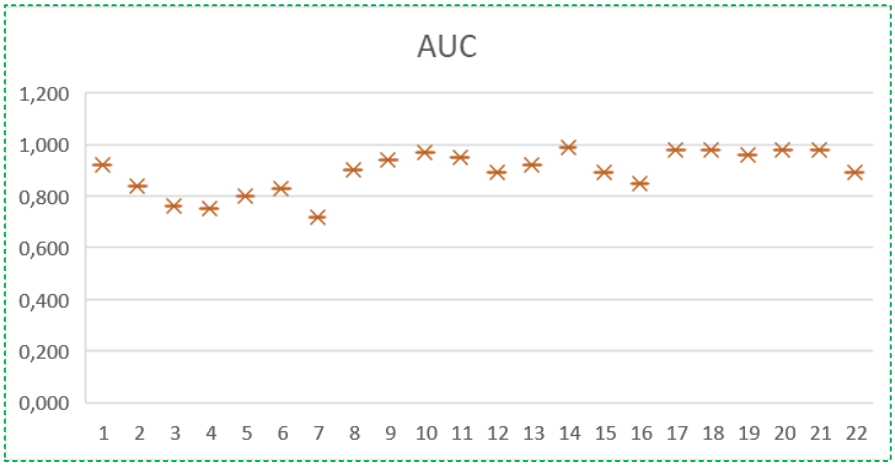
Şekil 6.4. ML yöntemlerinin duyarlılık grafiği



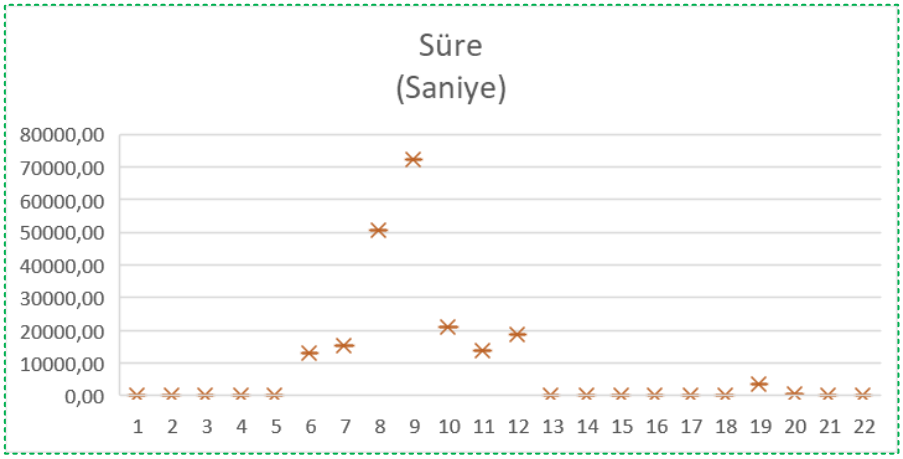
Şekil 6.5. ML yöntemlerinin özgüllük grafiği



Şekil 6.6. ML yöntemlerinin F1 skoru grafiği



Şekil 6.7. ML yöntemlerinin AUC grafiği



Şekil 6.8. ML yöntemlerinin süre grafiği

Veri setini analiz etmek için her kullanıcı için ayrı veri setleri oluşturuldu. Bu oluşturulan 20 alt veri seti, veri setinin tamamı için uygulanan 22 adet ML yöntemlerinde denendi. Bu denemelerde alt veri setlerinin ML yöntemlerindeki doğruluk değerleri Çizelge 6.7 ve Çizelge 6.8'de verildi.

Çizelge 6.7. ML yöntemlerinin alt veri setlerindeki doğruluk değerleri (1)

Kullanıcı	ML Yöntemleri Doğruluk (Ac) Değerleri											
	Tree			Logistic Regression	Naive Bayes		SVM					
	Fine Tree	Medium Tree	Coarse Tree		Gaussian Naive Bayes	Karnel Naive Bayes	Linear SVM	Quadratic SVM	Cubic SVM	Fine Gaussian SVM	Medium Gaussian SVM	Coarse Gaussian SVM
	1	2	3	4	5	6	7	8	9	10	11	12
Ku1	98,4	98	94,5	70,9	83,4	93,5	77,6	97,4	97,2	97,8	96,5	91,2
Ku2	96,2	93,8	89,5	89,5	89,5	89,5	89,5	89,5	89,6	93,4	89,5	89,5
Ku3	98,7	98,8	98,1	85,3	91,4	97,2	88,7	97,9	97,8	97,8	97,9	91,1
Ku4	98,3	97,9	97,7	94,5	94,2	94,6	94,5	94,5	97,6	97,5	94,5	94,5
Ku5	69,5	66,5	65,1	65,5	65,4	66,1	65	66,1	56,8	65,7	66,6	65,5
Ku6	98,2	98,3	97,7	81,7	96,6	98,2	81,7	97	97,9	98,2	97,3	81,7
Ku7	99	97,4	96,8	91	94,1	96,1	92,3	96,4	97	97,2	96,6	92,3
Ku8	97,8	96,5	95,3	77,9	89,5	93,9	82,9	95,9	96,6	96,8	96,4	85,7
Ku9	98,8	98	96	79,9	92,5	95,9	71,7	95,9	96,4	96,6	96,1	92,4
Ku10	96,4	95,3	91,6	69,5	63,8	91,1	66,2	73,4	82,3	94,3	84,5	72,5
Ku11	95,3	95,1	94,8	76,6	92,5	92,8	82,9	94,8	94,1	94,5	94,6	82,9
Ku12	99,5	98,3	97,4	83,5	93,5	96	88,2	98,1	97,8	98	97,8	92,1
Ku13	98,4	97,2	94,7	55,9	88,6	92,6	66,4	95,3	96,5	96,3	96,1	88,2
Ku14	85,1	82,8	81	63,9	75,5	79,9	68,7	82	80,5	81,7	82,3	80,8
Ku15	57	55,5	55,2	55,3	55,3	55,2	55,3	55,4	50,2	56,7	56,8	55,3
Ku16	97,8	97,5	89,5	70	75,5	96,7	70,5	70,5	69,5	96,8	87,3	70,5
Ku17	98,8	97	92,8	70,6	91,2	94	76,7	94,9	97,2	97,6	96,7	87,5
Ku18	98,5	96,7	89,4	73,3	72,1	75,5	73,3	86,1	92,2	93,8	91	73,3
Ku19	98,9	97,7	96,7	90,8	91,9	96,2	90,2	96,8	97,2	97,5	97,2	92,7
Ku20	99,7	97,6	93,1	93,1	91,6	92,2	91,7	94,7	95,2	95,3	95,2	91,7
Hepsi	84,4	81	77	71,4	77,6	79,5	70,9	86,3	89,5	92,1	90,1	82,9

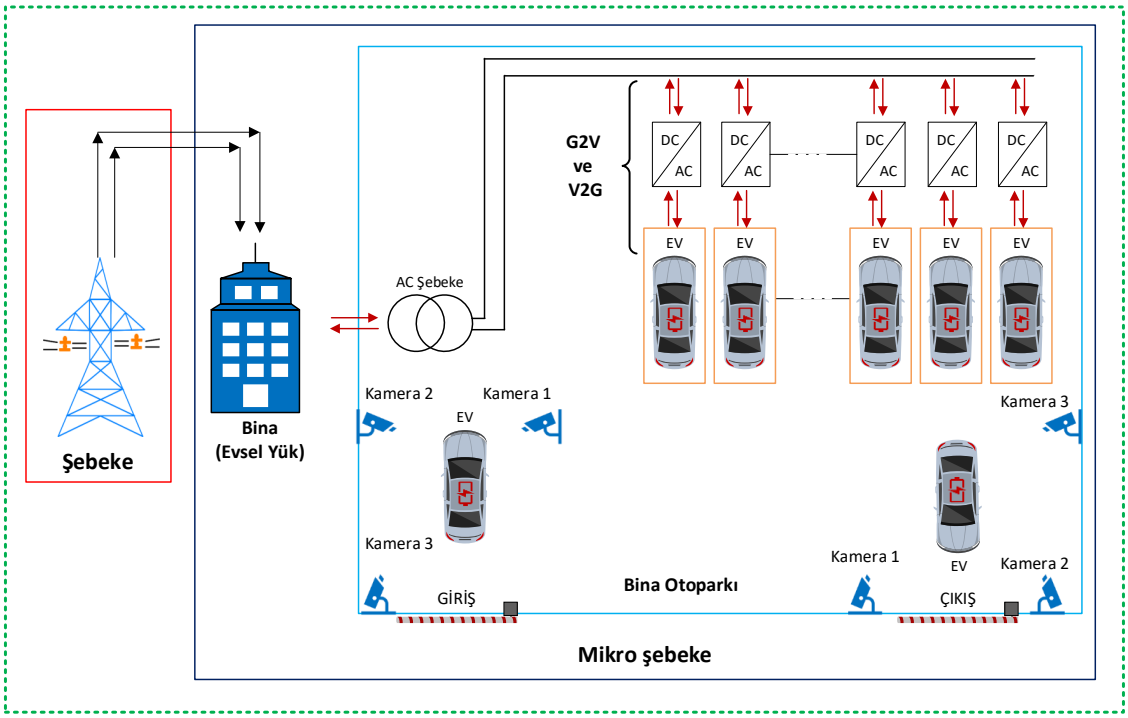
Çizelge 6.8. ML yöntemlerinin alt veri setlerindeki doğruluk değerleri (2)

Kullanıcı	ML Yöntemleri Doğruluk (Ac) Değerleri									
	Ensemble			KNN						YSA
	Boosted Trees	Bagged Trees	RUS Boosted Trees	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	
	13	14	15	16	17	18	19	20	21	22
Ku1	98	98,6	98	97,8	97,6	97,3	97,3	97,7	97,9	98
Ku2	94,9	97,8	86,4	94,7	95,5	90,5	95	95,2	96,2	96
Ku3	98,8	98,9	98,7	96,7	97,7	97,2	97,5	97,6	97,8	98,1
Ku4	97,7	99,3	97,3	95,7	97,4	96,8	97,4	97,5	97,7	97,7
Ku5	68,6	86,2	67,4	39,1	70,9	66,3	61,9	70,7	53,7	66
Ku6	98,3	98,4	98,3	97,4	98,1	97,9	98,1	98	98,1	98,3
Ku7	98	99,4	96,4	96	97,7	96,5	97,6	97,5	97,9	96,3
Ku8	97,1	98,5	96,7	95,2	96,8	95,6	96,3	96,6	97	97
Ku9	98,1	98,9	98	95,9	97,1	95,5	96,7	96,5	97,7	96,8
Ku10	95,8	97,1	95,4	92,7	94,3	92,5	93,9	93,9	95,1	94,4
Ku11	95,1	96,1	95	90,8	94,5	93,5	94,1	94,3	94,5	94,7
Ku12	99,4	99,5	98,1	98	98,9	97,9	98,7	98,4	99	98,1
Ku13	97,6	98,6	97,6	94,8	96,3	95,4	96,1	96,3	96,6	97,6
Ku14	83,5	93	83	68,1	84,2	81,9	80,2	84,3	76	82,2
Ku15	55,9	72,9	55	26,6	62,6	55,6	50	59,4	46,1	55,4
Ku16	97,6	98,1	97,5	95,9	96,7	93,9	95,4	96,6	97	97,4
Ku17	98,2	98,9	97	96,9	97,4	96,4	97,2	97,4	97,6	98,2
Ku18	97,5	98,7	97,3	93,9	96,1	91,3	96	95,3	97,1	97,8
Ku19	98	99	97,7	95,9	97,1	94,1	96,4	97,1	97,3	97,6
Ku20	99,7	99,7	98,5	91,4	95,3	94,5	95,1	95,2	95	96,7
Hepsi	85,6	95	80,3	87,6	92,5	81,8	89,2	92	91,2	85,6

Alt veri setleri ile gerçekleştirilen denemeler sonucunda da en yüksek başarı oranı Bagged Trees yönteminde elde edildi. Her bir kullanıcıya ait 20 alt veri seti ML yöntemlerinde denendiğinde elde edilen sonuçlar, veri setinin tamamında elde edilen sonuçlara benzer olduğu tespit edildi.

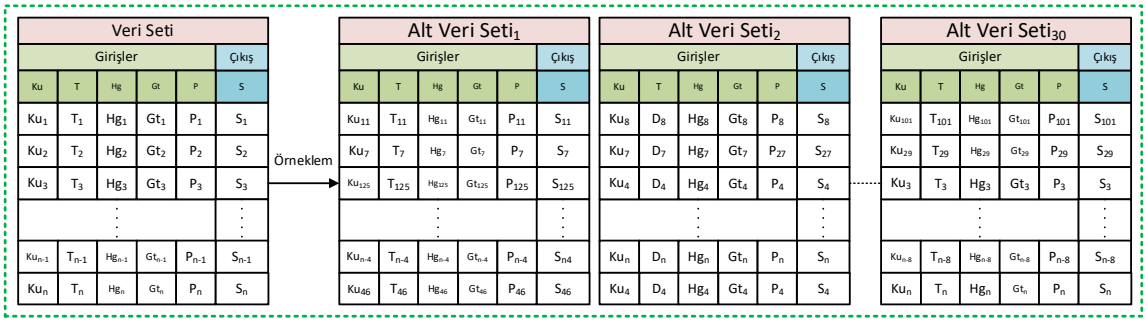
6.1.4. V2G topolojisinde EV seçimi

Veri setindeki araç sahiplerinin hepsinin EV sahibi olduğu kabul edilerek, bina ile binanın otoparkından oluşan ve Şekil 6.9'da gösterildiği gibi bir mikro şebeke tasarlandı. V2G topolojisinde şebekeye enerji verebilecek araçların seçimi bir sınıflandırma problemi haline getirilerek veri seti 22 adet ML yönteminde denendi. En yüksek ortalama *Ac* değerine sahip ML yöntemi %95 ile Bagged Trees olarak tespit edildi. V2G işletildiği durumda mikro şebekeye enerji sağlayacak araç seçimi için araçların araç seçim değerlerine bakıldı (Es_i). Esi değerleri araç tahmin değerleri (Ps_i), araçların otoparkta bulunma sıklığı (F_i) ve araç batarya şarj durumu (SOC_i) değerleri kullanılarak hesaplandı.



Şekil 6.9. Veri setindeki EV'lere ait mikro şebeke

Bagged Trees sınıflandırma yönteminde *N* adet örneğe sahip veri seti örneklem yolu ile *M* adet alt veri setine ayrılır. Oluşturulan temel veri setinde örnek sayısı 350400'dür. Veri setinden örneklem yoluyla her biri 350400 örneğe sahip 30 alt veri seti oluşturuldu. Şekil 6.10'da gösterildiği gibi 30 adet eğitim alt veri seti, her biri 350400 adet üyeden oluşan, temel veri setinden rastgele örneklem yolu ile her seferinde değiştirilerek oluşturulur. Bu durum her sınıflandırıcının eğitiminde rastgelelik meydana getirir. Eğitimden sonra tüm sınıf tahminleri birleştirilerek varyans azaltılmış olur ve bias artması engellenmiş olur.



Şekil 6.10. Bagged Trees örneklem işlemi

Bütün alt veri setleri, temel veri setinden rastgele seçildiğinden her bir alt veri seti için örneklem oluşturmak olasılıkla ilgili olduğundan örneklemin belirli bir örneğe sahip olmaması da mümkündür. Bir başka ifadeyle çoklu örneklem olsa bile olasılıksal olarak bazı örneklerin dışarıda kalma ihtimali her zaman vardır. Bu dışarıda kalan örneklerin oluşturduğu veri seti torba dışı (*OOB*) olarak isimlendirilir. *OOB* örnekleri torbalama işleminin performans testi için kullanılır. Örneklem ile alt veri seti oluşturulurken örnekler değiştirilerek alındığından bazı örnekler tekrarlanırken bazı örnekler hiç seçilmeyebilir. Eş. 6.2'de verildiği gibi örneklem sırasında toplam eğitim verilerinin yaklaşık 1/3'ünün örneklerden çıkarıldığı gösterilmektedir [146].

$$\rho = \left(1 - \frac{1}{N}\right)^N \xrightarrow{N \to \infty} \lim_{N \to \infty} \left(1 - \frac{1}{N}\right)^N = e^{-1} \approx 0.368 \tag{6.2}$$

Bu eşitlikte ρ *OOB* olasılığı iken N temel veri setinin örnek sayısıdır. Bu eşitlikte, temel veri seti örnek sayısı N arttıkça, bir örneğin örneklemlerde hiç bulunmama olasılığının yaklaşık 1/3 ≈ %33 olduğu ve tek bir örneğin örneklemlerin tamamında birden fazla kez görünme olasılığının 2/3 ≈ %66 olduğu gösterilmektedir.

Her örnekleme 5 katlı çapraz doğrulama uygulanmıştır. Çapraz doğrulamada eğitim için karar ağaçları yöntemi kullanılmıştır. Daha sonra her örnekleme ait *OOB* ile karar ağacı yeniden oluşturularak test edilmiştir. Her bir örneklemin eğitim ve test işlemlerinden sonra hata değeri ve tahmin skorları belirlenmektedir. Örneklem *m* için Eş. 6.3'de elde edilen K adet hata değerlerinin aritmetik ortalaması hesaplanarak ortalama hata bulunmuştur. Her bir örneklem için Eş. 6.4 ile doğruluk oranı hesaplanmıştır. Karar ağaçlarında dallanmanın gerçekleşmesi için karar verme yöntemleri Gini indeksi, entropi ve çekme uygulamasında denendiğinde maksimum başarı oranı (doğruluk) sırasıyla %95,15, %93,98 ve %94,1 olarak belirlenmiştir. Gerçekleştirilen uygulamada Gini indeksi en yüksek başarı oranını verdiğinden tercih edilmiştir. Gini indeksi bölünme kuralı sonucu elde edilen değer her bir düğüm için Eş. 6.5'de verilen tahmin skorunu temsil eder. Her örneklem *m*'deki her bir üye için tahmin skoru hesaplanmıştır.

$$E_{avg} = \frac{1}{K} \sum_{i=1}^{K} E_i \tag{6.3}$$

$$Ac_m = 1 - E_{avg} \tag{6.4}$$

$$\widehat{Ps}_m(n) = \frac{1}{K}\sum_{i=1}^{K}\sum_{j=1}^{N}\widehat{w}_{i,j} \quad (6.5)$$

Bu eşitliklerde;

- E_i: Her bir örneklemdeki hata oranı
- E_{avg}: Örneklem m için ortalama hata oranı
- Ac_m: Örneklem m için doğruluk oranı
- $\widehat{Ps}_m$: Örneklem m için ortalama tahmin skoru
- $\widehat{w}_{i,j}$: Örneklem m de her bir örnek için tahmin skoru ağırlığıdır.

Geliştirilen modelde her bir örneklem için oylama yolu ile sınıflandırma yapılır. Oylama için Eş. 6.6'da verilen ağırlıklı ortalama yöntemi kullanılmıştır. Bu formül, Bagged Trees yöntemindeki her bir örneklem karar ağacının *c* sınıfı için yaptığı tahminlerin ağırlıklı ortalamasını alır ve 0 ile 1 arasında bir ağırlık değeri elde edilir. Tüm örneklem ağaçlarının tahminleri torbalama işlemine tabi tutularak veri setindeki örnekler için *c* sınıfına ait nihai bir tahmin yapılır. Torbalama işleminde tahmin sınıfını oluşturmak için Eş. 6.7 ile en büyük ağırlık ortalamayı veren değer seçilir.

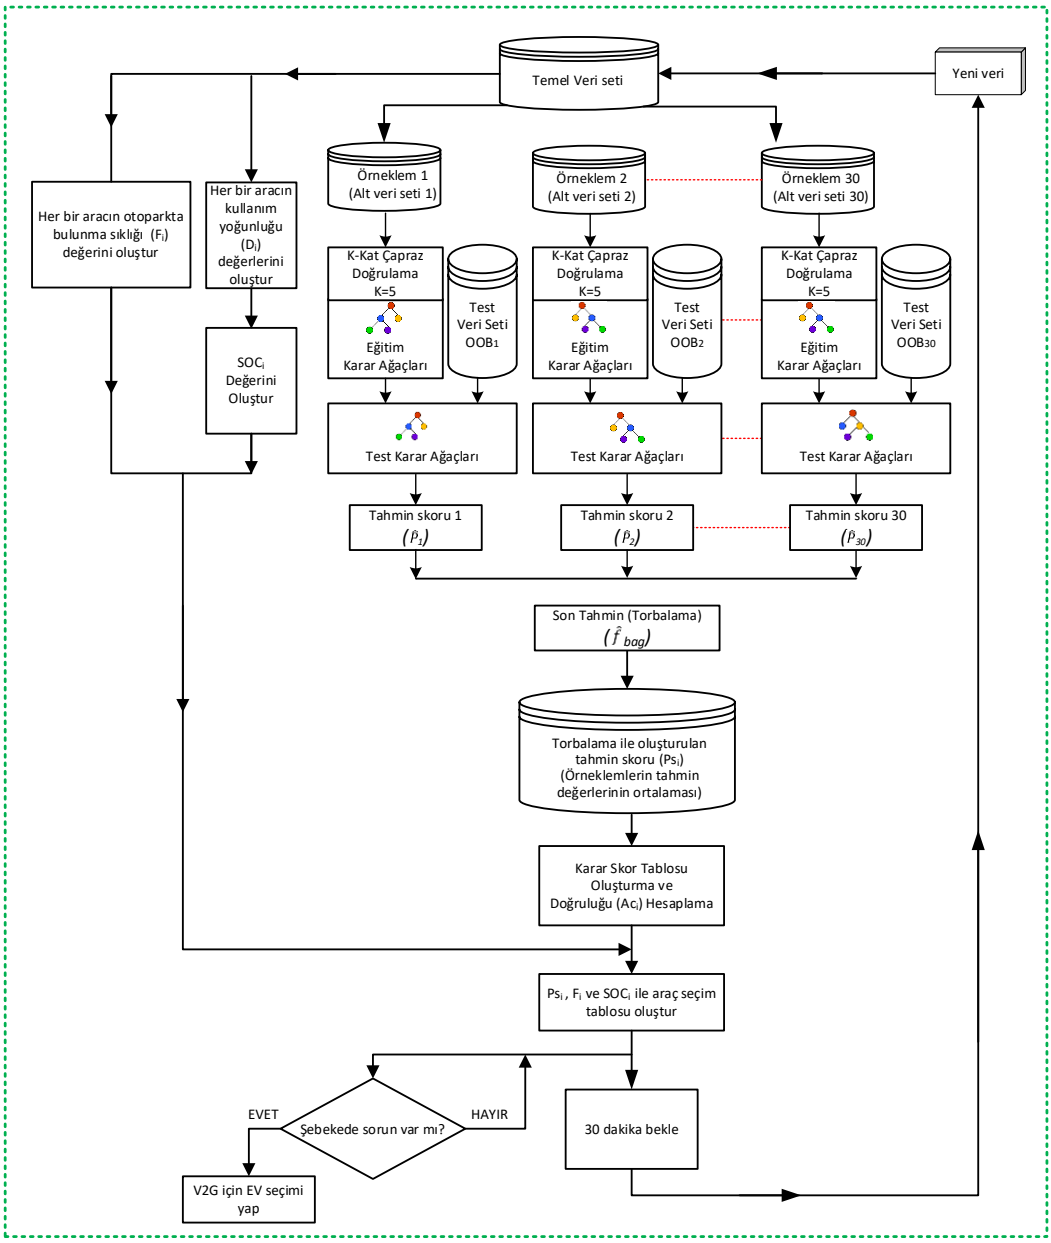
$$\hat{P}_{bag}(c|n) = \sum_{n=1}^{N}\frac{1}{\sum_{m=1}^{M}\alpha_m I(m\in S)}\sum_{m=1}^{M}\alpha_m\,\hat{P}_m(c|n)I(m\in S) \quad (6.6)$$

$$\hat{f}_{bag} = \sum_{n=1}^{N}\underset{c\in C}{argmax}\{\hat{P}_{bag}(c|n)\} \quad (6.7)$$

Bu eşitliklerde;

- $\hat{P}_{bag}(c|n)$: *n.* örneğin tahmin sınıfının ağırlıklı ortalama değeri (tahmin olasılığı)
- $\hat{f}_{bag}$: *n* örneğine ait tahmin sınıfının en büyük ağırlıklı ortalama değeri
- *M*: Ağaç (Örneklem) Sayısı
- α_m: Bir örnekleme ait karar ağacına atanan ağırlıktır ve her bir ağacın tahmine katkısını belirler
- *S*: Bir örnekleme ait karar ağacı değer kümesi
- *I(m∈S)*: *m S* kümesinde varsa 1'e yoksa 0' a eşittir
- C: Tahmin sınıfı
- $\hat{P}_m(c|n)$: Ağaç *m*'de *n* örneğine ait *c* sınıfının değeridir.

Veri setinin sınıflandırma işlemi için ML yöntemi Bagged Trees uygulandıktan sonra araç tahmin değerleri Ps_i tablosu oluşturuldu. Şekil 6.11'de verilen geliştirilen sistemin akış diyagramı çıkarılarak araç seçim için gerekli değerler hesaplandı.



Şekil 6.11. Tasarlanan sistemin akış diyagramı

Tasarlanan sistemin akış diyagramında da görüldüğü gibi 30 dakikalık periyotlarda tasarlanan mikro şebekede sorun olup olmadığına bakılmaktadır. Tasarlanan sistemdeki mikro şebekede bir sorun meydana geldiğinde V2G topolojisi devreye girmektedir. V2G topolojisinde şebekeye bağlanacak aracın seçiminde Eş. 6.8'deki Es_i değeri kullanılmaktadır.

$$Es_i = \frac{Ps_i + F_i + SOC_i}{3} \tag{6.8}$$

Es_i değeri en yüksek olan 4 araç şebekeye bağlanacaktır. Bu 30 dakikalık periyot da veri

setine yeni veri eklemek için 2022 yılına ait bir yıllık veri setinin son 5 günü kullanılarak denendi ve sonucun değişmediği tespit edildi. Tasarlanan mikro şebekedeki araç bilgileri akaryakıt kullanan araçlara ait olduğu için mikro şebekedeki araçların EV olduğu kabul edilerek gerçekleştirildi. V2G topolojisinin işletile bilmesi için Eş. 6.9'da verilen EV SOC değerlerinin de bilinmesi gerekmektedir. Müşteri memnuniyeti açısından SOC değeri %50'nin üzerindeki araçların V2G topolojisinde şebekeye bağlanması istenmektedir [6].

$$SOC_i = \begin{cases} Random(1{\sim}0{,}85) & ; \quad 0 \leq D_i \leq 0{,}15 \\ Random(0{,}84{\sim}0{,}6) & ; \quad 0{,}16 \leq D_i \leq 0{,}4 \\ Random(0{,}59{\sim}0{,}3) & ; \quad 0{,}41 \leq D_i \leq 0{,}7 \end{cases} \tag{6.9}$$

Es_i değerinin belirlenmesindeki diğer parametre Eş. 6.10 'da verilen bir EV'nin tahmin sınıfına ait ağırlıklı ortalama Ps_i değeridir.

$$Ps_i = \sum_{j=1}^{N} \begin{cases} \hat{f}_{bag}(c|j) & ; \quad c = 1 \\ 1 - \hat{f}_{bag}(c|j) & ; \quad c = 0 \end{cases} \tag{6.10}$$

Es_i değerinin belirlenmesindeki üçüncü parametre ise Eş. 6.11'de verilen bir EV'nin otoparkta bulunma sıklığı F_i değeridir.

$$F_i = \frac{1}{N} \sum_{j=1}^{N} \begin{cases} Fc_i & ; \quad c = 1 \\ 0 & ; \quad c = 0 \end{cases} \tag{6.11}$$

SOC değeri belirlenirken Eş. 6.12'de verilen bir EV'nin kullanım yoğunluğu D_i değerine göre rastgele değer verilmektedir.

$$D_i = 1 - F_i \tag{6.12}$$

Bu eşitliklerde;

- Es_i: Bir EV'nin seçim değeri
- SOC_i: Bir EV'nin şarj durum değeri
- Ps_i: Bir EV'nin tahmin sınıfına ait ağırlıklı ortalama değeri
- F_i: Bir EV'nin otoparkta bulunma sıklığı
- Fc_i: Bir EV'nin tüm periyotlardaki bulunma durumu sayısı
- D_i: Bir EV'nin kullanım yoğunluğu
- $\hat{f}_{bag}(c|j)$: j. örneğin c sınıfına ait tahminin ağırlıklı ortalama değeri

- N: Temel veri seti örnek sayısı
- C: Temel veri seti sınıf etiketidir.

Temel veri setinden sınıf etiketleri VAR ve YOK sayıları çıkarılarak F_i ve D_i değerleri hesaplandı. EV'lere ait F_i ve D_i değerleri ile sınıf etiketleri VAR ve YOK sayıları Çizelge 6.9'da verildi.

Çizelge 6.9. EV'lerin F_i ve D_i değerleri ile veri tabanı sınıf etiketleri sayısı

EV	VAR Sayısı	YOK Sayısı	Bulunma Yoğunluğu F_i (VAR Sayısı oranı)	Kullanma Yoğunluğu D_i (YOK Sayısı Oranı)
1	10027	7493	0,57	0,43
2	15673	1847	0,89	0,11
3	11483	6037	0,66	0,34
4	16549	971	0,94	0,06
5	9617	7903	0,55	0,45
6	14313	3207	0,82	0,18
7	16170	1350	0,92	0,08
8	10921	6599	0,62	0,38
9	10061	7459	0,57	0,43
10	11628	5892	0,66	0,34
11	14532	2988	0,83	0,17
12	15450	2070	0,88	0,12
13	11515	6005	0,66	0,34
14	11929	5591	0,68	0,32
15	7830	9690	0,45	0,55
16	12354	5166	0,71	0,29
17	10617	6903	0,61	0,39
18	12837	4683	0,73	0,27
19	7408	10112	0,42	0,58
20	12900	4620	0,74	0,26

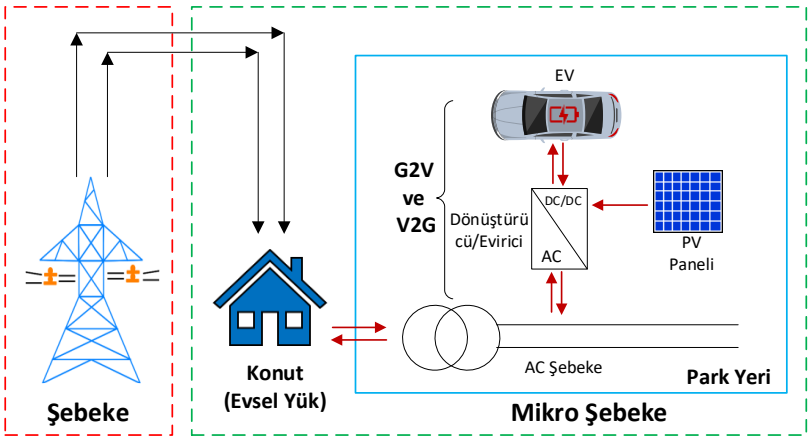
6.2. V2G topolojisinin simülasyonları ve uygulaması

Çalışmanın bu aşamasında V2G topolojisinin simülasyonları ve uygulaması gerçekleştirildi. Simülasyon çalışmalarında iki ayrı çalışma gerçekleştirildi. İlk çalışmada V2G topolojisinde enerji akış yönetimi için çift yönlü DC-DC dönüştürücü ve tek fazlı şebeke bağlantılı evirici simülasyonları gerçekleştirildi. İkinci çalışmada ise SVPWM anahtarlamalı üç fazlı şebeke bağlantılı evirici simülasyonları gerçekleştirildi. Simülasyon çalışmalarından sonra tek faz şebeke bağlantılı evirici ile bir batarya grubundan ana şebekeye enerji aktarılarak performans ölçümleri gerçekleştirildi.

6.2.1. V2G topolojisinde tek fazlı enerji akış yönetimi simülasyonu

Gerçekleştirilen simülasyon çalışmasında [147] tek fazlı V2G topolojisinde enerji akışı için bir mikro şebeke tasarlandı. Bu mikro şebeke içerisinde bir adet EV, bir adet konut ve bir adet güneş paneli (PV) bulunmaktadır. EV gündüzleri otoparkta iken PV ile şarj olmaktadır. Mikro şebekede güç kalitesinde bir problem olduğunda ise V2G topolojisi işletilerek EV bataryasından şebekeye enerji akışı gerçekleştirilmektedir. Bu sistemin işletilebilmesi için bir adet tek faz şebeke bağlantılı evirici ve bir adet çift yönlü DC-DC dönüştürücü tasarımı gerçekleştirilmiştir. Tasarlanan mikro şebekenin simülasyonları MATLAB/Simulink 2020b programında yapılmıştır. Simülasyon sonuçlarına göre EV bulunan evlerde ya da iş yerlerinde bu sistem kurularak PV ile EV bataryasının şarj edilmesi ve EV bataryasının mevcut mikro şebekede oluşabilecek güç kalitesi problemlerinin giderilmesinde kullanılması tek fazlı V2G topolojisi için bir çözüm önerisi sunmaktadır.

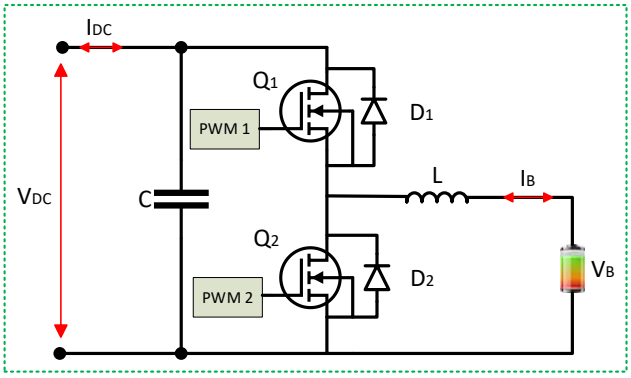
Tasarlanan sistem Şekil 6.12'de gösterildiği gibi ana şebeke, konut, EV ve PV olmak üzere dört temel bileşene sahiptir. Ana şebeke temel enerji kaynağıdır. Konut, EV ve PV ise mikro şebekeyi oluşturmaktadır. Tasarlanan mikro şebekede EV bataryası PV paneli ile şarj edilmektedir ve EV bataryası V2G topolojisi işletildiğinde şebeke bağlantılı eviriciye DC gerilim sağlamaktadır. EV bataryasının enerji akışını kontrol etmek için çift yönlü DC/DC dönüştürücü tasarımı gerçekleştirildi. V2G topolojisi işletildiğinde EV bataryasının sağladığı DC gerilim tasarlanan tek fazlı şebeke bağlantılı evirici ile şebekeye aktarılmaktadır.



Şekil 6.12. V2G topolojisinde enerji akışı için tek fazlı mikro şebeke tasarımı

Çift yönlü DC/DC dönüştürücü

Şekil 6.13'de verilen çift yönlü DC/DC dönüştürücünün temel amacı iki farklı DC gerilim seviyesi arasında enerji akışını sağlamaktır. Artıran ve azaltan olmak üzere 2 modu vardır. Artıran modunda düşük gerilim seviyesinden yüksek gerilim seviyesine enerji akışı sağlanır. Azaltan modunda ise yüksek gerilim seviyesinden düşük gerilim seviyesine enerji akışı sağlanır.



Şekil 6.13. Çift yönlü DC/DC dönüştürücü

Azaltan modunda yüksek gerilim seviyesinden (V_{DC}), düşük gerilim seviyesine (V_B) enerji akışı gerçekleştirilerek EV bataryası PV ile şarj edilir. Azaltan modunda Q1 MOSFET'i ve D2 diyotu iletimdedir. PV DC güç kaynağı olarak devreye bağlanır, EV bataryası ise devreye yük olarak bağlanır ve şarj olur. EV batarya voltajı V_B, kapasitör (C) ve indüktör (L) değerleri sırasıyla Eş. 6.13, Eş. 6.14 ve Eş. 6.15'deki gibi hesaplanır [147].

$$V_B = V_{DC} \times D_{Azaltan} \tag{6.13}$$

$$C_{Azaltan} = \frac{(1-D_{Azaltan})V_B}{8L_{Azaltan}\Delta V_B f_{sw}} \tag{6.14}$$

$$L_{Azaltan} = \frac{(V_{DC}-V_B)D_{Azaltan}}{\Delta I_L f_{sw}} \tag{6.15}$$

Bu eşitliklerde;

- V_B: Batarya voltajı
- V_{DC}: Azaltan modda PV voltajı
- $D_{Azaltan}$: Azaltan modda dönüşüm oranı

- $L_{Azaltan}$: Azaltan modda indüktör değeri
- $C_{Azaltan}$: Azaltan modda kapasitör değeri
- ΔV_B: Batarya voltajındaki dalgalılık
- ΔI_L: İndüktör akımındaki dalgalılık
- f_{sw}: Anahtarlama frekansıdır.

Artıran modunda ise düşük gerilim seviyesinden (V_B) yüksek gerilim seviyesine (V_{DC}) enerji akışı ile şebeke bağlantılı evirici beslenir. Artıran modunda Q2 MOSFET'i ve D1 diyotu iletimdedir. EV bataryası DC güç kaynağı olarak devreye bağlanır, evirici ise devreye yük olarak bağlanır. EV bataryası deşarj olarak eviriciyi besler. Artıran modunda evirici giriş gerilimi (V_{DC}), kapasitör (C) ve indüktör (L) değerleri sırasıyla Eş. 6.16, Eş. 6.17 ve Eş. 6.18'deki gibi hesaplanır [147].

$$V_{Dc} = \frac{V_B}{(1-D_{Artıran})} \tag{6.16}$$

$$C_{Artıran} = \frac{D_{Artıran} V_{DC}}{R_{ç} \Delta V_{DC} f_{sw}} \tag{6.17}$$

$$L_{Artıran} = \frac{V_B D_{Artıran}}{\Delta I_L f_{sw}} \tag{6.18}$$

Bu eşitliklerde;

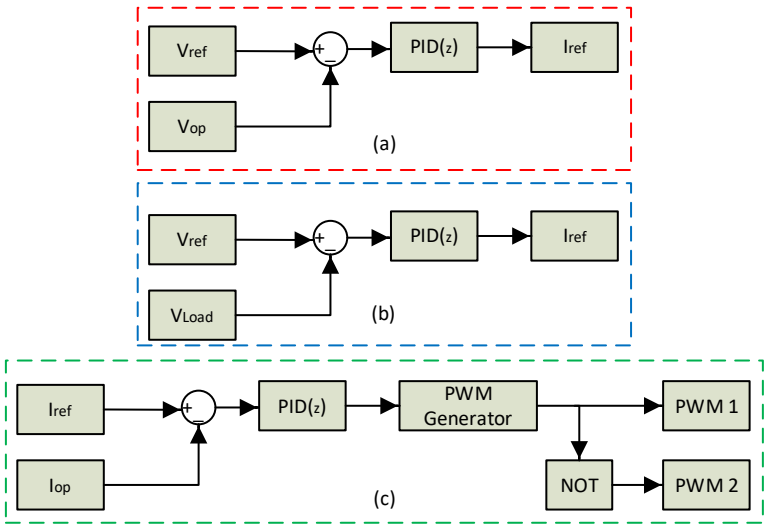
- V_B: Batarya voltajı
- V_{DC}: Artıran modda evirici giriş gerilimi
- $D_{Artıran}$: Artıran modda dönüşüm oranı
- $L_{Artıran}$: Artıran modda indüktör değeri
- $C_{Artıran}$: Artıran modda kapasitör değeri
- $R_{ç}$: Artıran modda çıkış empedansı
- ΔV_{DC}: Evirici girişi voltajındaki dalgalılık
- ΔI_L: İndüktör akımındaki dalgalılık
- f_{sw}: anahtarlama frekansıdır.

Çift yönlü DC/DC dönüştürücü azaltan ve artıran mod olmak üzere iki modda çalışmaktadır. Bu iki mod için ayrı ayrı L ve C değerleri hesaplandı. Çift yönlü DC/DC dönüştürücü için L ve C değerleri sırasıyla Eş. 6.19 ve Eş. 6.20'deki gibi belirlenir [147].

$$L = max\ (L_{Azaltan}, L_{Artıran}) \tag{6.19}$$

$$C = max\ (C_{Azaltan}, C_{Artıran}) \tag{6.20}$$

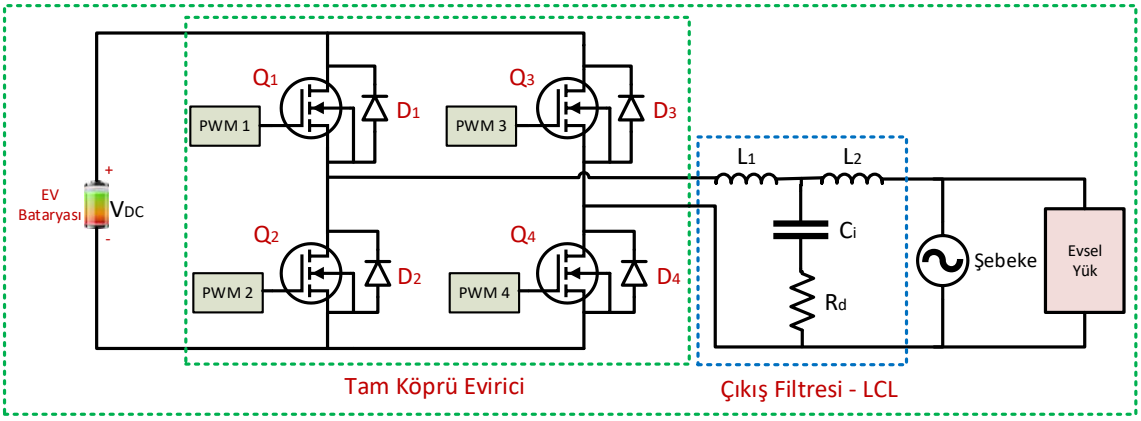
Çift yönlü DC/DC dönüştürücü kontrolü için üretilen PWM sinyalleri EV bataryasının şarj ve deşarjı için üretilen referans akımına (I_{ref}) göre belirlenir. EV bataryası şarj olurken verilen referans gerilimi (V_{ref}) ve bataryanın anlık çalışma gerilimi (V_{op}) ile PID kontrolü gerçekleştirilerek I_{ref} üretilir (Şekil 6.14. (a)). EV bataryası deşarj olurken verilen referans gerilimi V_{ref} ve evirici üzerindeki yük gerilimi (V_{Load}) ile PID kontrolü gerçekleştirilerek I_{ref} üretilir (Şekil 6.14. (b)). I_{ref} değeri ve bataryanın anlık çalışma akımı (I_{op}) ile PID kontrolü ile çift yönlü DC/DC dönüştürücü için PWM1 ve PWM2 kontrol sinyalleri üretilir (Şekil 6.14. (c)).



Şekil 6.14. Çift yönlü DC/DC dönüştürücü (a) Batarya şarj referans akımının (I_{ref}) üretilmesi (b) Batarya deşarj referans akımının (I_{ref}) üretilmesi(c) PWM kontrol sinyalinin üretilmesi

Tek faz şebeke bağlantılı evirici

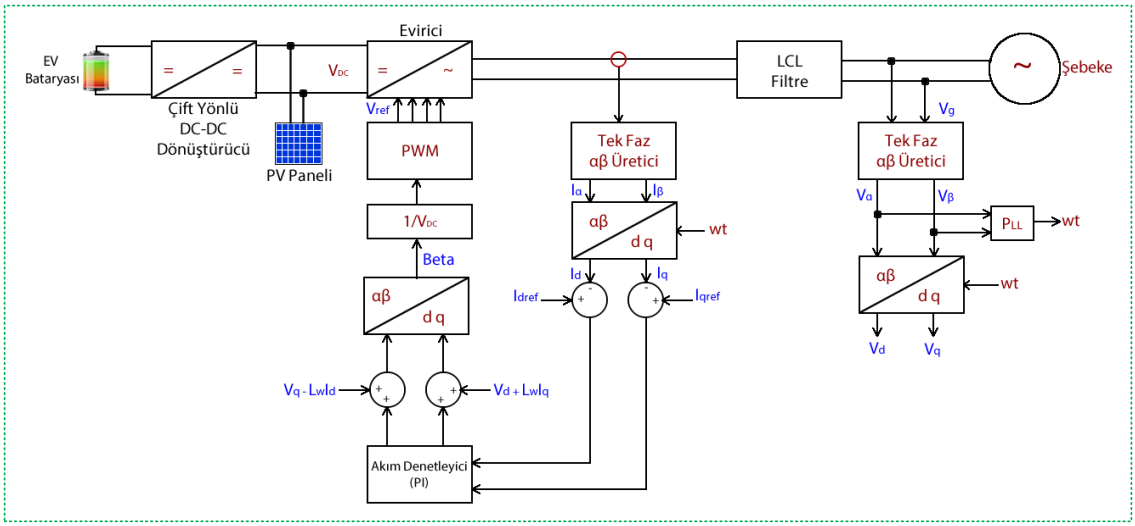
Tasarlanan sistemde V2G topolojisi işletildiğinde EV bataryasından şebekeye enerji Şekil 6.15'de verilen tek fazlı şebeke bağlantılı evirici ile aktarılmaktadır. V2G topolojisinde EV'nin bağlı olduğu mikro şebekede mevcut güç kapasitesinin üzerinde bir güç talebi olduğunda bu talebi karşılayabilmek için EV bataryası tek fazlı şebeke bağlantılı evirici ile şebekeye bağlanarak güç talebinin karşılanmasına yardımcı olur.



Şekil 6.15. Tek faz şebeke bağlantılı evirici

Tek faz şebeke bağlantılı evirici için tam köprü evirici tasarlandı. EV bataryasının şebeke bağlantısında ve enerji akış kontrolü için PWM sinyalleri kullanıldı. Tek faz şebeke bağlantılı evirici tasarımının blog diyagramı Şekil 6.16'da verilmiştir. Bu blog diyagramda PWM kontrol sinyalleri 5 adımda elde edilmiştir.

- Adım 1: Güç devresinin bağlanması
- Adım 2: α-β gerilimlerinin ve akımlarının üretilmesi
- Adım 3: PLL ve DQ trasformasyonunun oluşturulması
- Adım 4: PI ile akım kontrolünün yürütülmesi
- Adım 5: Güç devresi için PWM sinyallerinin üretilmesi



Şekil 6.16. Tek faz şebeke bağlantılı evirici blog diyagramı

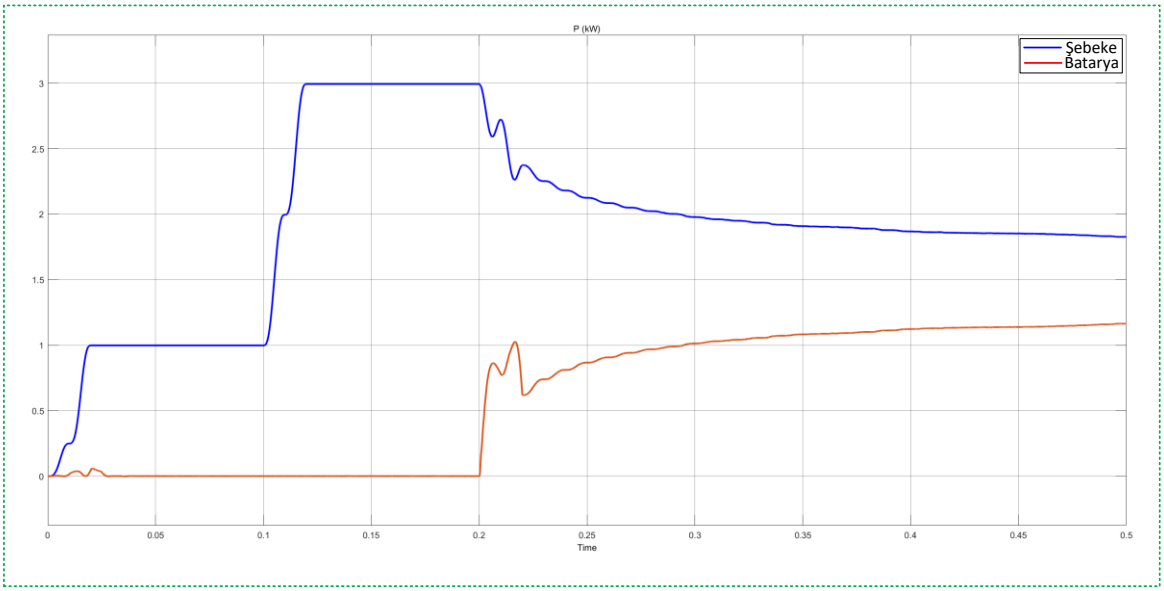
EV bataryasının şebekeye enerji aktarması esnasında eviricide kullanılan anahtarlama elemanlarından dolayı harmonikler oluşmaktadır. Şebeke bağlantılı eviricilerde şebekeye aktarılan temel frekans akımının toplam harmonik bozulma (THD) değeri uluslararası standartlara uygun olması gerekir. Standartlara uygun olarak EV bataryasından akımın şebekeye aktarılabilmesi için evirici çıkışında bir filtre kullanılması gereklidir. En yaygın kullanılan filtre çeşidi LCL filtredir, çünkü diğer filtrelerden daha küçük boyutta ve maliyet açısından daha ekonomiktir. Ancak, LCL filtresinin parametrelerinin belirlenmesi daha karmaşıktır. Bu nedenle, sistemin kararlı hal durumunu koruyabilmesi için parametrelerin doğru bir şekilde hesaplanması ve belirlenmesi gerekmektedir [147].

V2G topolojisinde enerji akışı için tasarlanan tek fazlı mikro şebeke simülasyonu için şebeke değerleri ile tasarlanan sistemin bileşen değerleri Çizelge 6.10'da verilmiştir. Bu değerler kullanılarak tasarlanan enerji akış modelinin simülasyonları gerçekleştirildi.

Çizelge 6.10. Tek faz enerji akış sisteminin bileşen değerleri

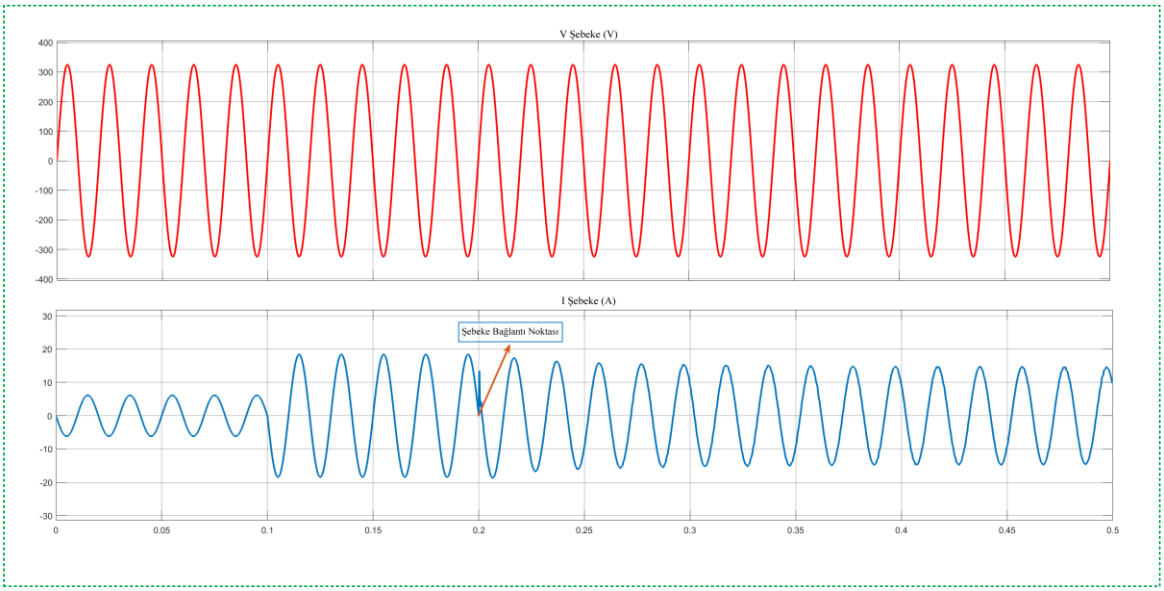
Sembol	Tasarlanan sistemin bileşenleri	Değerler
V_g	Şebeke voltajı	230 V
V_{Bch}	EV batarya şarj voltajı	330 V
V_{Bdch}	EV batarya deşarj voltajı	322 V
V_{PV}	PV çıkış voltajı	530 V
f_g	Şebeke Frekansı	50 Hz
f_{sw}	Anahtarlama frekansı	10 kHz
L	Çift Yönlü DC/DC dönüştürücü indüktörü	4 mH
C_i	Çift Yönlü DC/DC dönüştürücü kapasitörü	1000 μf
L_1	LCL filtrenin evirici tarafındaki indüktörü	4.06 mH
L_2	LCL filtrenin şebeke tarafındaki indüktörü	4.35 mH
C	LCL Filtre kapasitörü	6.01 μf
R_d	Sönümleme direnci	1 Ω

Şekil 6.17'de verilen tasarlanan sistemdeki şebeke ve EV bataryasının enerji akış grafiğinde gösterildiği gibi t=0 ile t=0,5 zamanları arasında gerçekleştirilmektedir. t=0'dan t=0,1 anına kadar şebeke 1kW'lık yük beslemektedir. t=0,15 anında şebekeye 2 kW'lık bir yük daha bağlanıyor ve şebeke toplamda 3 kW yükü besliyor. t=0,2 anında EV bataryası şebekeye bağlanıyor ve 3kW'lık yükün 1.8 kW'ı şebekeden 1.2 kW ise EV bataryasından karşılanıyor.



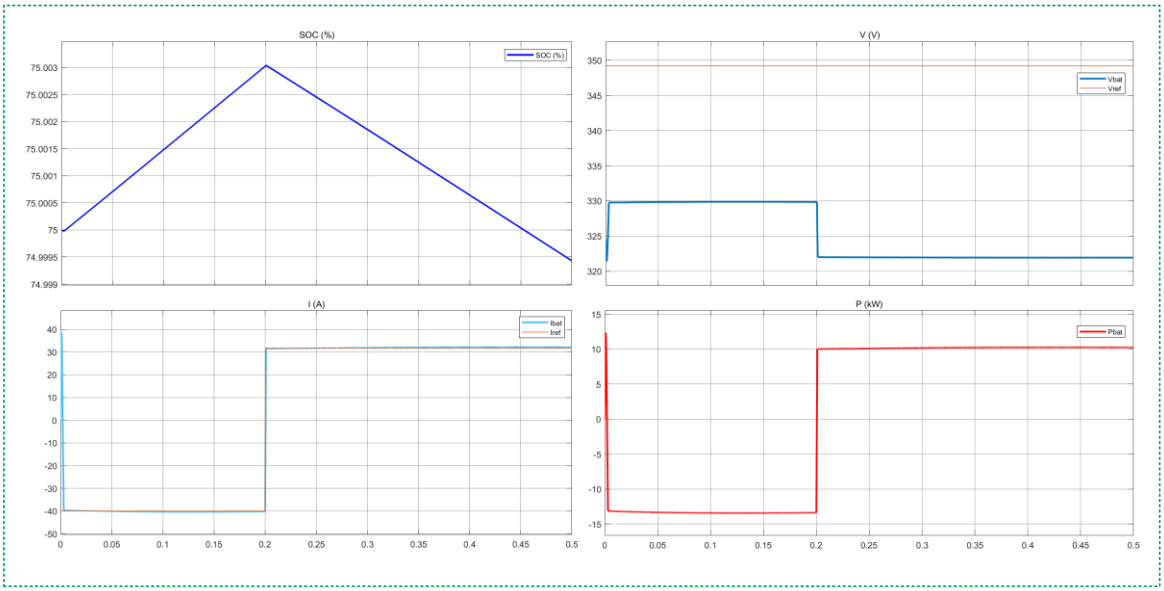
Şekil 6.17. Şebeke ve EV batarya enerji akış grafiği

Şekil 6.18'de tasarlanan sistemdeki şebekenin akım ve gerilim grafikleri verilmiştir. Simülasyon süresince şebeke gerilimi sabit kalmaktadır. t=0,1 anına kadar 1 kW'lık yük için şebeke akımı I_{RMS}= 4,3 A olarak ölçülmektedir. t=0.1 anında toplam yük 3kW olduğundan çekilen akım I_{RMS}= 12,7 A olarak ölçülmeye başlanıyor. t=0,2 anında şebekeye EV bataryası bağlandığında şebeke 3 kW'lık yükün 1,8 kW'lık kısmını beslemeye başladığından şebeke akımı I_{RMS}= 10,6 A e düşüyor.



Şekil 6.18. Tasarlanan sistemde şebekenin akım gerilim grafiği

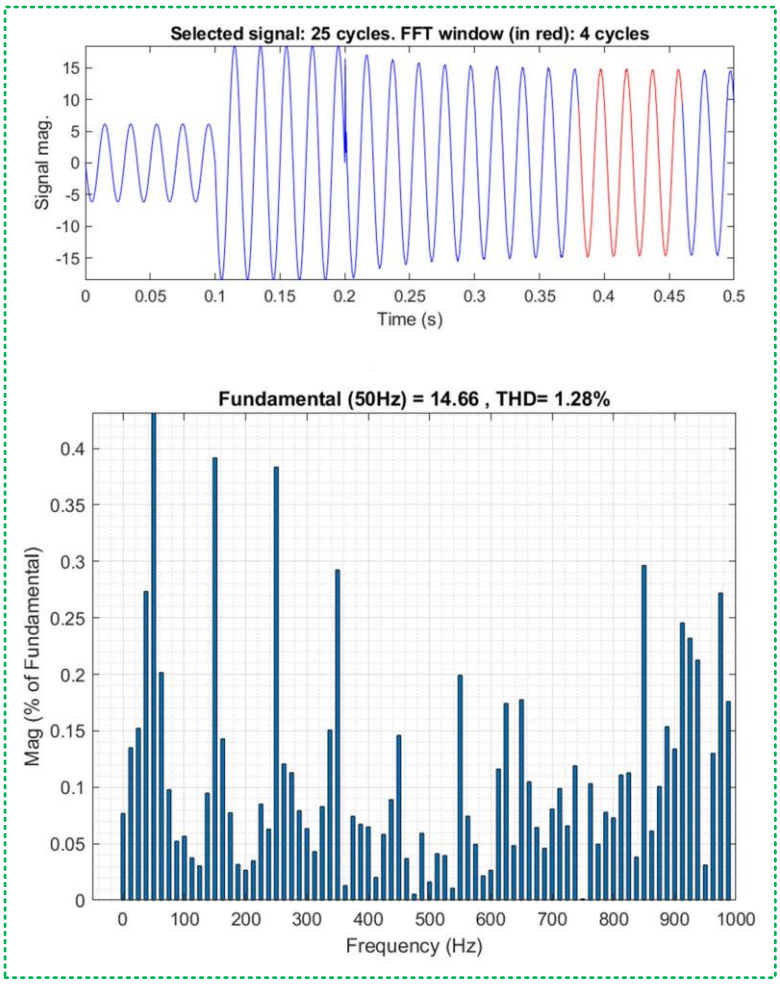
EV bataryasına ait akım, gerilim, SOC ve güç değerlerinin değişim grafiği Şekil 6.19'da verilmiştir. t=0,2 anına kadar PV çift yönlü DC/DC dönüştürücünün azaltan modunda EV bataryasını şarj ediyor. t=0,2 anından t=0,5 anına kadar çift yönlü DC/DC dönüştürücünün artıran modunda EV bataryası tek fazlı şebeke bağlantılı evirici ile şebekeye enerji akışı sağlayarak desteklemektedir. t=0,2 anına kadar EV bataryasının SOC değeri artarken t=0,2 anından sonra SOC değeri azalmaya başlıyor. EV bataryası 330 V 40A ile şarj olmaktadır, 322 V 32 A ile deşarj olmaktadır. Akım grafiğinden akımın şarj ve deşarj arsında yön değiştirdiği görülmektedir.



Şekil 6.19. EV bataryasının SOC, akım, gerilim ve güç grafiği

Şebekeden çekilen akımın THD değerinin IEEE-519 harmonik standartlarına göre; %5'ten küçük olması gerekmektedir. Yapılan FFT analizi ile Şekil 6.20'de verildiği gibi şebekenin THD değeri %1.28 olarak belirlendi.

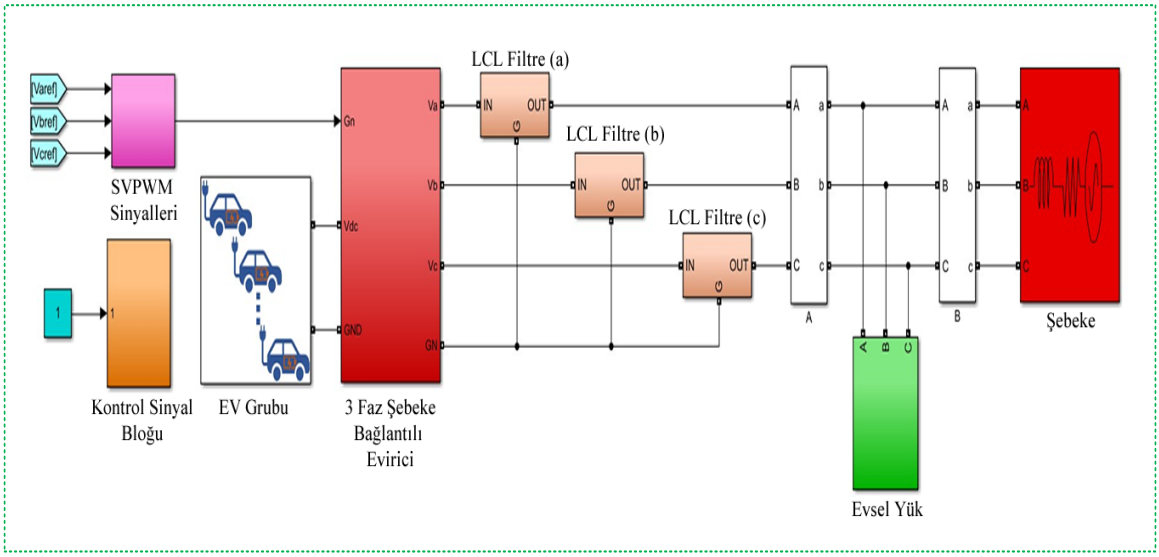
Simülasyon sonuçları ile tasarlanan sistemin verimli olduğu görülmüştür. Tasarlanan sistemde PV ile EV bataryası şarj edilmiş ve ana şebeke EV bataryası ile desteklenmiştir.



Şekil 6.20. Şebekenin FFT analizi ile THD değerinin belirlenmesi

6.2.2. V2G topolojisinde üç fazlı enerji akış yönetimi simülasyonu

Bu simülasyon çalışmasında [107] çift yönlü üç fazlı yarım köprü şebeke bağlantılı eviricinin simülasyonu gerçekleştirildi. Üç fazlı şebeke bağlantılı eviricilerde anahtarlama elemanlarında kapı sinyalleri üretmek için SVPWM tekniği kullanılmıştır. Simülasyon çalışmasında bir bina ve bu binada bulunan EV'ler için oluşturulan V2G ve G2V topolojilerini kullanan Şekil 6.21'de gösterilen bir mikro şebeke tasarlanmıştır. Tasarlanan bu mikro şebekede, binada bulunan yükler ve EV'lerin şarjı için 120 kW enerji akışı sağlanmaktadır. Bina içerisinde şebekeye fazladan yük eklendiğinde şebekeyi desteklemek için 120 kW'lık enerjinden fazlası şebeke içerisinde bulunan elektrikli araçlardan sağlanmaktadır. Diğer bir ifade ile V2G topolojisi işletilmektedir.

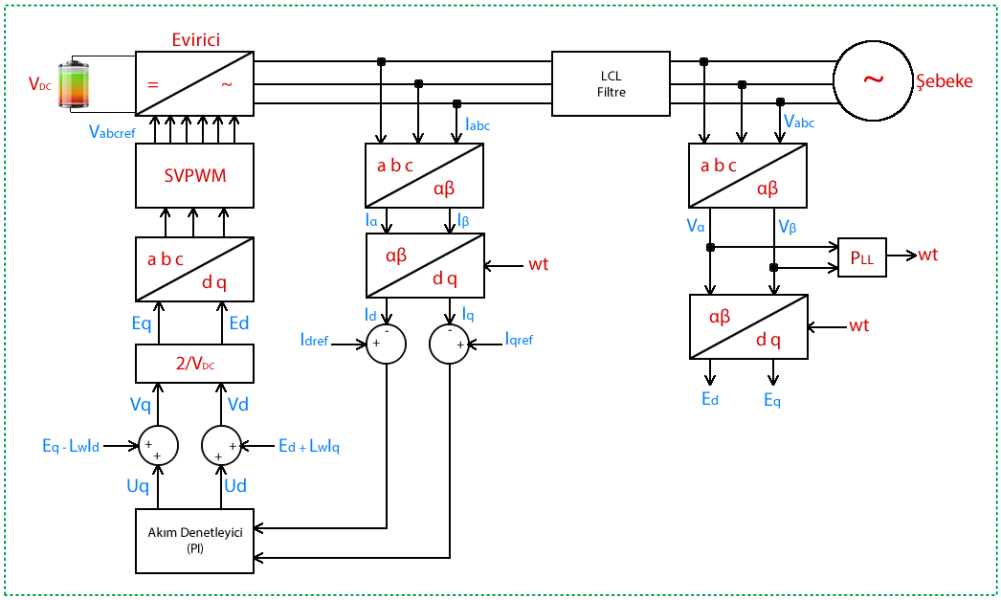


Şekil 6.21. V2G topolojisinde kullanılan üç fazlı şebeke bağlantılı evirici modeli

Bu çalışmamızda V2G topolojisinde kullanılan şebeke bağlantılı yarım köprü evirici ve eviriciler için filtre tasarımı gerçekleştirilmiştir. Belirlenen parametre değerlerine göre LCL filtrenin THD performansı, LC ve L filtreler ile karşılaştırılarak daha iyi olduğu gösterilmiştir. Yapılan simülasyonlar ile G2V ve V2G topolojileri incelenmiştir. Gerçekleştirilen sistemin parametreleri Çizelge 6.11'de belirlenmiştir ve Şekil 6.22'de simülasyonun akış diyagramı oluşturuldu ve bu akış diyagramı yardımıyla MATLAB 2020b/Simulink ortamında simülasyon gerçekleştirildi.

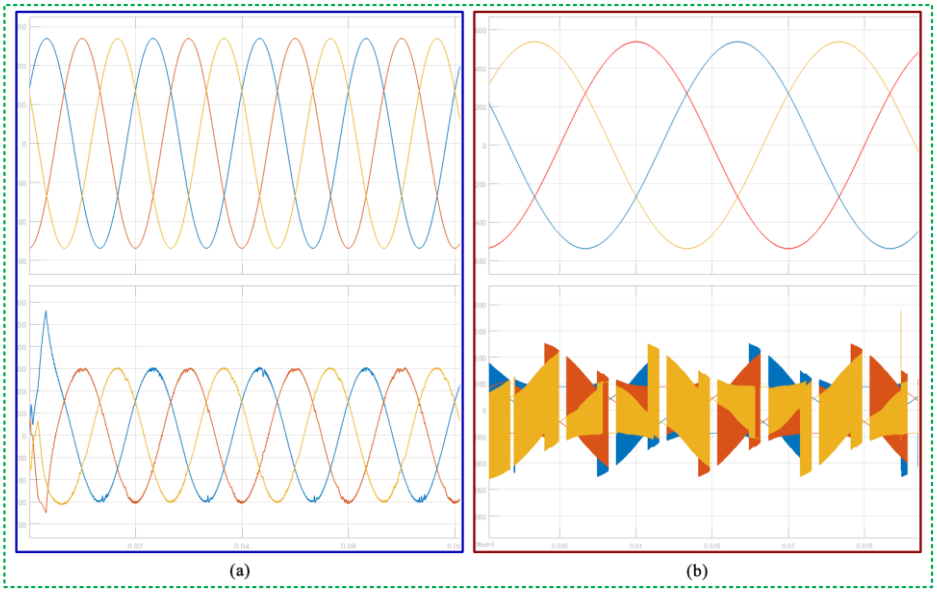
Çizelge 6.11. Üç faz enerji akış sisteminin bileşen değerleri

Sembol	Tasarlanan sistemin bileşenleri	Değerler
f_g	Şebeke Frekansı	50 Hz
f_s	Anahtarlama frekansı	10 kHz
V_g	Şebeke gerilimi	380 V
V_{dc}	DC hat (Batarya) voltajı	800 V
L_1	LCL filtrenin evirici tarafındaki indüktörü	1 mH
L_2	LCL filtrenin şebeke tarafındaki indüktörü	500 µH
C	LCL Filtre kapasitörü	100 µf
R_d	Sönümleme direnci	10 Ω



Şekil 6.22. Üç faz şebeke bağlantılı evirici blog diyagramı

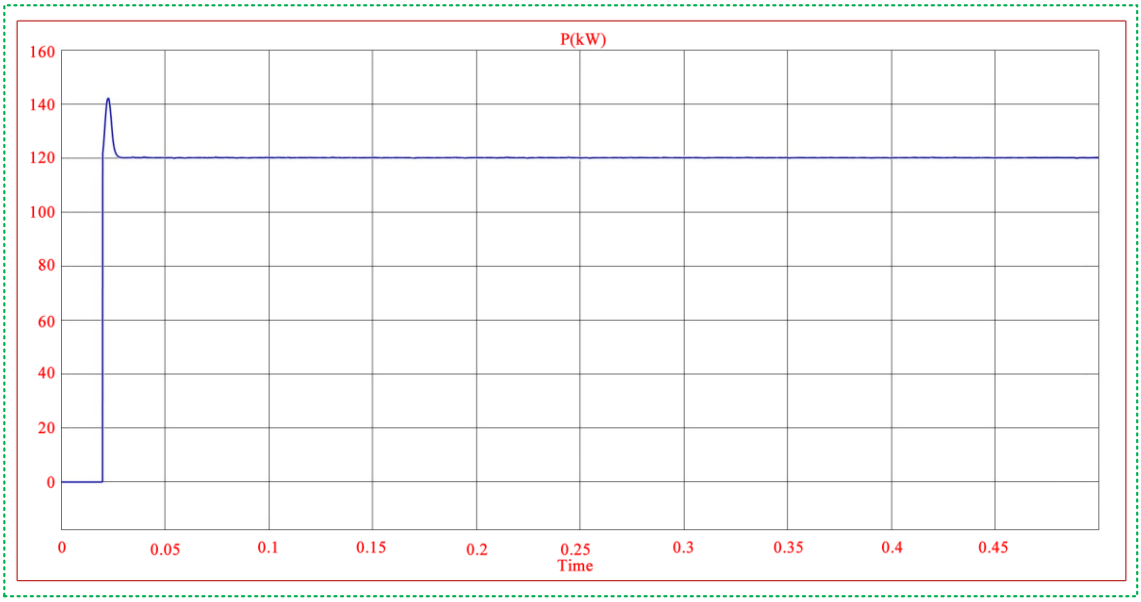
Bilindiği gibi bir eviricinin girişinde DC sinyal vardır ve çıkışında da AC sinyal vardır. Eviricinin çıkış sinyali saf sinüs dalga olmalıdır. Fakat pratik bir eviricinin çıkış gerilimi harmonikler ve dalgalanmalar içerir. Bu dalgalanmalar ve harmonikler filtre kullanılarak bastırılır. Ayrıca şebeke bağlantılı eviricilerde şebeke ile evirici çıkış gerilimlerinin ve akımlarının faz açıları örtüşmelidir. Filtre kullanılarak evirici sinyali ile şebeke sinyalinin faz açılarının kısa sürede üst üste bindirilmesi sağlanır. Şekil 6.23'de şebeke bağlantılı eviricinin 3 faz V-I (Gerilim-Akım) grafiği verilmiştir.



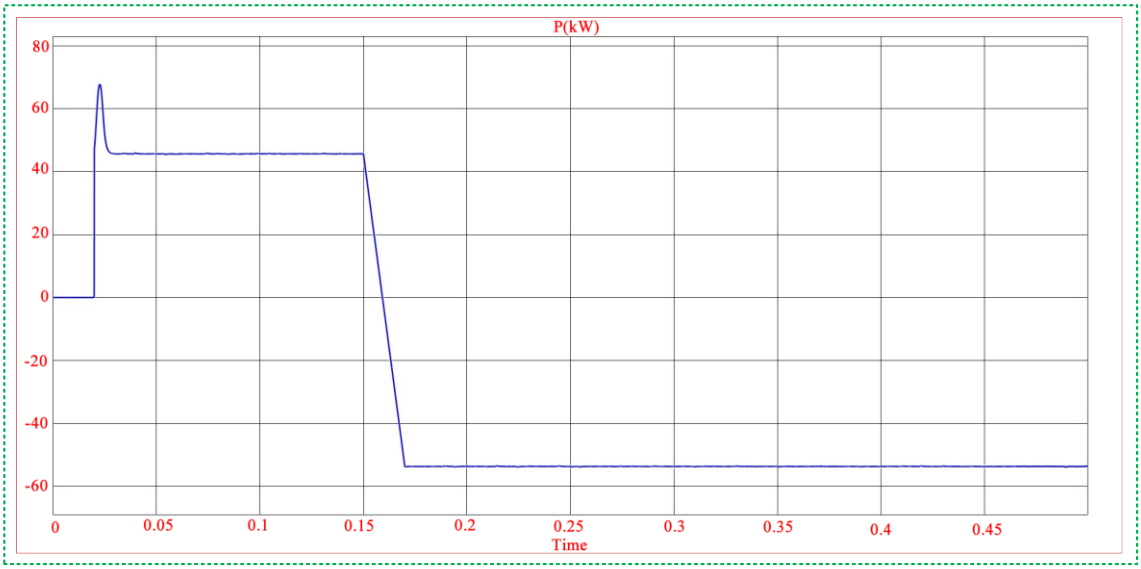
Şekil 6.23. 3 faz evirici çıkışının V-I grafiği a) LCL filtreli b) Filtresiz

Şekil 6.23 a'da LCL filtre kullanılmış şebeke bağlantılı eviricinin V-I grafiği verilmiştir. Şekilden de görüldüğü gibi harmonikler bastırılmış ve faz açıları ayarlanmıştır. Filtre çıkarılarak simülasyon tekrarlanmış ve Şekil 6.23 b'de filtresiz V-I grafiği verilmiştir. Akım grafiğinde faz açılarının örtüşmediği ve harmoniklerin olduğu görülmektedir.

Simülasyondaki mikro şebeke toplamda 120kW lık enerjinin 75 kW'lık kısmı ile evsel yükü beslemekte ve 45 kW'lık kısmı ile şarj istasyonunda bulunan EVleri şarj etmektedir. Burada G2V topolojisi işletilmektedir. Şebekeye 100 kW'lık ikinci bir evsel yük bağlanıyor. Şebeke talep edilen 175 kW lık enerjiyi sağlayamadığı için V2G topolojisi işletilmeye başlanıyor. Şebekenin ihtiyaç duyduğu 55 kW'lık kısım (175 kW- 120 kW = 55 kW) şarj istasyonunda bulunan EV'lerin bataryalarından sağlanmaktadır. Şekil 6.24'de şebekenin enerji akış grafiği verilmiştir. Şekil 6.25'de ise EV'lerin enerji akış grafiği verilmiştir. EV'ler G2V topolojisinde şebekeden 45 kW lık enerji çekerek bataryaları şarj olmaktadır. V2G topolojisi süresince ise EV'ler şebekeye 55 kW lık enerji desteği vererek toplamda 175 kW lık yükün beslenmesi sağlanmaktadır.

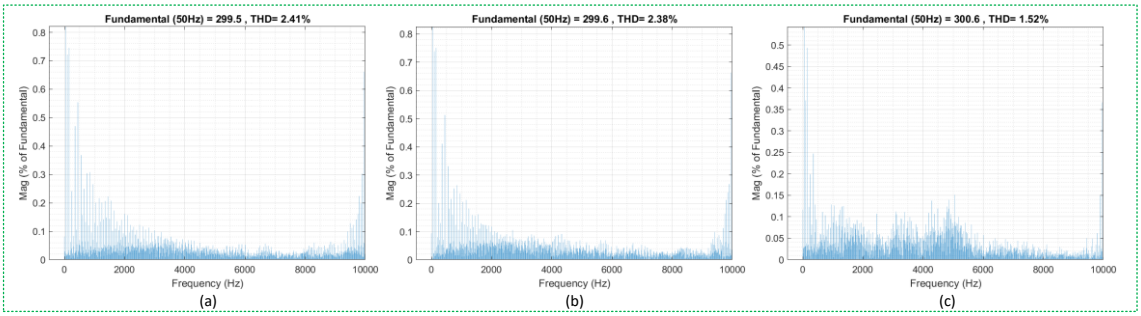


Şekil 6.24. Şebekenin enerji akış grafiği



Şekil 6.25. Ev batarya grubunun enerji akış grafiği

V2G topolojisi için kullanılan üç fazlı şebeke bağlantılı evirici modelinde simülasyonlar sırasıyla L, LC, LCL filtreler için gerçekleştirilerek THD değerlerine bakıldı. IEEE-519 harmonik standartlarına göre; şebekeden çekilen akımın THD değerinin %5'ten küçük olması gerektiği vurgulanmıştı. Her üç filtre içinde THD değeri %5 den küçüktür. Sırasıyla L, LC, LCL filtreleri için FFT analizleri yapılarak sonuçları Şekil 6.26'da verilmiştir.

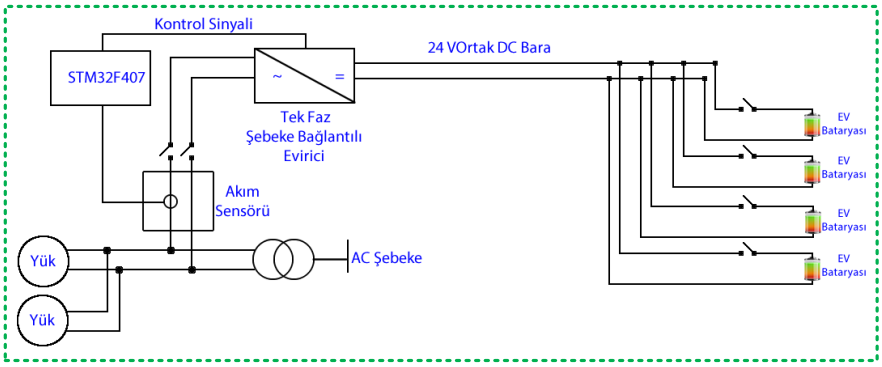


Şekil 6.26. FFT analizi (a) L Filtre için (b) LC Filtre için (c) LCL Filtre için

Yapılan FFT analiz sonuçlarına bakıldığında L, LC, LCL filtreleri için THD değeri sırasıyla %2,41, %2,38 ve %1,52 olarak ölçülmüştür. LCL filtrenin diğerlerine göre daha iyi sonuç verdiği görülmektedir. Simülasyon sonuçları ile tasarlanan sistemin verimli olduğu görülmüştür. Tasarlanan mikro şebekede G2V ve V2G topolojilerinde enerji akışı gerçekleştirilmiştir.

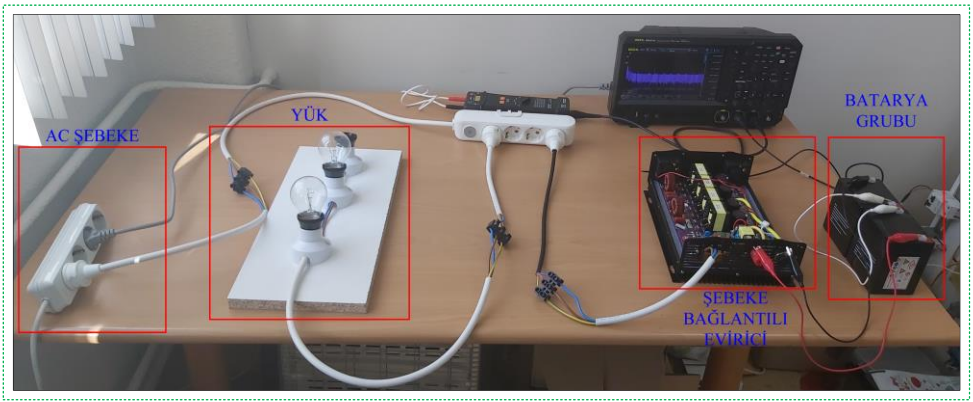
6.2.3. Tek fazlı şebeke bağlantılı evirici uygulaması

Bu tez çalışmasında önerilen V2G topolojisinde araçtan şebekeye enerji aktarılmaktadır. Bu nedenle V2G topolojisinin uygulanabilirliğini göstermek için laboratuvar ortamında Şekil 6.27'de verilen tek fazlı şebeke bağlantılı evirici sistem mimarisi gerçekleştirilerek ölçümler yapılmış ve sistemin uygulanabilirliği gösterilmiştir.



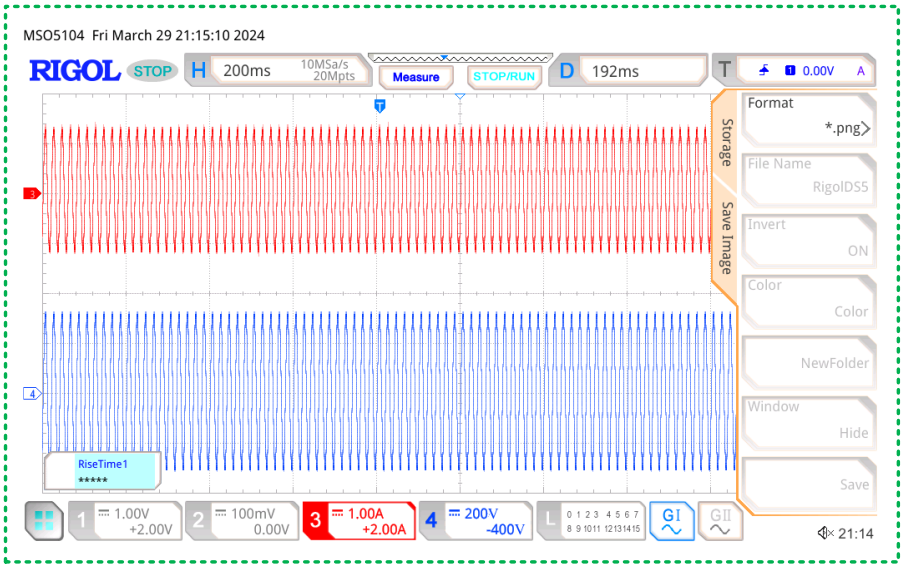
Şekil 6.27. Tek fazlı şebeke bağlantılı evirici sistem mimarisi

V2G topolojisinde, iki adet EV'yi temsil edecek 2 adet 12 V-5 Ah batarya kullanılarak 24 V DC gerilim ile 1000W tek fazlı şebeke bağlantılı evirici girişine uygulanmıştır. Şekil 6.28'de gösterilen deney düzeneği kurularak osiloskop ölçümleri gerçekleştirilmiştir. Bu düzenekte yük olarak 2 adet 100 W akkor flamanlı ampul kullanılmıştır.



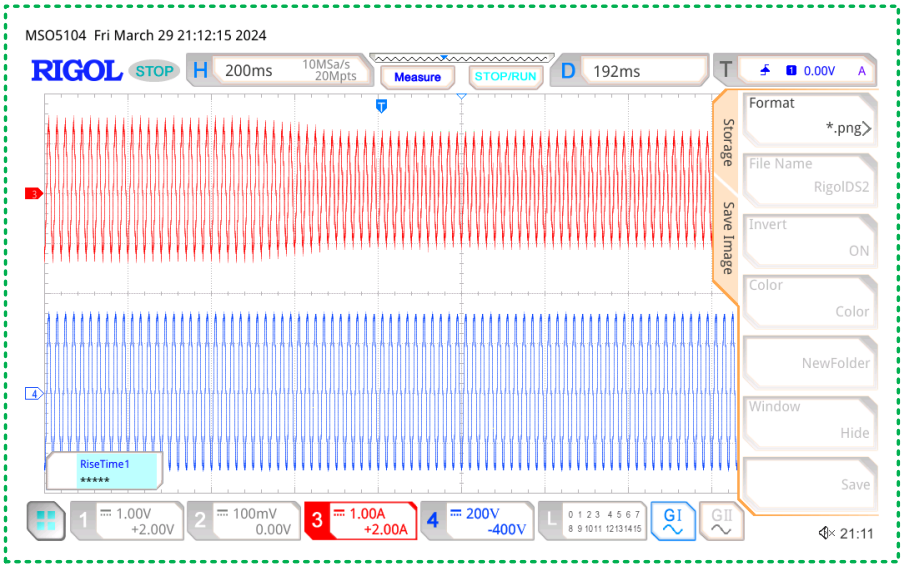
Şekil 6.28. Tek fazlı şebeke bağlantılı evirici deney düzeneği

Gerçekleştirilen deneysel çalışmada ilk ölçümde Şekil 6.29'da verilen ana şebekenin akım ve gerilim değerleri osiloskop ile ölçüldü. Gerçekleştirilen ölçümde gerilimin değerleri V_m=321 V, V_{rms}=227 V ve akım değerleri I_m=1,4 A, I_{rms}=0,99 A olarak ölçüldü.



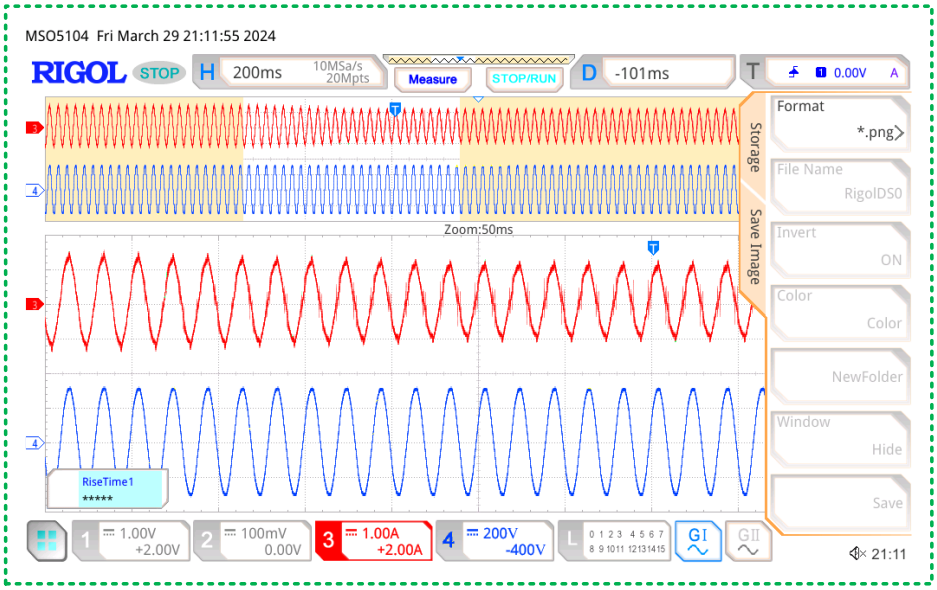
Şekil 6.29. AC ana şebeke akım ve gerilim ölçümü

İkinci olarak şebeke bağlantılı evirici, ana şebekeye bağlandıktan sonra Şekil 6.30'da verilen ana şebekenin akım gerilim değerleri ölçüldü. Ana şebekenin gerilim değerinde değişim olmadı. Akım değeri ise I_m=1,1 A, I_{rms}=0,78 A olarak ölçüldü. Buradan bataryalar ile şebekenin 47,7 W güç ile desteklendiği görülmektedir.



Şekil 6.30. Evirici şebekeye bağlandıktan sonraki şebeke akım ve gerilim grafiği

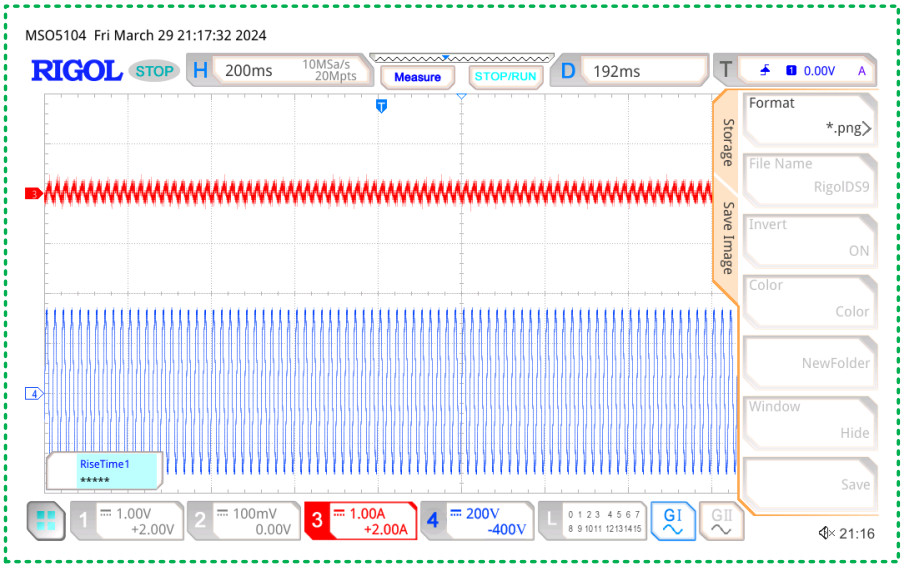
Üçüncü olarak eviricinin şebekeye bağlandığı an yakınlaştırılarak Şekil 6.31'de verilen akım gerilim değerlerinin değişimi ölçüldü.



Şekil 6.31. Evirici bağlanma sürecinde ana şebeke akım ve gerilim değişimi

Burada bataryadan ana şebekeye enerji akışı gerçekleştirildiği için gerilim değerinin sabit olduğu ve akım değerinin azaldığı görülmektedir.

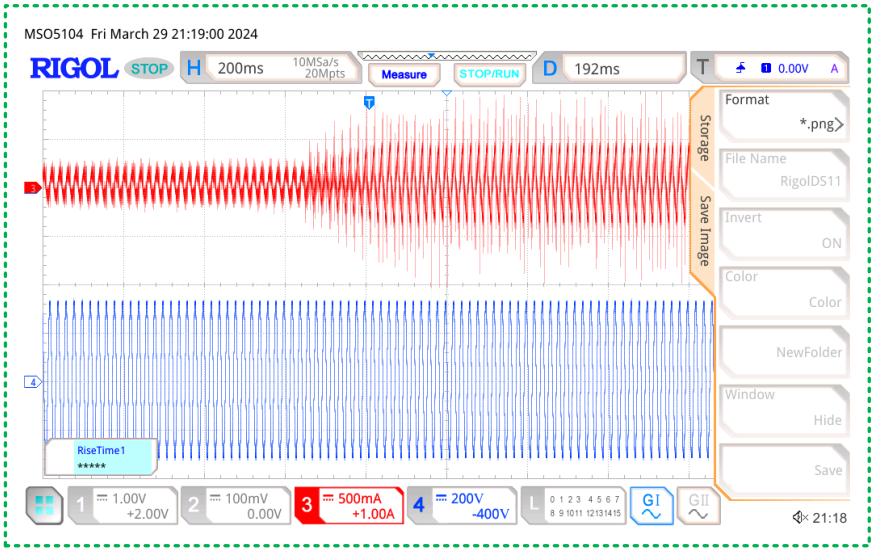
Daha sonra Şekil 6.32'de verilen evirici üzerindeki akım ve gerilim değişimleri ölçüldü. V_m=321 V, V_{rms}=227 V, I_m=0,2 A, I_{rms}=0,141 A olarak ölçüldü.



Şekil 6.32. Evirici akım ve gerilim ölçümü.

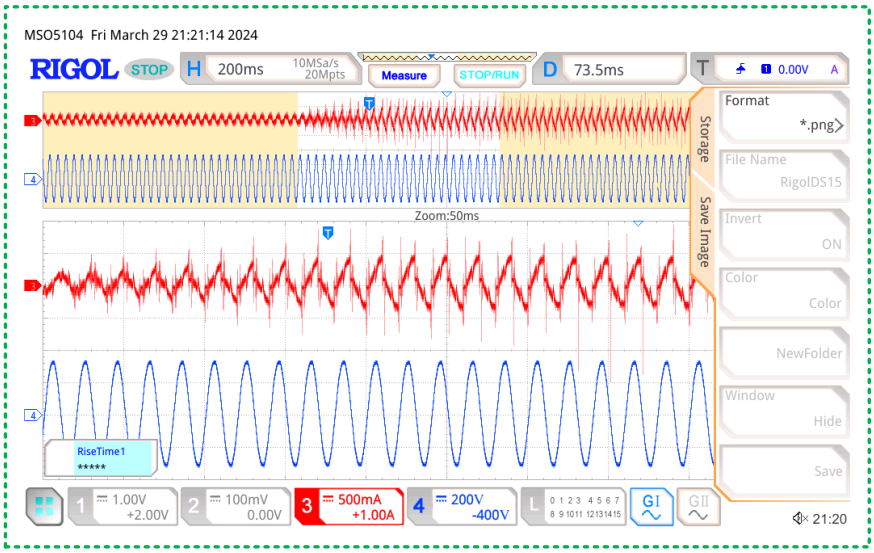
Bir diğer ölçümde ise Şekil 6.33'de verilen evirici şebekeye bağlandığında evirici üzerindeki akım ve gerilim ölçümleri gerçekleştirildi. Gerilim değerinde bir değişim

olmadı, akım değerinde ise dalgalanmalar oluştu. V_m=321 V, V_{rms}=227 V, I_m=0,3 A, I_{rms}=0,212 A olarak ölçüldü.



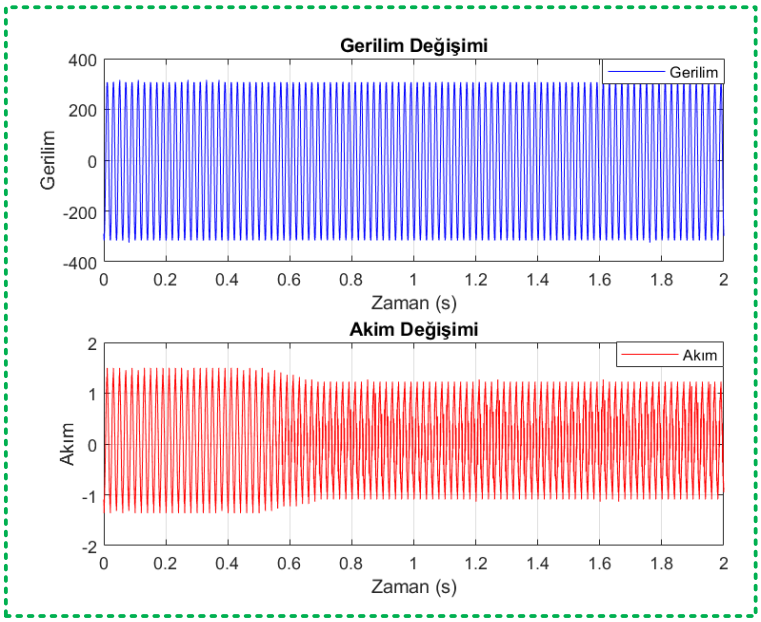
Şekil 6.33. Evirici şebekeye bağlandığında evirici akım ve gerilim ölçümleri

Bu ölçümde evirici şebeke bağlandığında bataryalardan ana şebekeye enerji akışı gerçekleşmeye başlıyor ve eviricinin sağladığı akım artmaktadır. Bir önceki ölçümde şebeke bağlanma anı yakınlaştırılarak Şekil 6.34'de verilen evirici üzerindeki akım ve gerilim grafiği tekrardan ölçüldü. Bu ölçümde akım üzerindeki dalgalanmalar görülmektedir. Bu dalgalanmalar şebeke üzerinde harmonikler oluşmasına neden olmaktadır.



Şekil 6.34. Eviricinin şebekeye bağlanma anı akım ve gerilim ölçümü

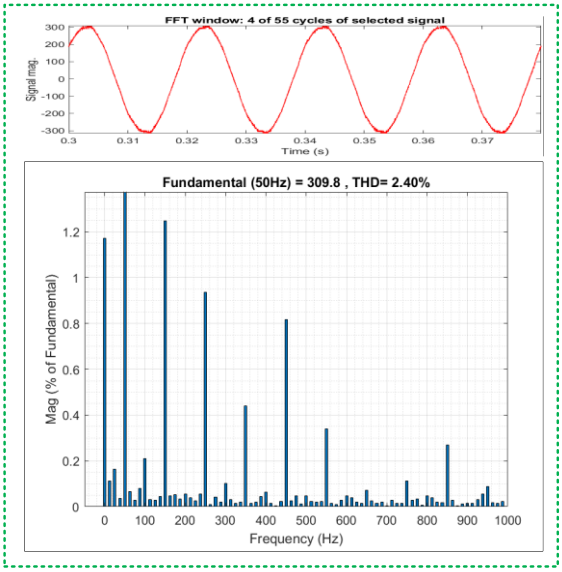
Türkiye'deki elektrik şebekesinde THD ile ilgili sınır değerleri T.C. Enerji Piyasası Düzenleme Kurumu (EPDK) tarafından belirlenen standartlara dayanmaktadır. Bu sınır değerler, şebekenin güvenilirliği, enerji kalitesi ve elektrikli cihazların korunması açısından önemlidir. Alçak gerilim şebekelerinde THD değeri gerilim için THDv ≤ %8 olmalıdır, akım için ise THDi ≤ %20 olmalıdır. Orta gerilim şebekelerinde ise THD değeri Gerilim için THDv ≤ %5 olmalıdır, akım için ise THDi ≤ %12 olmalıdır. Bu sınırlar, genellikle IEC 61000-3-2 ve IEC 61000-3-4 gibi uluslararası standartlarla uyumlu olacak şekilde belirlenmiştir. Standartlar, özellikle tüketicilerin bağlı olduğu şebekelerdeki harmonik bozunumunun kontrol altında tutulmasını amaçlar. Harmoniklerin yüksek olması, şebeke ekipmanlarına zarar verebilir, enerji kayıplarını artırabilir ve genel enerji kalitesini düşürebilir. Bu nedenle, bu değerlerin düzenli olarak izlenmesi ve kontrol edilmesi önemlidir [148]. Tasarlanan sistemin ana şebeke üzerindeki etkileri FFT analizi ile THD değerleri ölçülerek belirlendi. THD ölçümü için osiloskop ile gerçekleştirilen ölçüm değeri “csv” formatında kaydedildi. Kaydedilen dosyadaki veriler kullanılarak MATLAB/Simulink programında FFT analizi ile gerilim ve akım için THD değerleri ölçüldü. İlk olarak dosyadan okutulan sinyalin Şekil 6.35’de verilen akım ve gerilim grafiği MATLAB’da çizdirildi.



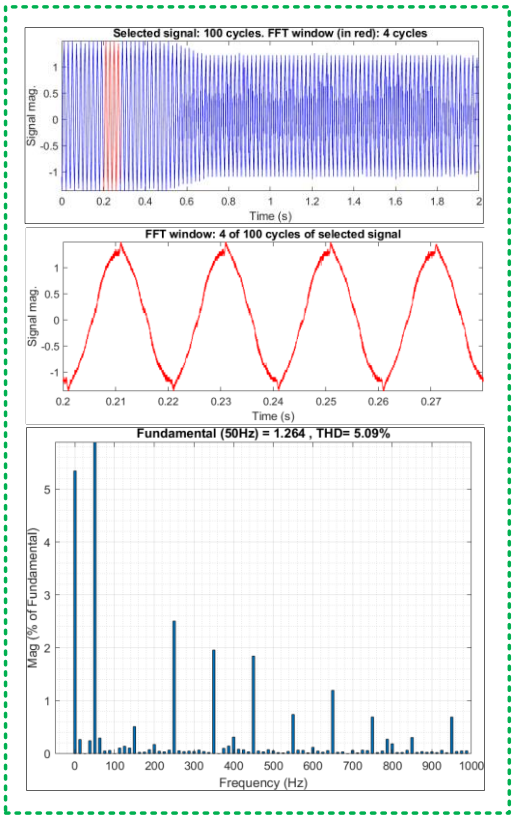
Şekil 6.35. Şebeke akım ve geriliminin csv dosyasından MATLAB ile çizdirilmesi

Daha sonra Şekil 6.36’da verilen gerilim için FFT analizi yapılarak THDv değeri %2,40 olarak ölçüldü. Gerilim için THD değerinin değişmediği tespit edildi. Akım için de FFT

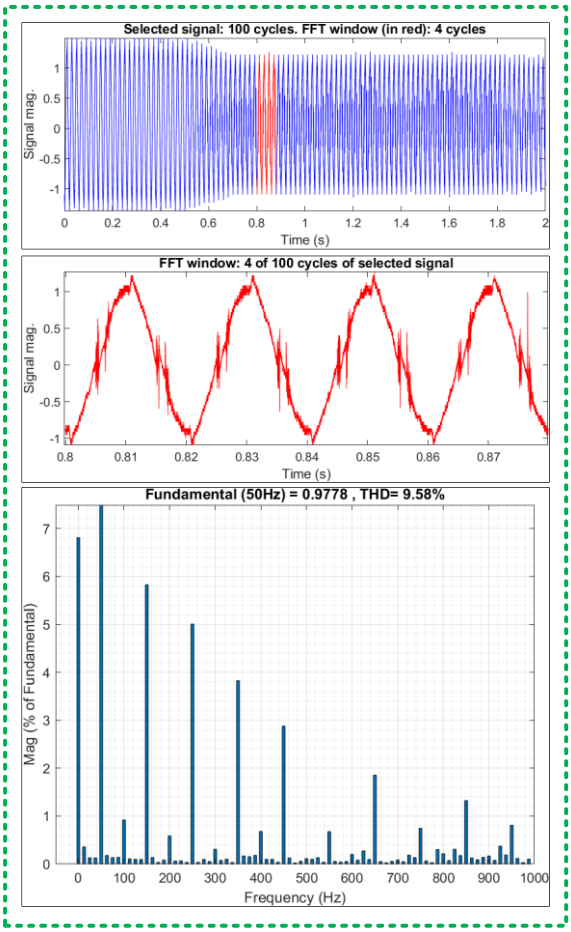
analizi yapılarak THDi değeri Şekil 6.37'de verilen evirici bağlanmadan önce %5,09 olarak ölçüldü, Şekil 6.38'de verilen evirici bağlandıktan sonra ise %9,58 olarak ölçüldü.



Şekil 6.36. Gerilimin FFT analizi



Şekil 6.37. Evirici bağlanmadan önce akımın FFT analizi



Şekil 6.38. Evirici bağlandıktan sonra akımın FFT analizi

Şekil 6.37 ve Şekil 6.38'de ana şebek akımının THDi değerinin attığı görülmektedir. Şebeke bağlantılı evirici ile bataryalardan ana şebekeye enerji akışı gerçekleştirildiğinde THDi değeri %5,09'dan %9,58'e çıkmaktadır. THDi değeri %4,49 artmaktadır. Bu artış EPDK'nın belirlediği sınırlar içerisinde gerçekleşmektedir.

7. SONUÇ VE ÖNERİLER

Dünya genelinde EV'lerin ana şebekelerdeki arz-talep dengesini bozacak kadar artması mevcut ana şebekeye öngörülemeyen büyük yükler bindirecektir. Bu nedenle EV'ler ana şebekenin güç kalitesini giderek daha fazla tehdit etmektedir. Özellikle, şebeke arzı ile talep arasındaki dengesizliğin büyümesi, enerji sistemleri açısından en büyük tehditlerden biri olarak öne çıkmaktadır. Bu dengesizliğin, enerji kaynaklarının hızla artırılması veya mevcut altyapının kapsamlı bir şekilde revize edilmesi gibi çözümlerle giderilmesi mümkün görünmüyor; çünkü bu tür yaklaşımlar hem yüksek maliyetli hem de uzun vadeli olacaktır.

Bu bağlamda, EV'lerin şebeke entegrasyonu koordineli bir şekilde gerçekleştirilmeli, yani enerji akışının etkin bir şekilde yönetilmesi, kaçınılmaz hale gelmektedir. Şebeke kararlılığının korunması ve enerji arz-talep dengesinin sağlanması için, V2G topolojisinde enerji akışını kontrol edebilecek çözümler ön plana çıkmaktadır. Bu tür akıllı yönetim sistemleri, EV'lerin şebekeye entegre olmasını sağlarken, enerji arz-talep dengesizliklerini minimuma indirecek ve şebeke kararlılığını koruyacak yaklaşımlardır.

Bir diğer önemli husus da mikro şebeke yaklaşımıdır. EV'lerin şebeke entegrasyonu ile bozduğu arz talep dengesine yerel çözümler üretmek maliyet ve zaman açısından daha avantajlı olacaktır. Bu yerel kontrol stratejisi daha sonra birleştirilerek merkezi kontrol stratejisine dönüştürülebilir. Bu bağlamda bu tez çalışmasında V2G teknolojisinde ML tabanlı özgün bir enerji akış yönetimi önerilmektedir. Enerji akış yönetiminin yapılacağı bir mikro şebeke tasarlandı. Bu mikro şebekede ML tabanlı enerji akış yönetimi için Türkiye'nin Başkenti Ankara'da yer alan bir konut sitesindeki 20 araç kullanıcısına ait özgün bir veri seti kullanılmıştır.

Bu 20 araçın otoparka giriş-çıkış saat ve tarih bilgilerini içeren veri seti bir sınıflandırma problemi haline getirilerek 22 farklı ML yönteminde eğitilmiştir. Eğitim sonuçları ile performans kriterleri incelendiğinde en başarılı yöntemin Bagged Trees olduğu belirlendi. Bagged Trees yönteminin performans kriterlerinden doğruluk oranı %95 olarak belirlendi. Ortalama eğitim süresi ise 132,49 saniye olarak ölçüldü. Bu değerlerin geliştirilen model ve gerçek uygulamalar için kabul edilebilir olduğu tespit edildi.

V2G topolojisi işletildiğinde şebekeye bağlanacak EV seçimi için bir model önerildi. Bu modelde "*Araç Seçim Değeri (Esi)*" parametresi belirlendi ve matematiksel modeli geliştirildi. Es_i parametresi tahmin sınıfına ait Ps_i, araçların SOC_i ve F_i değerleri kullanılarak hesaplandı. Araçlar EV olmadığından *SOC* değerlerinin belirlenmesi için bir matematiksel model önerildi. Bu modelde her bir aracın kullanım yoğunluğu hesaplanarak bu değere göre 20 araç için yıl boyunca *SOC* değeri belirlendi. Geliştirilen sistemde her 30 dakikada bir, yeni veriler temel veri setine eklenmektedir. Bu süre baz alındığında Bagged Trees ortalama eğitim süresi olan 132,49 saniyenin geliştirdiğimiz model için uygun olduğu görülmektedir.

Bu tez çalışmasında önerilen V2G topolojisinde araçtan şebekeye enerji aktarılmaktadır. V2G topolojisinde enerji akışını göstermek için simülasyonlar gerçekleştirildi ve hemen ardından laboratuvar ortamında bir deney düzeneği kuruldu. Bu deney düzeneğinde batarya grubundan tek fazlı şebeke bağlantılı evirici ile ana şebekeye enerji aktarılarak gerekli ölçümler yapıldı ve sistemin uygulanabilirliği gösterildi. Bu ölçümlerde 2 adet 12 V, 5 Ah batarya kullanılarak 24 V DC gerilim ile 1000 W tek fazlı şebeke bağlantılı evirici ile ana şebekeye 47,7 W güç aktarıldı. Deney düzeneğinin performansı için THD değerleri ölçüldü. Gerilim için THD değerinin değişmediği tespit edildi. Akım THD değeri, evirici bağlanmadan önce %5,09 olarak ölçüldü ve evirici bağlandıktan sonra ise %9,58 olarak ölçüldü. Bu değerler EPDK tarafından belirlenen standartlara uymaktadır. Bu sonuçlar da V2G topolojisinin uygulanabilirliğini ve gerçek dünya uygulamalarında kullanılabileceğini göstermektedir.

Gelecekte kullanılacak araçların hepsinin EV olduğu düşünüldüğünde bu çalışmada geliştirilen V2G topolojisinde ML tabanlı enerji akış modeli mikro şebekelerde enerji kalitesi ve müşteri memnuniyeti için özgün bir çözüm önerisi olarak değerlendirilmektedir. Enerji kaynaklarının etkin yönetimi ile şebekenin gelecekteki sürdürülebilirliği açısından, EV'lerin koordineli ve akıllı entegrasyonu, özellikle ML tabanlı enerji akış yönetimi çözümleri ile sağlanabileceği öngörülmektedir. Önerilen V2G topolojisindeki enerji akış modeli, uzun vadede şebeke güvenilirliğini artırarak enerji sistemlerinin sürdürülebilirliğini sağlayacak kritik bir adım olarak değerlendirilmektedir. Geliştirilen modelin gelecekte farklı mikro şebekeler ve EV kullanıcı profilleri ile test edilmesi, enerji sistemlerinin daha geniş bir perspektifte iyileştirilmesine katkıda bulunacaktır.

Geliştirilen V2G topolojisinin uzun vadede şebeke güvenilirliğini artırarak enerji sistemlerinin sürdürülebilirliğine katkıda bulunması, enerji kaynaklarının etkin yönetimi açısından kritik bir rol oynamaktadır. Bu nedenle, önerilen modelin, YEK'ler ile entegre edilmesi ve bu kaynakların şebeke kararlılığına olan etkisinin incelenmesi, gelecekte yapılacak çalışmalara ışık tutacaktır. EV bataryaları dışında farklı enerji depolama sistemlerinin (örneğin, ev tipi batarya depolama sistemleri) V2G topolojisine entegrasyonu, şebekenin esnekliğini artırabilir. Bu nedenle, geliştirilen modelin bu tür depolama sistemleri ile entegrasyonu incelenebilir. V2G topolojisinin yaygınlaştırılması için standartların ve düzenleyici çerçevelerin oluşturulması gerekmektedir. Özellikle, enerji arz-talep dengesinin sağlanması ve şebeke kararlılığının korunması için, bu sistemlerin enerji piyasaları ile düzenleyici kurumlar tarafından desteklenmesi kritik öneme sahiptir.

Gelecek perspektifinden bakıldığında V2G topolojisinde kullanılan ML tabanlı enerji akış yönetimi modellerinin farklı mikro şebekeler ve farklı EV kullanıcı profilleri ile test edilmesi, modelin genellenebilirliği ve uygulanabilirliği açısından faydalı olacaktır. Veri setlerinin genişletilmesi, farklı mevsimsel ve çevresel koşulların dikkate alınması, modelin performansını ve doğruluğunu artırabilir. Geliştirilen sistemin gerçek zamanlı veri ile sürekli olarak güncellenmesi, şebeke kararlılığını ve enerji kalitesini optimize etmek için kritik öneme sahiptir. Yerel kontrol stratejilerinin birleştirilerek merkezi bir kontrol stratejisine dönüştürülmesi, daha geniş ölçekli uygulamalarda faydalı olabilir.

KAYNAKLAR

1. Ahmad, F., Alam, M. S., and Asaad, M. (2017). Developments in xEVs charging infrastructure and energy management system for smart microgrids including xEVs. *Sustainable Cities and Society*, 35(2017), 552-564.

2. Khalid, M., Ahmad, F., Panigrahi, B. K., and Al-Fagih, L. (2022). A comprehensive review on advanced charging topologies and methodologies for electric vehicle battery. *Journal of Energy Storage*, 53(2022), 105084.

3. İnternet: Global EV Outlook 2024. URL: https://www.iea.org/data-and-statistics/data-product/global-ev-outlook-2024, Son Erişim Tarihi: 29.08.2024.

4. Şahinkaya, K. (2019). *Monte Carlo Based Control Algorithm For Economic Feasibility of V2G Applications*. Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 121.

5. İnternet: Elektrikli Araç ve Şarj Altyapısı Projeksiyonu. URL: https://www.epdk.gov.tr/Detay/Icerik/1-4448/enerji-donusumuelektrikli-arac-sarj-agi-altyapis, Son Erişim Tarihi: 29.08.2024.

6. Üstünsoy, F., and Sayan, H.H. (2021). Real time realization of network integration of electric vehicles with a unique balancing strategy. *Electrical Engineering*,103(2021), 2647–2660.

7. Praiselin, W. J., and Edwerd, J. B. (2018). A Review on Impacts of Power Quality, Control and Optimization Strategies of Integration of Renewable Energy Based Microgrid Operation. *International Journal of Intelligent Systems and Applications*, 10(3), 67-81.

8. İnci M., Çelik Ö., Lashab A., Bayındır K.Ç., Vasquez J.C., and Guerrero J.M. (2024). Power System Integration of Electric Vehicles: A Review on Impacts and Contributions to the Smart Grid. *Applied Sciences*, 14(6), 2246.

9. Sharma, G., and Sood, V.K. (2021). Power Quality Problems in Grid-Connected Electric Vehicle (EV) Fast Charging Stations. *In Kumar, J., Jena, P. (eds) Recent Advances in Power Electronics and Drives. Lecture Notes in Electrical Engineering*, 707(2020), 11-27.

10. Üstünsoy, F., and Sayan, H. H. (2023). *Development of Rule-Based Control Algorithm for DC Charging Stations and Simulation Results*. 12th International Symposium on Intelligent Manufacturing and Service Systems, IMSS 2023, İstanbul, Turkey, 336-346.

11. Triviño, A., Casaucao I., and Castilla, M. (2024). Flexible Regulation of Active and Reactive Power for a Fully Controllable V2G Wireless Charger. *IEEE Transactions on Transportation Electrification*, 10(1), 1070-1079.

12. Sousa, T. J. C., Monteiro, V., Fernandes, J. C. A., Couto, C., Meléndez, A. A., and Nafonso, J. L. (2018). *New Perspectives for Vehicle-to-Vehicle (V2V) Power Transfer*. IECON 2018- 44th Annual Conference of the IEEE Industrial Electronics Society, Washington, DC, USA, 5183-5188.

13. Gao, S., Chau, K. T., Liu, C., Wu, D., and Chan, C. C. (2014). Integrated Energy Management of Plug-in Electric Vehicles in Power Grid With Renewables. *IEEE Transactions on Vehicular Technology*, 63(7), 3019-3027.

14. Sarker, M. R., Ortega-Vazquez, M. A., and Kirschen, D. S. (2015). Optimal Coordination and Scheduling of Demand Response via Monetary Incentives. *IEEE Transactions on Smart Grid*, 6(3), 1341-1352.

15. Hu, J., You, S., Lind, M., and Østergaard, J. (2014). Coordinated Charging of Electric Vehicles for Congestion Prevention in the Distribution Grid. *IEEE Transactions on Smart Grid*, 5(2), 703-711.

16. Grasel, B., Serôdio, C., Mestre, P., Baptista, J., Tragner, M., and Reisenbauer, H. (2022). *Integration of a V2G charging station in a smart Prosumer household via a cloud-based energy management system considering ToU tariffs.* International Conference on Smart Energy Systems and Technologies (SEST), Eindhoven, Netherlands, 1-5.

17. Singh, K., and Singh, A. (2022). Behavioural modelling for personal and societal benefits of V2G/V2H integration on EV adoption. *Applied Energy*, 319(2022), 119265.

18. Madani, S., and Pineau, P.-O. (2024). Investment in vehicle-to-grid and distributed energy resources: Distributor versus prosumer perspectives and the impact of rate structures. *Utilities Policy*, 88(101736), 1-16.

19. Huaman-Rivera, A., Calloquispe-Huallpa, R., Luna Hernandez, A. C., and Irizarry-Rivera, A. (2024). An Overview of Electric Vehicle Load Modeling Strategies for Grid Integration Studies. *Electronics*, 13(12):2259, 1-23.

20. Nour, M., Chaves-Ávila, J. P., Magdy, G., and Sánchez-Miralles, Á. (2020). Review of Positive and Negative Impacts of Electric Vehicles Charging on Electric Power Systems. *Energies*, 3(18):4675, 1-34.

21. Un-Noor, F., Padmanaban, S., Mihet-Popa, L., Mollah, M. N., and Hossain, E. (2017). A Comprehensive Study of Key Electric Vehicle (EV) Components, Technologies, Challenges, Impacts, and Future Direction of Development. *Energies*, 10(8):1217, 1-84.

22. Mohammad, A., Zamora, R., and Lie, T. T. (2020). Integration of Electric Vehicles in the Distribution Network: A Review of PV Based Electric Vehicle Modelling. *Energies*, 13(17):4541, 1-20.

23. Purushothaman, D., Narayanamoorthi, R., Elrashidi, A., and Kotb, H. (2023). A Comprehensive Review on Single-Stage WPT Converter Topologies and Power Factor Correction Methodologies in EV Charging. *IEEE Access*, 11(2023), 135529-135555.

24. Kumar, S., and Usman, A. (2018). *A Review of Converter Topologies for Battery Charging Applications in Plug-in Hybrid Electric Vehicles*. IEEE Industry Applications Society Annual Meeting (IAS), Portland, OR, USA, 1-9.

25. Acharige, S. S. G., Haque, M. E., Arif, M. T., Hosseinzadeh, N., Hasan, K. N., and Oo, A. M. T. (2023). Review of Electric Vehicle Charging Technologies, Standards, Architectures, and Converter Configurations. *IEEE Access*, 11(2023), 41218-41255.

26. Avci, E. (2022). *Elektrikli Araç Şarj İstasyonlarının Akıllı Şebekelerle Entegrasyonunun Sağlanması ve Bu İstasyonların Şebekeye Getireceği Yükün İncelenmesi: Bursa Örneği*. Yüksek Lisans Tezi. Bursa Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Bursa, 94.

27. Cem, Z. T. (2023). *Elektrikli Araçlarda Kullanılan Bataryaların Sağlık ve Şarj Durumlarının Makine Öğrenmesi İle Tahmini*. Yüsek Lisans Tezi. Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü, Düzce, 77.

28. Muratoğlu, Y., and Alkaya, A. (2016). *Elektrikli Araç Teknolojisi ve Pil Yönetim Sistemi-İnceleme*. Elektrik Mühendisleri Odası VIII. Yenilenebilir Enerji Kaynakları Sempozyumu, 458, 10-14.

29. Kumar, S., Usman, A., and Rajpurohit, B.S. (2021). Battery charging topology, infrastructure, and standards for electric vehicle applications: A comprehensive review. *IET Energy Systems Integration*, 3(4), 381–396.

30. Çelenk, İ. (2023). *Elektrikli Araçlarda Enerji Depolama ve Araçtan Şebekeye Enerji Aktarım Uygulamaları*. Yüsek Lisans Tezi. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, 77.

31. Kuzu, B. (2023). *Elektrikli Araç Bataryalarının Akıllı Şebeke Uygulamalarında Alternatif Enerji Depolama Sistemi Olarak Modellenmesi Ve Simülasyonu*. Yüsek Lisans Tezi. İnönü Üniversitesi Fen Bilimleri Enstitüsü, Malatya, 90.

32. Tezde, E. İ., and Okumuş, H. İ. (2018). Batarya Modelleri ve Şarj Durumu (SoC) Belirleme. *EMO Bilimsel Dergi*, 8(1), 21-25.

33. Özcan, Ö. F., Karadağ, T., Altuğ, M., and Özgüven, Ö. (2021). Elektrikli Araçlarda Kullanılan Pil Kimyasallarının Özellikleri ve Üstün Yönlerinin Kıyaslanması Üzerine Bir Derleme Çalışması. *Gazi University Journal of Science Part A: Engineering and Innovation*, 8(2), 276-298.

34. Pan, J., Li, H., Sun, H., Zhang, Y., Wang, L., Liao, M., Sun, X., and Peng, H. (2018) A Lithium-Air Battery Stably Working at High Temperature with High Rate Performance. *Small*, 14(6): 1703454, 1-6.

35. Aykaç, C. B. (2021). *Elektrikli Taşıtlardaki Enerji Depolama ve Dağıtım Sistemleri*. Yüsek Lisans Tezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 96.

36. Kisacikoglu, M. C. (2013). *Vehicle-to-grid (V2G) Reactive Power Operation Analysis of the EV/PHEV Bidirectional Battery Charger*. Doktora Tezi. Tennessee Üniversitesi, Knoxville, 138.

37. Kaymaz, H., and Demir, M. F. (2020). Elektrikli Otomobiller için Çekiş Motor Tip Seçimi. *International Periodical of Recent Technologies in Applied Engineering*, 2(1), 35-41.

38. Ramya, K.C., Ramani, J.G., Sridevi, A., Rai, R.S., and Shirley, D.R.A. (2022). *Analysis of the Different Types of Electric Motors Used in Electric Vehicles*. In: Kathiresh, M., Kanagachidambaresan, G.R., Williamson, S.S. (eds) *E-Mobility. EAI/Springer Innovations in Communication and Computing. Springer*, 43-57.

39. Raj, Y., Agrawal, B., and Kirar, M. (2023). *A Review on Components of Electric Vehicle and Indian Scenario of Electric Vehicles*. IEEE Renewable Energy and Sustainable E-Mobility Conference (RESEM), Bhopal, India, 1-7.

40. Ramakrishnan, V., Savio, D., Narayanamoorthi, R., Kotb, H., Alrashidi, A, and Nureldeen, W. (2024). A Comprehensive Review on Efficiency Enhancement of Wireless Charging System for the Electric Vehicles Applications. *IEEE Access*, 12(2024), 46967-46994.

41. Tian, H., Tzelepis, D., and Papadopoulos, P. N. (2021). Electric Vehicle Charger Static and Dynamic Modelling for Power System Studies. *Energies*, 14(7):1801, 1-16.

42. Safayatullah, M., Elrais, M. T., Ghosh, S., Rezaii, R., and Batarseh, I. (2022). A Comprehensive Review of Power Converter Topologies and Control Methods for Electric Vehicle Fast Charging Applications. *IEEE Access*,10(2022), 40753-40793.

43. Mohammed, S. A. Q., and Jung, J.-W. (2021). A Comprehensive State-of-the-Art Review of Wired/Wireless Charging Technologies for Battery Electric Vehicles: Classification/Common Topologies/Future Research Issues. *IEEE Access*, 9(2021), 19572-19585.

44. Brenna, M., Foiadelli, F., Leone, C., and Longo, M. (2020). Electric Vehicles Charging Technology Review and Optimal Size Estimation. *Journal of Electrical Engineering & Technology*,15(2020), 2539–2552.

45. Kerem, A., and Gürbak, H. (2020). Elektrikli Araçlar İçin Hızlı Şarj İstasyonu Teknolojileri. *Gazi University Journal of Science Part C: Design and Technology*, 8(3), 644-661.

46. Zhou, K., Wu, Y., Wu, X., Sun, Y., Teng, D., and Liu, Y. (2023). Research and Development Review of Power Converter Topologies and Control Technology for Electric Vehicle Fast-Charging Systems. *Electronics*, 12(7):1581, 1-39.

47. Özbay, H. (2017). *Şebeke Etkileşimli Yenilenebilir Enerji Destekli Hızlı Batarya Şarj Sisteminin Gerçekleştirilmesi*. Doktora Tezi. Karabük Üniversitesi Fen Bilimleri Enstitüsü, Karabük, 157.

48. Tarar, M. O., Hassan, N. U., Naqvi, I. H., and Pecht, M. (2023). Techno-Economic Framework for Electric Vehicle Battery Swapping Stations. *IEEE Transactions on Transportation Electrification*, 9(3), 4458-4473.

49. Rahulkumar, J., Narayanamoorthi, R., Vishnuram, P., Bajaj, M., Blazek, V., Prokop, L., and Misak, S. (2023). An Empirical Survey on Wireless Inductive Power Pad and Resonant Magnetic Field Coupling for In-Motion EV Charging System. *IEEE Access*, 11(2023), 4660-4693.

50. Eltoumi, F. (2020). *Charging station for electric vehicle using hybrid sources*. Doktora Tezi. Bourgogne Üniversitesi, Comte, 125.

51. Çalışkan, E., (2022). *Batarya şarj uygulamalarında kullanılan LLC rezonans çeviricilerde optimum verim eldesi için yeni bir yöntem*. Doktora Tezi. İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul, 119.

52. Aggeler, D., Canales, F., Zelaya-De La Parra, H., Coccia, A., Butcher, N., and Apeldoorn, O. (2010). *Ultra-fast DC-charge infrastructures for EV-mobility and future smart grids*. IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe), Gothenburg, Sweden, 1-8.

53. Saadaoui, A., Ouassaid, M., and Maaroufi, M. (2023). Overview of Integration of Power Electronic Topologies and Advanced Control Techniques of Ultra-Fast EV Charging Stations in Standalone Microgrids. *Energies*,16(3):1031, 1-21.

54. Karapınar, F., and Daldaban, F. (2022). Elektrikli Araçların Şarj Yöntemleri ve Şarj İstasyon Tipleri. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 38(3), 549-556.

55. Falvo, M. C., Sbordone, D., Bayram, I. S., and Devetsikiotis, M. (2014). *EV charging stations and modes: International standards*. International Symposium on Power Electronics, Electrical Drives, Automation and Motion, Ischia, Italy,1134-1139.

56. İnternet: Electrical Vehicle Database. URL: https://ev-database.org/, Son Erişim Tarihi: 29.08.2024.

57. Heider, F., Jahic, A., Plenz, M., Tröger, K., and Schulz, D. (2022). *A generic EV charging model extracted from real charging behaviour*. IEEE IAS Global Conference on Emerging Technologies (GlobConET), Arad, Romania, 393-398.

58. Srilatha, A., Pandian, A., and Varma, P. S. (2020). Review of Different Methods and Topologies for Fast Charging of Electric Vehicles. *International Journal of Research and Innovation in Applied Science (IJRIAS)*, 5(11), 64-76.

59. Yong, J. Y., Ramachandaramurthy, V. K., and Tan, K. M., Mithulananthan, N. (2015). A review on the state-of-the-art technologies of electric vehicle, its impacts and prospects. *Renewable and Sustainable Energy Reviews*, 49(2015), 365-385.

60. Chen, L.-R. (2009). Design of Duty-Varied Voltage Pulse Charger for Improving Li-Ion Battery-Charging Response. *IEEE Transactions on Industrial Electronics*, 56(2),480-487.

61. Zafar, B., and Slama S. A. B. (2022). PV-EV integrated home energy management using vehicle-to-home (V2H) technology and household occupant behaviors. *Energy Strategy Reviews*, 44(2022):101001, 1-18.

62. Sharma, G., Sood, V. K., Alam, M. S., and Shariff, S. M. (2020). Comparison of common DC and AC bus architectures for EV fast charging stations and impact on power quality. *eTransportation*, 5(2020):100066, 1-15.

63. Rituraj, G., Mouli, G. R. C., and Bauer, P. (2022). A Comprehensive Review on Off-Grid and Hybrid Charging Systems for Electric Vehicles. *IEEE Open Journal of the Industrial Electronics Society*, 3(2022), 203-222.

64. Aluisio, B., Conserva, A., Dicorato, M., Forte, G., and Trovato, M. (2017). Optimal operation planning of V2G-equipped Microgrid in the presence of EV aggregator. *Electric Power Systems Research*, 152(2017), 295-305.

65. Mouli, G. R. C., Leendertse, M., Prasanth, V., Bauer, P., Silvester, S., Geer S., and Zeman, M. (2016). *Economic and CO2 Emission Benefits of a Solar Powered Electric Vehicle Charging Station for Workplaces in the Netherlands*. IEEE Transportation Electrification Conference and Expo (ITEC), Dearborn, MI, USA, 1-7.

66. A. Bidram, A., and Davoudi, A. (2012). Hierarchical Structure of Microgrids Control System. *IEEE Transactions on Smart Grid*, 3(4), 1963-1976.

67. Guerrero, J. M., Vasquez, J. C., Matas, J., Vicuna, L. G. de, and Castilla, M. (2011). Hierarchical Control of Droop-Controlled AC and DC Microgrids-A General Approach Toward Standardization. *IEEE Transactions on Industrial Electronics*, 58(1), 158-172.

68. Vandoorn, T. L., Vasquez, J. C., Kooning, J., Guerrero, J. M., and Vandevelde, L. (2013). Microgrids: Hierarchical Control and an Overview of the Control and Reserve Management Strategies. *IEEE Industrial Electronics Magazine*, 7(4), 42-55.

69. Kang, Q., Wang, J., Zhou, M., and Ammari, A. C. (2016). Centralized Charging Strategy and Scheduling Algorithm for Electric Vehicles Under a Battery Swapping Scenario. *IEEE Transactions on Intelligent Transportation Systems*, 17(3), 659-669.

70. Jiang, J., Bao, Y., and Wang, L. Y. (2014). Topology of a Bidirectional Converter for Energy Interaction between Electric Vehicles and the Grid. *Energies*, 7(8), 4858-4894.

71. Panchanathan, S., Vishnuram, P., Rajamanickam, N., Bajaj, M., Blazek, V., Prokop, L., and Misak, S. A. (2023). Comprehensive Review of the Bidirectional Converter Topologies for the Vehicle-to-Grid System. *Energies*, 6(5):2503, 1-33.

72. Sharma, A., and Sharma, S. (2019). Review of power electronics in vehicle-to-grid systems. *Journal of Energy Storage*, 21(2019), 337-361.

73. Ravi, D., Letha, S. S., Samuel, P., and Reddy, B. M. (2018). *An Overview of Various DC-DC Converter Techniques used for Fuel Cell based Applications*. International Conference on Power Energy, Environment and Intelligent Control (PEEIC), Greater Noida, India, 16-21.

74. Syah, M. N., Firmansyah, E., and Utomo, D. R. (2022). *Interleaved Bidirectional DC-DC Converter Operation Strategies and Problem Challenges: An Overview*. IEEE International Conference in Power Engineering Application (ICPEA), Shah Alam, Malaysia, 1-6.

75. Aarninkhof, B. O., Lyu, D., Soeiro, T. B., and Bauer, P. (2024). A Reconfigurable Two-Stage 11 kW DC–DC Resonant Converter for EV Charging With a 150–1000 V Output Voltage Range. *IEEE Transactions on Transportation Electrification*, 10(1), 509-522.

76. Wang, Z., Su, X., Zeng, N., and Jiang, J. (2024). Overview of Isolated Bidirectional DC–DC Converter Topology and Switching Strategies for Electric Vehicle Applications. *Energies*,17(10):2434, 1-29.

77. Lenka, R. K., Panda, A. K., Dash, A. R., Venkataramana, N. N., and Tiwary, N. (2021). *Reactive Power Compensation using Vehicle-to-Grid enabled Bidirectional Off-Board EV Battery Charger*. 1st International Conference on Power Electronics and Energy (ICPEE), Bhubaneswar, India, 1-6.

78. Gao, J., Jiang, D., Sun, W., and Zhang, Y. (2019). *Zero Torque Three Phase Integrated On-board Charger by Multi-Elements Motor Torque Cancellation*. 2019 IEEE Energy Conversion Congress and Exposition (ECCE), Baltimore, MD, USA, 563-568.

79. Pan, L., and Zhang, C. (2015). A High Power Density Integrated Charger for Electric Vehicles with Active Ripple Compensation. *Mathematical Problems in Engineering*, 918296(2015), 1-18.

80. İnternet: Tesla Onboard Charger. URL: https://www.tesla.com/blog/introducing-v3-supercharging, Son Erişim Tarihi: 29.08.2024.

81. İnternet: Introducing V3 Supercharging. URL: https://www.tesla.com/blog/introducing-v3-supercharging , Son Erişim Tarihi: 29.08.2024.

82. United States Patent (2018). Bidirectional Powering On -Board Charger, Vehicle Power Supply System Including The Same, and Control Method Thereof. *U. S. A., Patent Documents*: US 10 ,046 ,656 B2.

83. R. Pandey, R., and Singh, B. (2020). *A Power Factor Corrected Resonant EV Charger Using Reduced Sensor Based Bridgeless Boost PFC Converter*. IEEE Transportation Electrification Conference & Expo (ITEC), Chicago, IL, USA, 359-364.

84. Lu, X., Iyer, K. L. V., Mukherjee, K., and Kar, N. C. (2016). Investigation of Integrated Charging and Discharging Incorporating Interior Permanent Magnet Machine With Damper Bars for Electric Vehicles. *IEEE Transactions on Energy Conversion*, 31(1), 260-269.

85. Metwly, M. Y., Abdel-Majeed, M. S., Abdel-Khalik, A. S., Hamdy, R. A., Hamad, M. S., and Ahmed, S. (2020). A Review of Integrated On-Board EV Battery Chargers: Advanced Topologies, Recent Developments and Optimal Selection of FSCW Slot/Pole Combination. *IEEE Access*, 8(2020), 85216-85242.

86. Singh, A. K., Pathak, M. K. (2018). *A Comprehensive Review of Integrated Charger for on-Board Battery Charging Applications of Electric Vehicles*. IEEE 8th Power India International Conference (PIICON), Kurukshetra, India, 1-6.

87. Liang, J., Li, W., and Song, Z. (2017). *Control strategy of integrated charger base on split-winding switched reluctance motor drive*. 20th International Conference on Electrical Machines and Systems (ICEMS), Sydney, NSW, Australia, 1-6.

88. Subotic, I., Bodo, N., Levi, E., Dumnic, B., Milicevic, D., and Katic, V. (2016). Overview of fast on-board integrated battery chargers for electric vehicles based on multiphase machines and power electronics. *IET Electric Power Applications*, 10(3), 217-229.

89. Khaligh A., and D'Antonio, M. (2019). Global Trends in High-Power On-Board Chargers for Electric Vehicles. *IEEE Transactions on Vehicular Technology*, 68(4), 3306-3324.

90. İnternet: Mobility Fair EVS30: Continental Presents Innovative Charging Technologies for All Applications. URL: https://www.continental.com/en/press/press-releases/2017-10-09-charging-solutions/, Son Erişim Tarihi: 29.08.2024.

91. Haghbin, S., Lundmark, S., Alakula, M., Carlson, O. (2011). An Isolated High-Power Integrated Charger in Electrified-Vehicle Applications. *IEEE Transactions on Vehicular Technology*, 60(9), 4115-4126.

92. Khalid, M. R., Khan, I. A., Hameed, S., Asghar, M. S. J., and Ro, J. (2021). A Comprehensive Review on Structural Topologies, Power Levels, Energy Storage Systems, and Standards for Electric Vehicle Charging Stations and Their Impacts on Grid. *IEEE Access*, 9(2021),128069-128094.

93. Rathore, V., Reddy, S. R. P., and Rajashekara, K. (2022). An Isolated Multilevel DC–DC Converter Topology With Hybrid Resonant Switching for EV Fast Charging Application. *IEEE Transactions on Industry Applications*, 58(5), 5546-5557.

94. Yilmaz M., and Krein, P. T. (2013). Review of Battery Charger Topologies, Charging Power Levels, and Infrastructure for Plug-In Electric and Hybrid Vehicles. *IEEE Transactions on Power Electronics*, 28(5), 2151-2169.

95. Ericsen, T., Khersonsky, Y., and Steimer, P. K. (2005). *PEBB Concept Applications in High Power Electronics Converters*. IEEE 36th Power Electronics Specialists Conference, Dresden, Germany, 2284-2289.

96. Danese, A., Torsæter, BN., Sumper, A., and Garau, M. (2022). Planning of High-Power Charging Stations for Electric Vehicles: A Review. *Applied Sciences*,12(7),3214.

97. Bui, D. M., Chen, S.-L, Wu, C-H., Lien, K.-Y., Huang, C.-H., and Jen, K.-K. (2014). *Review on protection coordination strategies and development of an effective protection coordination system for DC microgrid*. IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), Hong Kong, China, 1-10.

98. Srdic, S., and Lukic, S. (2019). Toward Extreme Fast Charging: Challenges and Opportunities in Directly Connecting to Medium-Voltage Line. *IEEE Electrification Magazine*, 7(1), 22-31.

99. Şahinler, G. B. (2021). *Modeling and Simulation Of Three-Phase Bidirectional Electric Vehicle Charger*. Yüksek Lisans Tezi. Özyeğin Üniversitesi Fen Bilimleri ve Mühendislik Enstitüsü, İstanbul, 211.

100. Kapil, P.N., and Dhrangadharia, C. M. (2014). Design and Simulation of Three-Phase Voltage Source Based Converter for HVDC Applications. *International Journal of Electronic and Electrical Engineering*, 7(6), 573-580.

101. Madan, A. (2019). *Performance And Thermal Reliability Comparisons Of 2-Level And 3-Level Npc Voltage Source Inverters For Electric Vehicle Drive Applications*. Yüksek Lisans Tezi. Ortadoğu Teknik Üniversitesi Fenbilimleri Enstitüsü, Ankara, 87.

102. Öner, S. (2023). *Akıllı Arıza Koruma Ve Güç Akışı Kontrol Fonksiyonlarına Sahip Bir Elektrikli Araç Şarj Cihazının Şebekeden-Araca Ve Araçtan-Şebekeye Etkileşimli Şekilde Geliştirilmesi*. Yüksek Lisans Tezi. Bursa Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Bursa, 51.

103. Kubeitari, M., Alhusayn, A., and Alnahar, M. (2012). Space Vector PWM Simulation for Three Phase DC/AC Inverter. *International Journal of Electrical and Computer Engineering*, 6(12), 1402-1407.

104. Li, F., Ji, F., Guo, H., Li, H., and Wang, Z. (2017). *Research on integrated bidirectional control of EV charging station for V2G*. 2nd International Conference on Power and Renewable Energy (ICPRE), Chengdu, China, 833-838.

105. Dursun, M., and Döşoğlu, M. K. (2018). *LCL Filter Design for Grid Connected Three-Phase Inverter*. 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Ankara, Turkey, 1-4.

106. Shaikh, S. A., Bagewadi, M. D., and Shaikh, S. (2022). *Bi-directional Multifunctionality Optimum Power Converter For Electric Vehicle Application With Provision For V2G and G2V*. International Conference on Emerging Trends in Engineering and Medical Sciences (ICETEMS), Nagpur, India, 274-278.

107. Yildiz, S., and Sayan, H. H. (2023). *LCL Filter Design and Simulation for Vehicle-To-Grid (V2G) Applications*. 12th International Symposium on Intelligent Manufacturing and Service Systems, IMSS 2023, Sakarya, Turkey, 347-358.

108. Sorhun, E. (2023). *Python İle Makine Öğrenmesi* (Dördüncü Baskı). Türkiye: Abaküs Yayınevi, 225-365.

109. Kılınç, D., ve Başeğmez, N. (2022). *Uygulamalar İle Veri Bilimi* (Dördüncü Baskı). Türkiye: Abaküs Yayınevi, 1-20.

110. Altun, M., Nacar, M., ve Çakar., O. (2023). *Yapay Zeka Ve Makine Öğrenmesi* (Birinci Baskı). Türkiye: Milli Eğitim Bakanlığı Ders Materyali, 68-175.

111. Savaş, S., ve Buyrukoğlu, S. (2022). *Teori Ve Uygulamada Makine Öğrenmesi* (Birinci Baskı). Türkiye: Nobel Yayınevi, 1-18, 223-248.

112. Uğuz, S. (2021). *Makine Öğrenmesi-Teorik Yönleri Ve Python Uygulamaları Yapay Zeka Ekolü* (Birinci Baskı). Türkiye: Nobel Yayınevi, 68-91, 149-265.

113. Burkov, A. (2021). *100 Sayfada Makine Öğrenmesi Kitabı* (Birinci Baskı). Türkiye: Akademik Yayınevi, 1-7.

114. Emami, P., Pardalos, P. M., Elefterıadou, L., and Ranka, S. (2020). Machine Learning Methods for Data Associationin Multi-Object Tracking. *ACM Computing Surveys (CSUR)*, 53(4), 69, 1-34.

115. Wang, J., Deng, Y., Zhang, J., Liang, J., Geng, J., Wang, H., and Liu C. (2021). *Prediction Method of Distribution Network Area Based on Association Analysis and Machine Learning*. IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), Xi'an, China, 672-676.

116. Wang, C., Chen, Y., Liu, F., Elliott, M., Kwok, C. F., Peña-Solorzano, C., Frazer, H., McCarthy, D. J., and Carneiro, G. (2024). An Interpretable and Accurate Deep-Learning Diagnosis Framework Modeled With Fully and Semi-Supervised Reciprocal Learning. *IEEE Transactions on Medical Imaging*, 43(1), 392-404.

117. Yuan, X., Li, Z., and Wang, G. (2022). *ActiveMatch: End-To-End Semi-Supervised Active Representation Learning*. IEEE International Conference on Image Processing (ICIP), Bordeaux, France, 1136-1140.

118. Le, T.-T.-H., Kang, H., and Kim, H. (2020). Household Appliance Classification Using Lower Odd-Numbered Harmonics and the Bagging Decision Tree. *IEEE Access*, 8(2020), 55937-55952.

119. Ye, J., Yang, J., Yu, J., Tan, S., Luo, F., Yuan, Z., and Chen, Y. (2021). A Chi-MIC Based Adaptive Multi-Branch Decision Tree. IEEE Access, 9(2021), 78962-78972.

120. Al-Ssulami, A.M., Alsorori, R.S., Azmi, A.M., and Aboalsamh, H. (2023). Improving Coronary Heart Disease Prediction Through Machine Learning and an Innovative Data Augmentation Technique. *Cognitive Computation*, 15(2023), 1687-1702.

121. Yuan, L., Chen, H., and Gong, J. (2018). Classifications Based Decision Tree and Random Forests for Fanjing Mountains' Tea. *IOP Conference Series: Materials Science and Engineering*, 394, 052002.

122. Damarla, T. S., and Yadav, A. (2023). *Detection of Cyber- Attacks in Digital Power System Using Ensemble Bagged Trees*. 4th International Conference for Emerging Technology (INCET), Belgaum, India, 1-6.

123. Polo, J. L., Berzal, F., and Cubero, J. C. (2007). *Weighted Classification Using Decision Trees for Binary Classification Problems*. II Congreso Español de Informática, IV Taller de Minería de Datos y Aprendizaje, 333-341.

124. Saeed, M. S., Mustafa, M.W., Sheikh, U. U., Jumani, T. A., and Mirjat, N. H. (2019). Ensemble Bagged Tree Based Classification for Reducing Non-Technical Losses in Multan Electric Power Company of Pakistan. *Electronics,* 8(8),860.

125. Singh, A. R., Singh, G., and Saluja, N. (2024). *Emotion Classification of EEG signals using Logistic Regression classification.* 2024 3rd International Conference for Innovation in Technology (INOCON), Bangalore, India,1-5.

126. Pérez, A., Larrañaga, P., and Inza, I. (2009). Bayesian classifiers based on kernel density estimation: Flexible classifiers. *International Journal of Approximate Reasoning*, 50(2), 341-362.

127. Brownlee, J. (2016). *Master Machine Learning Algorithms-Discover How They Work and Implement Them From Scratch* (Birinci Baskı). San Francisco: e-Kitap, 115-118.

128. Mateen, B. S. H. (2020). *Prediction of Colorectal Cancer Using Support Vector Machines Algorithm*. Yüksek Lisans Tezi. Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü, Van, 94.

129. Sa'id, A. A., Rustam, Z., Wibowo, V. V. P., Setiawan, Q. S., and Laeli, A. R. (2020). *Linear Support Vector Machine and Logistic Regression for Cerebral Infarction Classification*. International Conference on Decision Aid Sciences and Application (DASA), Sakheer, Bahrain, 827-831.

130. Demidova, L., and Egin, M. (2018). *Improving the accuracy of the SVM classification using the Parzen classifier*. 7th Mediterranean Conference on Embedded Computing (MECO), Budva, Montenegro,1-4.

131. Mienye, I. D., and Sun, Y., A (2022). Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects. *IEEE Access*, 10(2022), 99129-99149.

132. Qin, F., Fu, L., Wang, Y., and Mao, Y., (2021). A bagging tree-based pseudorange correction algorithm for global navigation satellite system positioning in foliage canyons. *International Journal of Distributed Sensor Networks*, 17(5), 1-11.

133. Zhang, H., Zhou, T., Xu, T., and Hu, H. (2023). Remote Interference Discrimination Testbed Employing AI Ensemble Algorithms for 6G TDD Networks. *Sensors*, 23(4):2264, 1-22.

134. Zounemat-Kermani, M., Batelaan, O., Fadaee, M., and Hinkelmann, R. (2021). Ensemble machine learning paradigms in hydrology: A review. *Journal of Hydrology*, 598(2021):126266, 1-13.

135. Fazakis, N., Kocsis, O., Dritsas, E., Alexiou, S., Fakotakis, N., and Moustakas, K. (2021). Machine Learning Tools for Long-Term Type 2 Diabetes Risk Prediction. *IEEE Access*, 9(2021), 103737-103757.

136. Zeng, X.-D., Chao, S., and Wong, F. (2010). *Optimization of bagging classifiers based on SBCB algorithm*. International Conference on Machine Learning and Cybernetics, Qingdao, China, 262-267.

137. Kurt, A. (2021). *Ağ Tabanlı Saldırı Tespit Sistemlerinde Topluluk Öğrenme Yöntemlerinin Karşılaştırmalı Performans Analizi*. Yüksek Lisans Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 83.

138. Elasan, S. (2019). *Veri Madenciliğinde Farklı Karar Ağaçları Ve K-En Yakın Komşuluk Yöntemlerinin İncelenmesi: Kadın Hastalıkları Ve Doğum Verisinde Bir Uygulama*. Doktora Tezi. Van Yüzüncü Yıl Üniversitesi Sağlık Bilimleri Enstitüsü, Van, 77.

139. Köktürk, F. (2012). *K-En Yakın Komşuluk, Yapay Sinir Ağları Ve Karar Ağaçları Yöntemlerinin Sınıflandırma Başarılarının Karşılaştırılması*. Doktora Tezi. Bülent Ecevit Üniversitesi Sağlık Bilimleri Enstitüsü, Zonguldak, 75.

140. Hamorro-Atalaya, O., Arévalo-Tuesta, J., Balarezo-Mares, D., Gonzáles-Pacheco, A., Mendoza-León, O., Quipuscoa-Silvestre, M., and Suarez-Bazalar, R. (2023). K-Fold Cross-Validation through Identification of the Opinion Classification Algorithm for the Satisfaction of University Students. *International Journal of Online and Biomedical Engineering (iJOE)*, 19(11), 140-158.

141. Hassan, A., Ali, M., Durrani, N. M., and Tahir, M. A. (2021). An Empirical Analysis of Deep Learning Architectures for Vehicle Make and Model Recognition. *IEEE Access*, 9(2021), 91487-91499.

142. Şengör, N. (2024). *Estimation of Electromagnetic Model of Light In Different Media Using Artificial Neural Network*. Yüksek Lisans Tezi. Eskişehir Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Eskişehir, 92.

143. Bawa, T. A. (2022). *Topluluk Öğrenmesi Yöntemi İle Mikrodizi Veri Analizi*. Yüksek Lisans Tezi. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 67.

144. Öztürk, A. (2023). *Otomatik Üretim Kontrolü Sistemlerine Yapılan Yanlış Veri Enjeksiyon Saldırılarının Torbalama Ağaçları Algoritması İle Tespiti*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul, 101.

145. Wu, Y., Ke, Y., Chen, Z., Liang, S., Zhao, H., and Hong, H. (2020). Application of alternating decision tree with AdaBoost and bagging ensembles for landslide susceptibility mapping. *CATENA*, 187(2020):104396, 1-17.

146. Khan, Z., Gul, N., Faiz, N., Gul, A., Adler, W., and Lausen, B., (2021). Optimal Trees Selection for Classification via Out-of-Bag Assessment and Sub-Bagging. *IEEE Access*, 9(2021), 28591-28607.

147. Yıldız, S., and Sayan, H. H. (2024). Bidirectional DC-DC Converter and Single-Phase Grid-Connected Inverter Design for Energy Management in V2G Topology. *Gazi Journal of Engineering Sciences*, 10(2), 419-431.

148. İnternet: Elektrik Dağıtım Sisteminin Teknik Kalitesine İlişkin Usul ve Esaslar. URL: https://www.epdk.gov.tr/Detay/Icerik/3-24176/elektrik-dagitim-sisteminin-teknik-kalitesine-ili, Son Erişim Tarihi: 29.08.2024.



Gazili olmak ayrıcalıktır