

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ENERJİ SÜREKLİLİĞİ İÇİN GÖLGE ETKİLİ FOTOVOLTAİK
SİSTEMİN ŞEBEKE/YÜK ENTEGRASYONU

DOKTORA TEZİ

Büşra ÖZGENÇ

KASIM 2025

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ENERJİ SÜREKLİLİĞİ İÇİN GÖLGE ETKİLİ FOTOVOLTAİK
SİSTEMİN ŞEBEKE/YÜK ENTEGRASYONU**

Büşra ÖZGENÇ

ORCID :

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 17 / 09 / 2025

Tezin Savunma Tarihi : 03 / 11 / 2025

Tez Danışmanı : Prof. Dr. İsmail Hakkı ALTAŞ
ORCID :

Trabzon 2025

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalında
Büşra ÖZGENÇ Tarafından Hazırlanan**

**ENERJİ SÜREKLİLİĞİ İÇİN GÖLGE ETKİLİ FOTOVOLTAİK
SİSTEMİN ŞEBEKE/YÜK ENTEGRASYONU**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 09 / 10 / 2025 gün ve 2123 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Prof. Dr. Saffet AYASUN

Üye : Prof. Dr. İsmail Hakkı ALTAŞ

Üye :Prof. Dr. Emre ÖZKOP

Üye : Prof. Dr. Mustafa ULUTAŞ

Üye : Prof. Dr. Nuran YÖRÜKEREN

**Prof. Dr. Asim KADIOĞLU
Enstitü Müdürü**

ÖNSÖZ

“Enerji Sürekliliği İçin Gölge Etkili Fotovoltaik Sistemin Şebeke/Yük Entegrasyonu” başlıklı bu tez, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı’nda hazırlanmıştır.

Tez çalışmam boyunca desteğini esirgemeyen, değerli bilgi ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. İsmail Hakkı ALTAŞ’a teşekkürlerimi saygıyla sunarım. Yapıcı eleştirileri ve önerileriyle tezime büyük katkı sağlayan hocalarım Sayın Prof. Dr. Emre ÖZKOP ve Sayın Prof. Dr. Mustafa ULUTAŞ’a, ayrıca tez süresince her türlü yardımda bulunan değerli hocam ve arkadaşım Dr. Öğr. Üyesi Yeşim Aysel BAYSAL ASLANHAN’a gönülden teşekkür ederim.

Çalışmalarım süresince destek ve sevgileriyle yanımda olan arkadaşlarım Esra DEMİR AYDIN, Kezban KOÇ SAVAŞ, Fatih AYDIN, Sibel ÇEVİK BEKTAŞ, Zeliha ÖZDEMİR AYDIN, Reyhan SAĞ ÖRNEK ve Besra ÇETİNDERE VELA’ya çok teşekkür ederim.

Bu doktora tezi, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 122E545 numaralı “Enerji Sürekliliği için gölge etkili Fotovoltaik Sistemlerin Şebeke/Yük Entegrasyonu” projesi kapsamında desteklenmiştir. Sağlanan finansal destek için TÜBİTAK’a teşekkür ederim.

Son olarak, beni yetiştiren, her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen annem Şadiye ÖZGENÇ ve babam İsmail ÖZGENÇ’e teşekkür eder, minnettarlığımı sunarım.

Bu tez çalışmasının gelecek araştırmalara katkı sağlamasını temenni ederim.

Büşra ÖZGENÇ

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Enerji Sürekliliği İçin Gölge Etkili Fotovoltaik Sistemin Şebeke/Yük Entegrasyonu” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. İsmail Hakkı ALTAŞ’ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 03/11/2025

Büşra ÖZGENÇ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER VE KISALTMALAR DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Literatür Araştırması	4
1.3. Tezin Amacı	15
1.4. Fotovoltaik Sistem.....	15
1.4.1. Düşük Gerilimde Şebekede Kalma Yeteneği.....	20
1.4.2. Düşük Gerilimde Şebekeye Bağlı Kalma Yöntemleri	22
1.5. FV Sistemin Düşük Gerilimde Şebekede Kalma Yeteneği.....	23
1.5.1. Simbiyotik Organizma Arama Algoritması	23
1.6. Pekiştirmeli Öğrenme.....	25
1.6.1. Pekiştirmeli Öğrenme Modelinin Bileşenleri	26
1.6.2. Markov Karar Süreci.....	27
1.6.3. Optimal Politika	28
1.6.4. Pekiştirmeli Öğrenme Algoritmaları.....	29
1.7. Derin Öğrenme	30
1.8. Derin Pekiştirmeli Öğrenme.....	31
1.8.1. Derin Q Ağı.....	32
1.8.2. Derin Deterministik Politika Gradyanı	32
1.8.3. İkiz Gecikmeli Derin Deterministik Politika Gradyanı	34
1.8.4. Soft Aktör-Kritik Algoritması.....	36
1.8.5. Transfer Öğrenme	39
2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	40

2.1. FV Sistemin Modellenmesi ve Simülasyonu	40
2.2. LVRT Yeteneği için Kontrol Yöntemlerinin Tasarımı	44
2.2.1. SOS-PI Tabanlı Denetleyici Uygulaması	45
2.2.2. DRL Tabanlı Denetleyici Uygulaması.....	47
2.2.3. Dengeli Arıza Sonuçlarının Karşılaştırılması	50
2.2.4. Dengesiz Arızalar İçin Sonuçların Karşılaştırılması.....	64
2.2.5. Transfer-DRL Sonuçlarının Karşılaştırılması	73
2.3. Maksimum Güç Noktası Takibi	85
2.3.1. P&O Algoritmasının MPPT İçin Uygulanması	85
2.3.2. SAC Algoritmasının MPPT İçin Uygulanması.....	86
2.3.3. Yöntemlerin Karşılaştırılması	88
2.4. FV Sistemin Dayanıklılığının Artırılması	91
2.5. Şebeke Parametrelerinin Değişimi	100
2.6. Önerilen Sistemin Gerçek Zamanlı Testi	102
3. SONUÇLAR VE TARTIŞMA	106
4. ÖNERİLER.....	108
5. KAYNAKLAR	109
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

ENERJİ SÜREKLİLİĞİ İÇİN GÖLGE ETKİLİ FOTOVOLTAİK SİSTEMİN ŞEBEKE/YÜK ENTEGRASYONU

Büşra ÖZGENÇ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. İsmail Hakkı ALTAŞ
2025, 132 Sayfa

Yenilenebilir enerji kaynaklarının şebeke entegrasyonu arttıkça, bu sistemlerin düşük gerilimde şebekede kalma kapasitesinin iyileştirilmesi şebeke kararlılığı ve enerji güvenliği için kritik önem taşımaktadır. Bu tez çalışmasında, şebeke bağlantılı fotovoltaik sistemin düşük gerilimde şebekede kalma kapasitesinin geliştirilmesi ele alınmıştır. İki aşamalı üç fazlı şebeke bağlantılı fotovoltaik sistem Matlab/Simulink'te modellenmiştir. Dinamik ve belirsiz şebeke koşullarına uyum sağlama ve çeşitli arıza senaryolarında genelleme yapma yetenekleriyle geleneksel yöntemlerden ayrılan derin pekiştirmeli öğrenme tabanlı üç farklı denetleyici geliştirilmiştir. Bu denetleyicilerin dengeli ve dengesiz arızalar altındaki performansları birbirleriyle ve simbiyotik organizma arama algoritması ile optimize edilmiş oransal-integral denetleyici ile karşılaştırılmıştır. Sonuçlar, genelleme kapasitesini iyileştiren transfer öğrenmenin, daha üstün bir performans sağladığını göstermiştir. Ayrıca, fotovoltaik sistemin dayanıklılığını artırmak için düşük gerilimde şebekede kalma kapasitesi ile çevresel faktörlerden kaynaklanan gölgelenme durumu birlikte incelenmiştir. Derin pekiştirmeli öğrenme yöntemi, değiştir-gözle algoritmasına kıyasla genelleme kapasitesini artırarak sistem dayanıklılığını geliştirmiştir.

Anahtar Kelimeler: Gölge etkili fotovoltaik sistem, Fotovoltaik-şebeke entegrasyonu, Şebeke yönetmeliği, Düşük gerilimde şebekede kalma, Derin pekiştirmeli öğrenme, Transfer öğrenme

PhD. Thesis

SUMMARY

GRID/LOAD INTEGRATION OF PHOTOVOLTAIC SYSTEM WITH SHADOW EFFECT FOR ENERGY CONTINUITY

Büşra ÖZGENÇ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electric-Electronic Engineering Graduate Program
Supervisor: Prof. Dr. İsmail Hakkı ALTAŞ
2025, 132 Pages

As the grid integration of renewable energy sources increases, improving the low voltage ride-through capability of these systems has become critically important for grid stability and energy security. This thesis addresses the enhancement of the low voltage ride-through capability of a grid-connected photovoltaic system. The two-stage three-phase grid-connected photovoltaic system is modeled in Matlab/Simulink. Three different deep reinforcement learning based controllers distinguished from conventional methods by their ability to adapt to dynamic and uncertain grid conditions and to generalize across various fault scenarios are developed. Their performances under balanced and unbalanced faults are compared with one another and with a proportional-integral controller optimized by the symbiotic organism search algorithm. The results show that transfer learning, which improves generalization capacity, provides superior performance. In addition, to increase the robustness of the photovoltaic system, the low voltage ride-through capability is considered together with shading conditions arising from environmental factors. The deep reinforcement learning method enhances system robustness by increasing generalization capacity compared with the perturb and observe algorithm.

Key Words: Shading effect photovoltaic system, Photovoltaic-grid integration, Grid code, Low voltage ride-through, Deep reinforcement learning, Transfer learning

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. FV hücreye ait tek diyot modeli eşdeğer devresi	16
Şekil 2. Almanya şebeke yönetmeliğine göre LVRT yeteneği	21
Şekil 3. Gerilim değerine bağlı reaktif akım değeri	22
Şekil 4. DA kıyıcı devresinin eşdeğer devresi.....	23
Şekil 5. RL modeline ait genel yapı blok diyagramı	26
Şekil 6. SAC algoritma yapısının blok diyagramı.....	39
Şekil 7. İki aşamalı üç fazlı şebeke bağlantılı FV sistem modeli	42
Şekil 8. Üç faz şebeke modeli blok diyagramı	43
Şekil 9. SOS-PI tabanlı denetleyicinin LVRT yeteneği için uygulama blok diyagramı	46
Şekil 10. Bir faz için şebeke kaynağı modellemesi	47
Şekil 11. DRL ile LVRT kontrol blok diyagramı.....	50
Şekil 12. DRL tabanlı denetleyicide LVRT kontrolü için kullanılan çevre	50
Şekil 13. SAC ağ mimarisi akış diyagramı.....	53
Şekil 14. Dengeli üç faz arıza için eğitim eğrileri	55
Şekil 15. FV sistemin 0.3 pu dengeli arıza için yanıtları.....	59
Şekil 16. FV sistemin 0.5 pu dengeli arıza için yanıtları.....	60
Şekil 17. FV sistemin 0.7 pu dengeli arıza için yanıtları.....	60
Şekil 18. Dengeli arıza için SAC ajanı frekans yanıtı	64
Şekil 19. Dengesiz arıza için eğitim eğrileri.....	66
Şekil 20. FV sistemin 0.3 pu dengesiz tek faz arıza için yanıtları.....	69
Şekil 21. FV sistemin 0.8 pu dengesiz tek faz arıza için yanıtları.....	69
Şekil 22. FV sistemin 0.3 pu dengesiz iki faz arıza için yanıtları	70
Şekil 23. FV sistemin 0.8 pu dengesiz iki faz arıza için yanıtları	70
Şekil 24. SAC ajanı için dengesiz arıza frekans yanıtı.....	73
Şekil 25. Dengeli-dengesiz arızalar için transfer ajanlarına ait eğitim eğrileri	74
Şekil 26. FV sistem için 0.3 pu tek faz arıza Transfer-DRL yanıtları.....	76
Şekil 27. FV sistem için 0.5 pu tek faz arıza Transfer-DRL yanıtları.....	76
Şekil 28. FV sistem için 0.7 pu tek faz arıza Transfer-DRL yanıtları.....	77
Şekil 29. Transfer-SAC ajanına ait tek faz arıza frekans yanıtı	79
Şekil 30. FV sistem için 0.3 pu iki faz arıza Transfer-DRL yanıtları	81
Şekil 31. FV sistem için 0.5 pu iki faz arıza Transfer-DRL yanıtları	82
Şekil 32. FV sistem için 0.7 pu iki faz arıza Transfer-DRL yanıtları	82

Şekil 33. Transfer-SAC ajanına ait iki faz arıza frekans yanıtı	84
Şekil 34. P&O algoritması akış diyagramı	85
Şekil 35. P&O tabanlı MPPT denetleyici sistemi.....	86
Şekil 36. DRL ile FV sistemde MPPT kontrolü blok diyagramı	86
Şekil 37. MPPT kontrolü için kullanılan çevre blok diyagramı	87
Şekil 38. MPPT için SAC ajanına ait eğitim eğrisi	89
Şekil 39. Statik durumda homojen ışıyım altında elde edilen maksimum güç değerleri	90
Şekil 40. Homojen güneş ışıyımının dinamik değişiminde maksimum güç değerleri	91
Şekil 41. Gölgeleme varken SAC ajanı dengeli arıza eğitim eğrileri.....	92
Şekil 42. Gölgeleme durumunda Transfer-SAC dengeli-dengesiz arıza eğitim eğrisi.....	95
Şekil 43. FV sistemin hem gölgeleme hem arıza altında 0.3 pu dengeli arıza yanıtları....	96
Şekil 44. FV sistemin hem gölgeleme hem arıza altında 0.3 pu iki faz arıza yanıtları	97
Şekil 45. FV sistemin hem gölgeleme hem arıza altında 0.3 pu tek faz arıza yanıtları.....	97
Şekil 46. Kısmi gölgeleme altında P-V eğrisi	99
Şekil 47. Kısmi gölgeleme ve dengeli arıza altında FV sistemin yanıtları.....	100
Şekil 48. Dengeli arıza için güçlü ve zayıf şebekelerde gerilim iyileşme yanıtları.....	101
Şekil 49. FV sistemin gerçek zamanlı modellenmesine ait test ortam fotoğrafı	103
Şekil 50. RT-LAB uyumlu sistem modeli	103
Şekil 51. Hesaplama (SM) alt sistem modeli	104
Şekil 52. Dengeli arıza için Transfer-SAC gerçek zamanlı çalışma yanıtları	104

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Çeşitli ülkelerdeki standart çalışma frekans sınırları	18
Tablo 2. Farklı ülkelerdeki LVRT parametreleri.....	20
Tablo 3. FV panel parametreleri.....	41
Tablo 4. Üç fazlı şebeke bağlantılı FV sistem parametreleri	44
Tablo 5. Optimizasyon parametre tablosu	47
Tablo 6. DDPG, TD3 ve SAC ajanlarının eğitim parametreleri	51
Tablo 7. DDPG ve TD3 ajanlarına ait parametreler	52
Tablo 8. SAC ajanına ait parametreler	52
Tablo 9. Dengeli arıza eğitim verileri için ITAE performans ölçüt değerleri	56
Tablo 10. Dengeli arıza test verileri için ITAE performans ölçüt değerleri.....	57
Tablo 11. Dengeli arıza için optimize edilmiş PI parametre değerleri	57
Tablo 12. Dengeli arıza eğitim verisi için aktif güç ve reaktif güç dinamik yanıtları.....	62
Tablo 13. Dengeli arıza test verisi için aktif güç ve reaktif güç dinamik yanıtları	63
Tablo 14. Tek faz arızasında eğitim verileri için ITAE performans ölçütü değerleri	66
Tablo 15. İki faz arızasında eğitim verileri için ITAE performans ölçütü değerleri	67
Tablo 16. Dengesiz arıza için optimize edilmiş PI parametre değerleri.....	67
Tablo 17. Tek faz arızasında eğitim verisi için aktif güç ve reaktif güç dinamik yanıtları .	71
Tablo 18. İki faz arızasında eğitim verisi için aktif güç ve reaktif güç dinamik yanıtları...	72
Tablo 19. Transfer-DRL için tek faz arızasında ITAE performans ölçütü değerleri	75
Tablo 20. Transfer-DRL için tek faz arızasında aktif güç ve reaktif güç dinamik yanıtları	78
Tablo 21. Transfer-DRL için iki faz arızasında eğitim verileri ITAE performans ölçütü...	80
Tablo 22. Transfer-DRL için iki faz arızasında test verileri için ITAE performans ölçütü	80
Tablo 23. Transfer-DRL için iki faz arızasında eğitim verileri dinamik yanıtları	83
Tablo 24. Transfer-DRL için iki faz arızasında test verileri dinamik yanıtları	84
Tablo 25. MPPT için SAC denetleyici gözlem uzayı.....	87
Tablo 26. MPPT için SAC eğitim parametreleri	88
Tablo 27. MPPT için SAC ajanına ait parametreler	89
Tablo 28. Statik durumda homojen ışınlam altında MPPT için performans ölçütleri	90
Tablo 29. Dinamik değişen homojen ışınlam altında performans ölçütleri	91
Tablo 30. Gölgeleme ve dengeli arıza altında ITAE performans ölçütleri	94
Tablo 31. Gölgeleme ve dengeli arıza altında dinamik yanıtlar	94
Tablo 32. Hem gölgeleme hem arıza altında FV sistemin ITAE performans ölçütleri.....	98

Tablo 33. Hem gölgelenme hem arıza altında FV sistemin dinamik yanıtları	98
Tablo 34. Kısmi gölgelenme ve dengeli arızada ITAE performans ölçütleri.....	99
Tablo 35. Kısmi gölgelenme ve dengeli arızada dinamik yanıtlar	99
Tablo 36. Dengeli arıza için güçlü ve zayıf şebekelerde gerilim iyileşme değerleri.....	101
Tablo 37. Zayıf şebekede dengeli arıza için ITAE performans ölçüt değerleri	102
Tablo 38. Zayıf şebekede dengeli arıza için aktif ve reaktif güçlerin dinamik yanıtları ...	102
Tablo 39. Simülasyon ve gerçek zamanlı çalışma için ITAE performans ölçüt değerleri	105
Tablo 40. Simülasyon ve gerçek zamanlı çalışma için dinamik yanıtlar	105



SEMBOLLER VE KISALTMALAR DİZİNİ

AA	: Alternatif akım
a	: Aksiyon
AC	: Aktör-kritik (Actor-Critic)
ADAM	: Adaptif moment tahmini (Adaptive Moment Estimation)
A_r	: Aksiyon uzay aralığı
b	: Bias vektörü
BESS	: Batarya enerji depolama sistemleri (Battery Energy Storage Systems)
D	: Doluluk-boşluk oranı
DA	: Doğru akım
DDPG	: Derin deterministik politika gradyan (Deep Deterministic Policy Gradient)
DFIG	: Çift beslemeli indüksiyon generatör (Doubly Fed Induction Generator)
DNN	: Derin sinir ağı (Deep Neural Network)
DRL	: Derin pekiştirmeli öğrenme (Deep Reinforcement Learning)
DVR	: Dinamik gerilim düzenleyici (Dynamic Voltage Restorer)
DQN	: Derin Q-ağı (Deep Q-Network)
EMS	: Enerji yönetim stratejisi (Energy Management Strategy)
FLC	: Bulanık mantık denetleyici (Fuzzy Logic Controller)
FOPID	: Kesir dereceli oransal-integral-türev (Fractional Order Proportional-Integral-Derivative)
FRT	: Arıza sonrası sisteme katkı (Fault Ride Through)
FV	: Fotovoltaik
GD	: Gradyan azaltma (Gradient Descent)
GWO	: Gri kurt optimizasyonu (Grey Wolf Optimization)
H	: SAC için entropi ölçüsü
HESS	: Hibrit enerji depolama sistemi (Hybrid Energy Storage System)
HVRT	: Yüksek gerilimde şebekede kalabilme (High Voltage Ride Through)
ITAE	: Zaman ağırlıklı mutlak hata integrali
I_q	: Reaktif akım
J	: SAC için amaç fonksiyonu
L	: Kayıp fonksiyonu
LVRT	: Düşük gerilimde şebekede kalma (Low Voltage Ride Through)

MDP	: Markov karar süreci (Markov Decision Process)
ML	: Makine öğrenimi (Machine Learning)
MPA	: Deniz avcısı algoritması (Marine Predator Algorithm)
MPC	: Model öngörülü kontrol (Model Predictive Control)
MPPT	: Maksimum güç noktası takibi (Maximum Power Point Tracking)
MV	: Ortak vektör
N	: DDPG aksiyon gürültüsü
OU	: Ornstein-Uhlenbeck aksiyon gürültüsü
PG	: Politika gradyanı (Policy Gradient)
PI	: Oransal-integral (Proportional Integral)
PLL	: Faz kilitli çevrim (Phase Locked Loop)
PPO	: Proksimal politika optimizasyonu (Proximal Policy Optimization)
PSO	: Parçacık sürü optimizasyonu (Particle Swarm Optimization)
pu	: per-unit
P&O	: Değiştir-gözle (Perturb and Observe)
P^*	: Referans aktif güç
Q	: Aksiyon değer fonksiyonu
Q'	: Optimal aksiyon değer fonksiyonu
Q^*	: Referans reaktif güç
r	: Ödül
ReLU	: Doğrultulmuş lineer birim (Rectified Linear Unit)
s	: Durum
s'	: Gelecek durum
SAC	: Soft aktör-kritik (Soft Actor-Critic)
SCR	: Kısa devre oranı (Short Circuit Ratio)
SDBR	: Seri dinamik frenleme direnci (Series Dynamic Breaking Resistor)
S_n	: Kısa devre kapasite gücü
SOS	: Simbiyotik organizma arama (Symbiotic Organism Search)
SR	: Seri direnç (Series Resistor)
TD	: Zamansal fark (Temporal Difference)
TD3	: İkiz gecikmeli derin deterministik politika gradyan (Twin Delayed Deep Deterministic Policy Gradient)
THD	: Toplam harmonik bozunum (Total Harmonic Distortion)

TRPO	: Güven bölgesi politika optimizasyonu (Trust Region Policy Optimization)
t_r	: Yükselme süresi
t_s	: Oturma süresi
V	: Durum değer fonksiyonu
V^*	: Optimal durum değer fonksiyonu
V_{DA}	: DA bara gerilimi
V_{dip}	: Arıza gerilim değeri
W	: Ağırlık matrisi
WCA	: Su döngüsü algoritması (Water Cycle Algorithm)
ZVRT	: Sıfır gerilimde şebekede kalabilme (Zero Voltage Ride Through)
α	: SAC için sıcaklık parametresi
σ	: Gürültü modelinin standart sapması
μ	: Gürültü modelinin ortalaması
ε'	: TD3 hedef aksiyon gürültüsü
τ	: Yumuşak hedef güncelleme katsayısı
γ	: Azaltma faktörü
π	: Politika
π'	: Optimal politika
θ	: Ağ parametresi

1. GENEL BİLGİLER

1.1. Giriş

Elektrik enerjisine olan talep, nüfus artışı, sanayileşme ve teknolojik gelişmelerle birlikte her geçen gün artmaktadır. Bu talebi karşılamak için en yaygın kullanılan enerji kaynakları kömür, petrol ve doğalgaz gibi fosil yakıtlardır. 2023 yılında elektrik üretiminde petrol, kömür ve doğalgazdan sırasıyla 54.564 TWh, 45.565 TWh ve 40.103 TWh kullanılmıştır (Şirin, 2025). Ancak bu kaynaklar doğada sınırlı miktarda bulunur ve yenilenmesi uzun zaman alır. Ayrıca yaygın kullanımları yalnızca kaynakların tükenme riskine yol açmakla kalmaz, küresel ısınmayı hızlandırma ve hava kalitesini düşürme gibi çevresel sorunlara da neden olur. Bu problemler, ekosistemi, toplumsal refahı ve sürdürülebilir kalkınmayı doğrudan etkiler.

Bu nedenle, çevresel etkileri azaltan ve uzun vadede enerji arz güvenliğine katkı sağlayan yenilenebilir enerji kaynakları ön plana çıkmıştır. 2023 yılında hidroelektrik santrallerden 11.014 TWh, rüzgar enerjisinden 6.040 TWh, güneş enerjisinden ise 4.264 TWh elektrik üretilmiştir. Küresel çapta yenilenebilir enerjinin elektrik üretimindeki payı 2000 yılında % 7 seviyesindeyken, 2023'te %13.67'ye yükselmiştir (Şirin, 2025). Bu kaynakların geliştirilmesi ve yaygınlaştırılması, hem çevresel sürdürülebilirlik hem de enerji arzında dışa bağımlılığın azaltılması açısından stratejik öneme sahiptir.

Türkiye'de hızlı ekonomik büyüme ve nüfus artışı, dünya genelinde olduğu gibi enerji talebini artırmaktadır. Bu durum, ülkenin enerji ithalatına olan bağımlılığını da güçlendirmektedir. Türkiye'nin kurulu elektrik gücü 2000 yılında 27.264 MW iken, 2023 yılı itibari ile 110.914 MW'a ulaşmıştır. 2023 yılındaki kurulu güçte hidroelektrik santraller %28.8, güneş enerjisi %14.08 ve rüzgar enerjisi %10.64 paya sahiptir (Şirin, 2025).

Güneş enerjisi, yenilenebilir enerji kaynakları arasında hem küresel ölçekte hem de OECD ülkelerinde stratejik öneme sahiptir. 2012-2040 yılları arasında yenilenebilir kaynaklardan elektrik üretimindeki en büyük artışın güneş enerjisi alanında gerçekleşmesi beklenmektedir (Çakmak, 2018).

Türkiye'de 5346 ve 6093 sayılı Yenilenebilir Enerji Kaynakları Kanunları ve bu kanunlar kapsamında çıkarılan yönetmelikler, yenilenebilir enerji kaynaklarından elektrik üretimini teşvik etmek için önemli adımlar atmıştır. Bu düzenlemeler özellikle güneş enerjisi alanında kayda değer bir artış sağlamıştır. Türkiye'nin güneş enerjisi kurulu gücü 2023 yılı

sonunda 11.316 MW iken, 2024 yılı sonunda yaklaşık %24.5 artışla 19.590 MW'a yükselmiştir (Enerji Günlüğü, 2024). Bu gelişmeler, Türkiye'nin 2014 yılında 2023 için belirlediği 5.000 MW'lık hedefinin çok üzerine çıkıldığını göstermektedir.

Fotovoltaik (FV) sistemler gibi dağıtık üretim birimlerinin elektrik şebekesine entegrasyonu giderek artmakta ve geleneksel şebeke yapısında önemli değişimlere yol açmaktadır. Bu durum, özellikle dağıtım seviyesinde kontrolsüz adalanma, hatlarda aşırı yüklenme ve güç kalitesi problemleri gibi teknik zorluklar getirmiştir. Ancak bu sorunların yanı sıra, sistemin çalışmasını iyileştiren çözümler de sunmaktadır.

Bu çözümlerden biri, yenilenebilir kaynakların arıza sırasında çalışmaya devam etme yetenekleridir. Ana şebekede arıza meydana geldiğinde, yenilenebilir kaynaklar genellikle zarar görmemek için şebekeden ayrılır. Bu işlem kaynakları korusa da şebekenin zayıflamasına neden olur ve arızalı alan dışındaki yüklerin beslenmesini zorlaştırır. Ayrıca arıza sırasında yenilenebilir kaynakların şebekeden ayrılması, güç sisteminin kararlılığı ve yönetimi açısından da sorun yaratabilir.

Bu nedenle çoğu ülke, dağıtık üretim birimlerine yönelik şebeke yönetmeliklerinde düzenlemeler yapmıştır. Bu düzenlemeler başlangıçta orta veya yüksek gerilim seviyesindeki dağıtık birimlere uygulanırken, FV sistemlerin yüksek penetrasyonu ile alçak gerilim seviyesinde de uygulanmaya başlanmıştır (Lin vd., 2020). Güncel şebeke yönetmelikleri arasında düşük gerilimde şebekede kalma (Low Voltage Ride Through, LVRT) yeteneği öne çıkmaktadır. LVRT, kısa süreli şebeke arızası sırasında FV sistemlerin şebekeye bağlı kalmasını ve reaktif güç desteği ile sistem kararlılığını desteklemesini gerektirir. LVRT yeteneği ile şebekeye reaktif güç desteği sağlanırken, FV sistemden elde edilen aktif gücün de kontrol edilmesi gerekir. Aksi takdirde doğru akım (DA) bara gerilimi ve evirici akım sınırları aşılarak FV sistemin şebekeden ayrılmasına neden olur. Bu gereklilik, evirici tabanlı kontrol yöntemleri ve donanımsal yaklaşımlarla sağlanmakta olup sistemin arıza sonrası toparlanma sürecine de katkıda bulunmayı hedeflemektedir.

LVRT yeteneğini sağlamak için DA kıyıcı devresi, STATCOM ve depolama enerji sistemi gibi donanımsal yaklaşımlar kullanılır. Bu sistemler DA veya AA tarafında konumlandırılarak şebeke kararlılığını artırır ve şebeke yönetmeliklerine uyumu destekler. Ancak bu çözümler, yüksek kurulum ve işletme maliyetleri nedeniyle ekonomik uygulanabilirliği sınırlamaktadır.

Evirici tabanlı kontrol yöntemlerinde geleneksel denetleyicilerden oransal-integral (Proportional-Integral, PI) denetleyici, basit bir yapısı nedeniyle yaygın kullanılmaktadır.

Ancak bu denetleyicilerin model belirsizlikleri ve hızlı deęiřen sistem dinamikleri karřısında sınırlı genelleme kapasitesine sahip olması önemli bir dezavantaj oluřturmaktadır. Ayrıca PI parametreleri çoęunlukla deneme-yanılma yöntemiyle belirlenmekte ve sistem performansını tasarımcının uzmanlığına büyük ölçüde baęımlı hale getirmektedir.

Model öngörölü kontrol (Model Predictive Control, MPC) yaklaşımı, sistemin matematiksel modelini kullanarak gelecekteki davranışları tahmin eder ve belirli bir optimizasyon kriterini karřılamak üzere kontrol eylemlerini belirler. PI denetleyiciye kıyasla genellikle daha iyi performans gösterse de, MPC'nin uygulamaya yönelik bazı sınırlamaları vardır. Birincisi, bu yöntemin hesaplama yükü yüksektir. İkincisi, modellenmemiş hatalar ve bozulmalarla karřılařıldığında yanlış tahminler hatalı sonuçlara yol açabilir.

Bulanık mantık denetleyici (Fuzzy Logic Controller, FLC), sistem modeline ihtiyaç duymadan belirsizlikler altında hızlı ve sezgisel kontrol sağlar. Ancak çok sayıda kural tablosu ve üyelik fonksiyonu tanımlanması gerektiğinden, sistem karmařıklığı arttıkça denetleyici tasarımı zorlařır ve büyük ölçekli uygulamalarda genelleme kapasitesi sınırlanabilir.

Ortam hakkında ön bilgi gerektirmemesiyle öne çıkan derin pekiřtirmeli öğrenme (Deep Reinforcement Learning, DRL) yöntemleri, enerji alanında da yaygın olarak kullanılmaya bařlamıştır. (Phan vd., 2020; Yin vd., 2023; Xu vd., 2022) çalışmalarında, FV sistemlerde maksimum güç noktası takibi (Maximum Power Point Tracking, MPPT), planlama ve enerji yönetimi kontrol görevlerinde kullanılan DRL yöntemleri geleneksel denetleyicilere göre üstün performans göstermiştir.

Bu tez kapsamında, řebeke baęlantılı FV sistemin kısa süreli arıza sırasında řebekeye baęlı kalarak enerji sürekliliğini saęlaması için LVRT yeteneğinin geliştirilmesine yönelik DRL tabanlı bir kontrol yapısı önerilmiştir. Önerilen yöntem, řebeke arızası sırasında reaktif güç desteęi saęlayarak hem řebeke kararlılığını artırmayı hem de aktif güç akışını kontrol etmeyi hedeflemektedir. Böylece reaktif güç ile řebekeye gerilim desteęi saęlanırken DA bara gerilimi ve AA akım sınırları korunarak řebeke baęlantısının devamı saęlanacaktır. Ayrıca, DRL tabanlı kontrol ile FV sistemin arıza sırasındaki dinamik davranışları iyileřtirilerek güncel řebeke yönetmeliklerine uyum saęlaması hedeflenmektedir. Önerilen kontrol yönteminin gerçek zamanlı uygulamalar için dayanıklılığını artırmak amacıyla güneř ışıınımı gibi çevresel faktörler ve řebeke parametre deęişimleri de göz önünde bulundurulmuřtur. Sistemin genelleme yeteneęi geliştirilerek her durumda enerji süreklilięi saęlanacaktır.

1.2. Literatür Araştırması

FV sistemlerde çevresel faktörlere bağlı olarak üretilen güç değeri gün içinde değiştiği için, FV panellerden maksimum verimle faydalanmak amacıyla MPPT yöntemleri kullanılmaktadır. Gün içinde her panele düşen gün ışığı eşit olmadığında kısmi gölgelenme durumu ortaya çıkar. Kısmi gölgelenmede, gölgeli panel bir yük gibi davranarak diğer panellerden akım çekmeye çalışır. Bu durum hem güç kaybına hem de sıcak nokta oluşumuna yol açarak panellere zarar verir.

Bu sorunu çözmek için panellere paralel bağlı bypass diyot kullanılır. Bypass diyot, gölgelenme olduğunda iletme geçerek gölgeli paneli devre dışı bırakır ve akımın diyot üzerinden geçmesini sağlar. Böylece sıcak nokta oluşumu önlenir ancak güç-gerilim (P-V) eğrisinde birden fazla güç noktası oluşur, bunlardan biri küresel, diğerleri yerel maksimum güç noktalarıdır. FV sistem yerel maksimum güç noktasında çalıştığında verim düşer. Bu nedenle gölge etkili FV sistemlerde MPPT'nin önemi daha da artar.

MPPT için geleneksel yöntemlere bakıldığında, değiştir gözle (Perturb and Observe, P&O) algoritması ve artan iletkenlik algoritması yaygın olarak kullanılmaktadır. Bu yöntemler homojen güneş ışınlamı altında etkili sonuçlar verir, ancak kısmi gölgelenme koşullarında yerel maksimum güç noktasına takılma ve osilasyon gibi dezavantajları vardır.

Daha gelişmiş yöntemler olarak (Titri vd., 2017; Kaced vd., 2017; Yang vd., 2019) çalışmalarında sırasıyla karınca koloni optimizasyonu, yarasa ilhamlı optimizasyon ve biyo-ilhamlı memetik salp sürüsü optimizasyon yöntemleri kullanılmıştır. Bu yöntemler kısmi gölgelenme koşullarında etkili sonuçlar verse de iteratif oldukları için çevrim içi durumlarda dinamik yanıtları yavaş kalır. (Artetxe vd., 2023; Nwachukwu vd., 2025) çalışmalarında DRL tabanlı yöntemler hem homojen hem de kısmi gölgelenme koşulları altında test edilmiş ve geleneksel yöntemlere kıyasla daha başarılı sonuçlar vermiştir.

Yenilenebilir enerji kaynaklarının şebeke entegrasyonu, modern güç sistemlerinde yeni gereksinimler ortaya çıkarmaktadır. Gerilim kararlılığı, reaktif güç kontrolü, aktif güç kontrolü, güç kalitesi ve arıza sonrası sisteme katkı (Fault Ride-Through, FRT) gittikçe önem kazanmaktadır (Al-Shetwi vd., 2020). Yenilenebilir enerji kaynaklarının penetrasyon seviyesi arttıkça, bu kaynakların arıza sırasında şebekeden ayrılması sistem kararlılığını olumsuz etkilemektedir. Bu nedenle güncel şebeke yönetmelikleri, arıza sırasında bu kaynakların şebekeye bağlı kalmasını ve belirli miktarda reaktif güç desteği sağlamasını zorunlu kılmaktadır (Talha vd., 2020). Reaktif akım desteğinin miktarı ve süresi ülkelere

özgü yönetmeliklerle belirlenmektedir. FRT gerekliliği kapsamında, kısa devre arızalarında sık karşılaşılan gerilim düşümleri nedeniyle LVRT yeteneği literatürde en çok çalışılan konulardan biridir.

LVRT yeteneğinin geliştirilmesine yönelik çalışmalar, donanımsal yaklaşımlar ve evirici tabanlı kontrol yöntemleri olmak üzere iki kategoriye ayrılabilir. Yaygın kullanılan donanımsal yaklaşımlardan biri DA kıyıcı devresidir. (Pereira vd., 2018) çalışmasında, çift beslemeli indüksiyon generatör (Doubly Fed Induction Generator, DFIG) sisteminde LVRT için crowbar ve DA kıyıcı devreleri kullanılmıştır. Çalışmada, kıyıcısız ve kıyıcılı DFIG modelleri karşılaştırılmıştır. Simülasyon sonuçlarına göre, kıyıcı olmadığında arıza sırasında rotor akımı artmış ve DA bara gerilimi 1.2 per unit (pu) değerini aşmıştır. Bu durumda crowbar devresi devreye girerek rotor tarafı dönüştürücünün bağlantısını kesmiştir. Kıyıcı kullanıldığında ise DA bara gerilimi 1.1 pu'ya ulaştığında kıyıcı devresi aktif hale gelmiş ve arıza süresince devrede kalmıştır. Böylece rotor akımı azalmış, crowbar koruması tetiklenmemiş ve DFIG şebekeye reaktif güç desteği sağlamaya devam etmiştir.

(Gencer, 2025) çalışmasında, FV sistemler için DA kıyıcı ile kapasitif köprü arıza akım sınırlayıcı içeren hibrit bir LVRT koruma sistemi önerilmiştir. Hibrit sistem kontrolü için makine öğrenimi (Machine Learning, ML) yaklaşımı kullanılmıştır. Yöntemde, hem normal hem de arıza koşullarında optimum koruma parametrelerini gerçek zamanlı tahmin etmek amacıyla geçmiş veriler üzerinde eğitilmiş ML modelleri kullanılmıştır. 20 farklı sınıflandırıcı algoritma arasından orta Gauss DVM sınıflandırıcı, hibrit koruma sistemi için %98.37 doğruluk ve %99.17 F1 skoru elde etmiştir. Hibrit yaklaşımın, tek başına kullanılan DA kıyıcı veya hata akım sınırlama yöntemlerine göre daha etkili olduğu belirtilmiştir.

(Muisyo vd., 2022) çalışmasında, 9 MW kapasiteli DFIG tabanlı bir rüzgar enerji sisteminin LVRT yeteneğini geliştirmek amacıyla STATCOM tabanlı bir kontrol yaklaşımı incelenmiştir. STATCOM parametreleri, Su döngüsü algoritması (Water Cycle Algorithm, WCA), Parçacık sürü optimizasyonu (Particle Swarm Optimization, PSO) ve hibrit WCA-PSO algoritmaları ile optimize edilmiştir. LVRT gerekliliğini analiz etmek için tek faz toprak ve üç faz toprak arızaları uygulanmıştır. Tek faz arıza durumunda Danimarka şebeke yönetmeliği sağlanmış ve gerilim dalgalanması %17'den %3'e düşürülmüştür. Üç faz arıza durumunda ise STATCOM kullanılmadığında gerilim seviyesi tamamen çökmüş ve türbinler devreden çıkmıştır. Ancak WCA-PSO algoritması ile optimize edilmiş STATCOM sayesinde, rüzgar enerji sistemi aynı koşullar altında şebekeye bağlı kalabilmiştir. Bu durumda gerilim dalgalanması %60'tan %25'e azaltılmıştır.

STATCOM dışında, LVRT performansını artırmak için farklı esnek alternatif akım iletim sistemi tabanlı cihazlar da kullanılmaktadır. (Benali vd., 2018) çalışmasında, rüzgar ve güneş enerjisinden oluşan hibrit bir dağıtık üretim sisteminin güç kalitesini artırmak ve LVRT yeteneğini iyileştirmek amacıyla dinamik gerilim düzenleyici (Dynamic Voltage Restorer, DVR) önerilmiştir. Elde edilen sonuçlara göre, DVR entegre edilen sistem şebekedeki gerilim kesintilerini ve kısa devre arızalarını etkili şekilde sönümlemekte, gerilim regülasyonunda esneklik sunmakta ve güç faktörünü düzeltmede başarılı olmaktadır. Simülasyon sonuçları, sistemin güvenli çalıştığını, gerekli gerilim sınırlarının korunduğunu ve dağıtık üretim kaynaklarının güvenilir biçimde çalıştığını doğrulamaktadır. Önerilen yapının temel avantajları: gerilim seviyesinin hızlı toparlanması, güç salınımlarındaki aşmanın azaltılması, rotor hızının kontrol edilmesi ve DA bara aşırı gerilimlerinin önlenmesidir. Bu özellikler sistem kararlılığını artırmaktadır.

(Alaboudy vd., 2023) çalışmasında, Mısır elektrik şebekesine bağlı Al-Zafarana rüzgar santralinin LVRT kapasitesini artırmak için seri direnç (Series Resistor, SR) tabanlı bir koruma sistemi önerilmiştir. Bu sistem, enerji dönüştürücülerini, rotor devrelerini ve DA bara kapasitörlerini korurken, rotor akımlarını, DA bara gerilimlerini ve tork değişikliklerini sınırlamayı hedeflemektedir. Simülasyon sonuçları, SR yapısının farklı arıza senaryolarında etkili olduğunu göstermiştir. %60 dengeli arıza durumunda, rotor akımı 1.77 pu'dan 1.14 pu'ya düşürülmüş ve DA bara şarj akımı azaltılarak aşırı gerilim ve tork salınımları önemli ölçüde engellenmiştir. %95 gibi daha şiddetli arıza durumunda, rotor akımı 2.5 pu'dan 1.21 pu'ya indirilmiş, tork osilasyonları ve DA bara zorlanması azaltılmıştır. Tek faz-toprak kısa devre senaryosunda ise rotor akımı 1.7 pu'dan 1.06 pu'ya düşürülerek rotor tarafı dönüştürücünün kontrol edilebilirliği artırılmış ve DA bara gerilim yükselmeleri önlenmiştir. Bu bulgular, SR tabanlı koruma yapısının hem dengeli hem de dengesiz arızalarda rotor akımlarını, DA bara zorlanmalarını ve tork salınımlarını azaltarak şebekeye bağlı rüzgar enerji sistemlerinin LVRT performansını ve kararlılığını önemli ölçüde iyileştirdiğini ortaya koymuştur.

(Döşoğlu, 2023) çalışmasında, 2.3 MW gücünde DFIG tabanlı bir rüzgar türbininin DA barasına arama tablosu tabanlı kontrol algoritmasıyla çalışan bir süperkapasitör sistemi entegre edilmiş ve bir STATCOM ünitesiyle birlikte kullanılmıştır. LVRT analizi için 34.5 kV barada üç fazlı ve iki fazlı arızalar, 0.58-0.68, 0.58-0.73 ve 0.58-0.78 saniye zaman aralıklarında uygulanmıştır. Üç faz arıza durumunda, elektriksel moment -3.8-6 pu, d eksen stator akımı -2.5-2.8 pu ve q eksen stator akımı -1.3-1.2 pu aralıklarında salınım

göstermiştir. Önerilen yaklaşım ile elektriksel moment 0.03-0.25 p.u, d eksen stator akımı -0.025-0.18 p.u ve q eksen stator akımı -0.01-0.01 pu aralıklarına düşmüştür. İki fazlı arıza durumunda oluşan salınımlar, üç fazlı arızaya kıyasla daha düşük seviyelerde gerçekleşmiştir. Önerilen yaklaşım olmadan elektriksel moment -0.58-0.76 pu, d eksen stator akımı -0.38-0.44 pu ve q eksen stator akımı -0.22-0.19 pu aralıklarında salınım gösterirken, önerilen yaklaşım ile elektriksel moment 0-0.18 pu, d eksen stator akımı -0.25-0.166 pu ve q eksen stator akımı -0.082-0.016 pu aralıklarına düşmüştür.

Batarya enerji depolama sistemleri (Battery Energy Storage Systems, BESS), süperkapasitörlere kıyasla daha yavaş tepki süresine sahip olmalarına rağmen, FV sistemlerde LVRT desteği açısından etkili bir rol oynamaktadır (Chatzigeorgiou vd., 2024). (Gholipour vd., 2025) çalışmasında, 100 kW iki aşamalı üç fazlı şebeke bağlantılı bir FV sistemde LVRT için BESS destekli bir kontrol stratejisi uygulanmıştır. Simülasyon sonuçlarında LVRT analizi için 0.15 saniye süren 0.5 pu üç faz arızası, 0.6 pu iki faz toprak arızası ve 0.45 pu tek faz toprak arızalarında negatif bileşen şebeke akımı %1'den az tutulmuş ve eviricideki kapasitörlerin gerilim dengesi korunmuştur. Ayrıca, DA bara kapasitörleri üzerindeki gerilim dalgalanmaları arıza sırasında %7 ile sınırlanmıştır.

LVRT yeteneğini sağlamak için kullanılan donanımsal yaklaşımlar, sistem kararlılığını artırma ve ulusal/uluslararası şebeke yönetmeliklerine uyum sağlama açısından önemli avantajlara sahiptir. Ancak, bu yaklaşımlar bazı teknik ve ekonomik sınırlamaları da beraberinde getirmektedir. İlk olarak, yüksek kurulum ve işletme maliyetleri bu yöntemlerin en belirgin dezavantajlarından. STATCOM, DA kıyıcı ve BESS gibi donanımlar güç elektroniği elemanları, koruma devreleri ve soğutma üniteleri gibi ek sistem bileşenlerine ihtiyaç duyar. Bu durum toplam sistem maliyetini önemli ölçüde artırır ve özellikle küçük ve orta ölçekli enerji kaynakları için ekonomik uygulanabilirliği sınırlar. İkinci olarak, crowbar devresi bazı durumlarda güç kalitesini olumsuz etkileyebilir. Arıza sırasında rotor devresini kısa devre yaparak rotor tarafı dönüştürücüyü geçici olarak devre dışı bırakır ve generatörü sadece endüksiyon generatörü modunda çalışmaya zorlar. Bu geçici kontrol kaybı, generatörün şebekeden kontrolsüz şekilde reaktif güç çekmesine ve sistemin gerilim toparlanma süresinin uzamasına neden olur. Son olarak, donanımsal yaklaşımların dinamik tepkileri bazı arıza senaryoları için yetersiz kalabilir. Özellikle batarya tabanlı enerji depolama sistemleri, süperkapasitörlere kıyasla daha düşük tepki süresine sahiptir. Bu nedenle ani gerilim çökmesi gibi hızlı gerilim değişimlerinde yeterli reaktif güç desteği sağlanamaz ve şebeke ile senkronizasyon gecikmesi yaşanabilir.

(Jaalam vd., 2016) çalışmasında, FV sistemde LVRT yeteneği için geleneksel PI denetleyici önerilmiştir. 1 MW'lık FV sistemde 4.saniyede başlayan 0.15 saniye süren dengeli üç faz arıza uygulanmıştır. Arıza sırasında DA bara gerilim sınırı korunmuş ve reaktif akım enjekte edilerek şebeke gerilim desteği sağlanmıştır. Geleneksel PI denetleyici, basit bir kontrol yöntemi olarak evirici kontrolünde yaygın şekilde kullanılır. Düşük yükselme süresi ve minimum kararlı durum hatası gibi avantajlar sunar. Ancak belirsiz sistemlerde genellikle yüksek kararlı durum hatası gösterir. Denetleyici parametreleri teorik hesaplama veya deneme yanılma yöntemiyle ayarlanır. Bu durum, sistem performansını tasarımcı uzmanlığına bağımlı hale getirir.

Çeşitli çalışmalarda (Elazab vd., 2020; Qais vd., 2020; Qais vd., 2018; Mostafa vd., 2023; Muisyo vd., 2022; Ellithy vd., 2024) LVRT gerekliliğinde PI denetleyici parametreleri, farklı algoritmalar kullanılarak optimize edilmiştir. Bu algoritmalar arasında salp sürü algoritması, optimal geçici arama algoritması, gri kurt optimizasyon algoritması (Grey Wolf Optimization, GWO), bonobo optimizasyon algoritması, WCA-PSO hibrit algoritması ve deniz avcısı algoritması (Marine Predator Algorithm, MPA) yer almaktadır. (Ellithy vd., 2024) çalışmasında, şebekeye bağlı bir FV eviricide kullanılan PI denetleyici parametreleri MPA ile optimize edilmiştir. Üç fazlı kısa devre arızasında MPA ile optimize edilen PI denetleyici, PSO ve GWO algoritmaları ile ayarlanan denetleyicilere kıyasla daha iyi LVRT performansı göstermiştir. Bulgular, önerilen algoritmanın DA bara gerilimi ve aktif güç açısından %14 ile %40 daha az aşma ve daha yüksek bir yakınsama oranı sağladığını ortaya koymuştur. Ayrıca MPA tabanlı PI denetleyicisi, PSO ve GWO'dan 0.76 ile 0.95 saniye daha kısa yerleşme süresi sunmuştur.

(Desalegn vd., 2022) çalışmasında, 2 MW kapasiteli bir DFIG rüzgar türbininde iki serbestlik derecesine sahip (2-DOF) PI denetleyici uygulanmıştır. 2-DOF PI denetleyicide, geleneksel PI denetleyiciden farklı olarak hem referans girişe hem de hata sinyaline dahil iki ayrı ağırlık uygulanır. Hem normal hem de arıza durumlarında performans karşılaştırması yapılmıştır. Normal durumda aktif güç çıkışı her iki denetleyicide benzer düzeydedir. Ancak 2-DOF PI ile rotor q-akımındaki toplam harmonik bozunum (Total Harmonic Distortion, THD), %9.15'ten %7.72'ye düşürülmüştür. 0.1 pu arıza durumunda ise THD değeri %35.46'dan %28.79'a inmiştir. Böylece arıza sırasında ve sonrasında daha düzgün akım ve moment elde edilerek güç kalitesi artırılmıştır.

(Yamparala vd., 2023) çalışmasında, DFIG tabanlı rüzgar türbini için bir kesir dereceli oransal-integral-türev (Fractional Order Proportional-Integral-Derivative, FOPID)

denetleyici tasarlanmıştır. Denetleyici parametreleri, deniz aslanı optimizasyonu ve GWO hibrit yöntemi kullanılarak optimize edilmiştir. Testlerde 0.1 saniye süren dengeli 0.5 pu arıza gerilimi uygulanmıştır. FOPID denetleyici, ek donanım ihtiyacı duymadan DFIG sistemini kararlı hale getirmiştir ve DA bara gerilimindeki aşmayı azaltmıştır. Rotor akımındaki THD %2.56 olarak elde edilmiştir ve diğer yöntemlere göre önemli bir iyileşme sağlanmıştır. Stator akımı ± 1.5 pu sınırları içinde kalmıştır.

PI denetleyici yaklaşımı, sistemin LVRT yeteneğini karşılama ve DA bara gerilim sınırlarını sağlamada etkilidir. Fakat bu denetleyicilerin model belirsizlikleri ve hızlı değişen sistem dinamikleri karşısında sınırlı genelleme kapasitesine sahip olması önemli bir dezavantaj oluşturmaktadır. Ayrıca, PI parametreleri çoğunlukla çevrim dışı optimizasyon yöntemleriyle belirlenir. Bu durum, parametrelerin gerçek zamanlı çalışma koşullarında sabit kalmasına yol açar ve kontrol performansını olumsuz etkileyebilir.

MPC yaklaşımı, FV sistemlerin LVRT yeteneğini artırmak için son yıllarda yaygın olarak kullanılan bir kontrol yöntemidir. Bu yaklaşımda denetleyici, sistemin matematiksel modelini kullanarak gelecekteki davranışları tahmin eder ve belirli bir optimizasyon kriterini karşılamak üzere kontrol eylemlerini belirler. (Nie vd., 2023) çalışmasında, DFIG tabanlı rüzgar türbininin LVRT yeteneğini iyileştirmek için değişken adımlı bir MPC (Variable-Step-MPC, VS-MPC) algoritması geliştirilmiştir. Önerilen yöntem, LVRT sırasında rotor akımının referans değere hızlı ve kararlı bir şekilde ulaşmasını sağlayarak türbinlerin şebekede kalma yeteneğini artırmaktadır. Ayrıca, arıza sırasında aşırı arıza akımını bastırmak için rotor tarafına bir crowbar devresi eklenmiştir. Geliştirilen VS-MPC algoritmasının performansı, 0.625 saniye süren 0.2 pu üç faz arıza durumunda test edilmiştir. Sonuçlara göre, MPC yöntemi geleneksel PI denetleyiciye kıyasla rotor akımını daha doğru izleyebilmekte ve LVRT performansını artırmaktadır. VS-MPC yöntemi, LVRT süresince adım büyüklüğünü DA bara gerilimindeki değişimlere göre dinamik olarak ayarlayarak geçici durum bileşenlerinin daha hızlı sönümlenmesini ve kontrol hassasiyetinin artırılmasını sağlamıştır. MPC'ye kıyasla rotor akım genliği %33 oranında azaltılmış, aktif güç düşüşü ise yaklaşık %12 oranında sınırlandırılarak sistemin toparlanma süresi hızlandırılmıştır.

(Ali vd., 2022) çalışmasında, sabit mıknatıslı senkron generatör tabanlı rüzgar türbinleri için LVRT yeteneğini sağlamak amacıyla sonlu kontrol kümesi- MPC (Finite Control Set-MPC, FCS-MPC) yöntemi önerilmiştir. Bu yöntem, amaç fonksiyonu minimizasyonu için optimize edilmiş anahtarlama durumlarını belirler. Ayrıca geçici

koşullarda aktif ve reaktif güç arasındaki çapraz kuplajı azaltmak için ağırlık faktörlerini tespit eder. Böylece hem türbin tarafı hem de şebeke tarafı dönüştürücüler kontrol edilerek arıza sırasında DA bara gerilim sınırı korunur ve şebekeye reaktif güç enjekte edilir. FCS-MPC yönteminin etkinliği, dengeli ve dengesiz şebeke arızaları durumunda geleneksel PI denetleyici ile karşılaştırılmıştır. 0.5 saniye süren 0.3 pu dengeli arıza durumunda, FCS-MPC algoritması DA bara gerilimini referans gerilim olan 1150 V'a yakın bir değerde tutarak dönüştürücülerin kapanmasını engellemiştir. PI denetleyicide ise gerilim 1490 V'a kadar yükselmiştir. Aynı arıza değeri için dengesiz arıza uygulandığında, önerilen yöntemle DA bara gerilimi kararlı halini sürdürmüş ve reaktif güç desteği PI denetleyiciye kıyasla daha hızlı sağlanmıştır. Bununla birlikte, PI denetleyicide şebeke frekansının neredeyse iki katı aktif güç dalgalanması görülmüştür.

(Gholipour vd. 2025) çalışmasında, iki kademeli üç fazlı şebeke bağlantılı FV sistem için FCS-MPC tabanlı çok amaçlı bir kontrol stratejisi önerilmiştir. Önerilen yaklaşım, sistem performansını artırmak amacıyla bir BESS ile entegre edilmiştir. Bu yöntemle, hem MPPT kontrolü hem de LVRT sırasında aktif ve reaktif güç kontrolü sağlanır. Dengeli ve dengesiz arıza durumlarında, akımın pozitif bileşeni kullanılarak sinüzoidal akım enjeksiyonu gerçekleştirilmiştir. Sonuçlara göre BESS, tek faz arızasında 15.7 kW, iki faz arızasında 42 kW enerji depolar. Reaktif güç enjeksiyonu tek faz arızasında 28.9 kVAr, iki faz arızasında 45 kVAr olarak ölçülmüştür. Ayrıca negatif bileşen akımı %1'in altında tutulmuş ve DA bara gerilim dalgalanması %7 ile sınırlandırılmıştır.

Ancak, MPC'nin uygulamaya yönelik bazı sınırları vardır. İlk olarak, bu kontrol yöntemi optimizasyon için yoğun çevrim içi hesaplamalar gerektirir ve bu nedenle hesaplama yükü yüksektir. İkinci olarak, modellenmemiş hatalar ve bozulmalarla karşılaşıldığında yanlış tahminler üretebilir. Bu da hatalı sonuçlara ve zayıf dinamik performansa yol açar.

FLC, özellikle belirsizliklerin yoğun olduğu şebeke arıza koşullarında, deneysel bilgiye dayalı kural tabloları ile sistemin LVRT yeteneğini iyileştiren esnek bir kontrol yaklaşımıdır. (Radwan vd., 2019) çalışmasında, tek fazlı şebeke bağlantılı FV sistemlerde LVRT yeteneği için FLC önerilmiştir. Bu yöntemde, arıza sırasındaki gerilim değeri ve FV dizinden elde edilen güce göre reaktif güç miktarı belirlenir. LVRT analizi için %75, %50 ve %10 seviyelerinde şebeke arızası uygulanmıştır. %75 gerilim düşümünde evirici, aktif güç çıkışını sınırlandırarak 1722 W düzeyine düşürmüş ve böylece 1016 VAr reaktif güç enjekte ederek şebeke gerilimini desteklemiştir. Bu senaryoda güç faktörü 0.86 olarak

belirlenmiş, evirici akımı ise nominal değerinin yaklaşık 1.3 katına ulaşmıştır. %50 gerilim düşmesinde aktif güç sıfırlanmış, evirici kapasitesinin tamamı reaktif güç üretimi için kullanılmış ve güç faktörü sıfıra düşmüştür. %10 gerilim seviyesinde de aktif güç sıfırlanarak evirici yalnızca reaktif güç sağlamış ve güç faktörü yine sıfıra düşmüştür. Elde edilen sonuçlar, eviricinin arıza sırasında güvenli sınırlar içinde kalarak güç faktörünü dinamik olarak ayarlayabildiğini ve şebekeye gerilim desteği sağladığını göstermiştir.

(Chakraborty vd., 2023) çalışmasında, dengeli arızayı hızlı ve doğru şekilde tespit etmek için yeni bir arıza tespit algoritması önerilmiştir. Bu algoritma (Voltage Sag Detection Algorithm, VSDA), frekans kilitli döngü tabanlı ve ikinci dereceden genelleştirilmiş integratör ve kuadratör sinyal üretici temelli bir yapıya sahiptir. VSDA, arızayı algıladıktan sonra devreye giren bir ileri beslemeli geçici akım telafi (Feed-Forward Transient Current Compensation, FFTCC) yapısıyla birlikte çalışır. Bu kontrol yapısı, ileri düzey tip-2 bulanık mantık- PI denetleyici (Interval Type-2 FLC PI, IT2-FLC-PI) ile entegre edilmiştir. LVRT analizi için 0.8 saniye süren üç faz dengeli arıza uygulanmıştır. Sonuçlara göre, önerilen yöntem arıza tespit süresini 2.1 milisaniyeye düşürmüştür. Ayrıca, IT2-FLC-PI tabanlı FFTCC yapısının geçici yanıt analizinde geleneksel PI ve PIR denetleyicilere kıyasla üstün performans gösterdiği belirlenmiştir. DFIG sisteminde daha düşük kararlı durum hatası, daha kısa yerleşme süresi ve daha az aşma elde edilmiştir.

FLC, LVRT yeteneğinde sistem modeline ihtiyaç duymadan belirsizlikler altında hızlı ve sezgisel kontrol olanağı sunar. Ancak, bu yapılar çok sayıda kural tablosu ve üyelik fonksiyonu tanımlanmasını gerektirir. Bu durum, sistem karmaşıklığı arttıkça denetleyici tasarımını zorlaştırır ve büyük ölçekli uygulamalarda genelleme kapasitesini sınırlayabilir.

Yapay zeka yöntemlerinin gelişmiş hali olan makine öğrenmede, derin öğrenme (Deep Learning, DL) ve pekiştirmeli öğrenme (Reinforcement Learning, RL) yaklaşımları, son yıllarda güç sistemleri ve mikroşebeke alanında sıkça kullanılmaya başlamıştır. Tekrarlayan sinir ağları ve konvolüsyonel sinir ağları gibi DL yöntemleri özellikle enerji tahmini (Forootan vd., 2022; Han vd., 2021; Nabavi vd., 2021) ve hata tespiti (Alijoyo 2024; Ozcanli vd., 2020) konularında tercih edilmiştir. RL ise ajan tabanlı bir öğrenme yöntemidir ve ödül-ceza mekanizması ile karar alır. Q öğrenme ve derin Q ağı (Deep Q-Network, DQN) gibi RL yöntemleri robotik ve oyun alanlarında yaygın olmasına rağmen, enerji yönetimi (Mbuwir vd., 2017) ve planlama (Glavic vd., 2017) gibi konularda da kullanılmaktadır. Ancak RL algoritmaları, yüksek boyutlu durum uzayı ve sürekli aksiyon uzayına sahip gerçek dünya uygulamalarında sınırlı performans göstermektedir. Bu sorunu çözmek için,

DL ve RL'nin birleştirilmesiyle elde edilen DRL yaklaşımı öne çıkmıştır. Bu yöntem, yüksek boyutlu durum uzaylarında daha etkili karar verme performansı göstererek karmaşık problemleri çözmede önemli bir potansiyel sunmaktadır. Enerji sistemlerinin karmaşıklığı, belirsizliği ve güvenlik problemleri arttıkça, kontrolün model tabanlı yaklaşımlarla yapılması zorlaşmaktadır. Bu nedenle DRL'nin enerji sistemlerinde kullanımı artmaktadır (Perera ve Kamalaruban, 2021). DRL yaklaşımı değer tabanlı, politika tabanlı, aktör-kritik tabanlı ve model tabanlı yöntemler olarak ayrılır. Yenilenebilir enerji üretiminde karşılaşılan belirsizlikler ve hızlı gerilim değişimleri, gerilim kontrolünü karmaşık hale getirmektedir. Ayrıca dengesiz güç akışları ve doğru model eksiklikleri de kontrol sürecini zorlaştırmaktadır. Bu nedenle literatürdeki çoğu çalışma modelsiz DRL kullanımını önermektedir (Chen vd., 2021).

(Avila vd., 2020) çalışmasında, kısmi gölgelenme koşulları altında çalışan FV sistem için MPPT amacıyla Derin Deterministik Politika Gradyan (Deep Deterministic Policy Gradient, DDPG) algoritması önerilmiştir. Çalışma, geleneksel yöntemlerin kısmi gölgelenme durumlarında yaşadığı temel sorunu ele almaktadır: P-V karakteristik eğrilerindeki çoklu tepe noktaları nedeniyle küresel maksimum güç noktasının yakalanamama problemi. Simülasyon sonuçları DDPG algoritmasının üstün performansını göstermiştir. Birinci gölgelenme senaryosunda DDPG, 30.576 W güç değeriyle yalnızca %0.68 sapma gösterirken, İkiz Gecikmeli Derin Deterministik Politika Gradyan (Twin Delayed Deep Deterministic Policy Gradient, TD3) algoritması %3.7 sapma üretmiştir. İkinci senaryoda DDPG'nin sapma oranı %0.89 olurken TD3'ün ortalama sapması yaklaşık %2.6 olarak ölçülmüştür.

(Phan vd., 2020) çalışmasında kısmi gölgelenme problemi için DRL yöntemi önerilmiş ve geleneksel P&O yöntemi ile karşılaştırılmıştır. Standart test koşulları altında DQN yöntemi 0.07 saniyede MPP'yi izleyebilmiş ve güç takip verimliliğini P&O yöntemine kıyasla %5.83 oranında artırmıştır. DDPG algoritması ise %3.21 oranında iyileşme sağlamıştır. Değişen ışıınım koşullarında P&O'ya göre %1.24 (DQN) ve %0.96 (DDPG) iyileşme göstermiştir. Değişen sıcaklık koşullarında ise %2.74 (DQN) ve %2.55 (DDPG) verimlilik artışı elde edilmiştir. Hem ışıınım hem de sıcaklık değişimlerinde DDPG algoritması %1.62, DQN algoritması %1.58 oranında performans artışı sağlamıştır. Kısmi gölgelenme durumunda klasik yönteme kıyasla DDPG algoritması %44.6, DQN algoritması ise %38.3 oranında daha yüksek güç izleme verimliliği göstermiştir.

(Yin vd., 2023) çalışmasında, açık deniz rüzgar ve FV güç sistemi için DDPG algoritması önerilmiştir. Algoritmanın amacı, enerji üretim verimliliğini artırmak ve güç salınımlarını etkin şekilde sönümlemektir. Çalışmada DDPG, PI denetleyici ile karşılaştırılmıştır. Sonuçlar, DDPG tabanlı denetleyicinin rüzgar türbini rotor hızını etkin biçimde düzenleyerek sistemden maksimum aktif güç çektiğini göstermiştir. PI denetleyici ise aynı performansı sağlayamamıştır. Ayrıca DDPG algoritması, sistemdeki toplam güç salınımlarını belirgin şekilde azaltmıştır. Normalize edilmiş varyasyon hızı yaklaşık 50 bölüm içerisinde sifıra yakınsamıştır. Bu sonuçlar, önerilen kontrol algoritmasının güçlü bir sönümleme etkisi ve kararlı bir dinamik yanıt sağladığını göstermektedir.

Ancak bu yöntemlerin de bazı sınırlamaları vardır. DDPG algoritması, kritik ağ Q-değerini aşırı tahmin etme eğiliminde olduğu ve deterministik politika kullandığı için keşif yeteneği zayıf kalarak lokal çözümlere takılabilir. TD3 algoritması, DDPG'deki Q-değeri aşırı tahminini azaltmak amacıyla iki kritik ağın Q değerinin minimumunu kullanır ve sorunu kısmen çözer. Ancak bu kez Q-değerlerini olduğundan düşük tahmin etme eğilimi gösterebilir, bu durum ajan performansını sınırlandırabilir. TD3 de DDPG gibi deterministik politika kullandığı için sınırlı keşif kapasitesine sahiptir (Tiong vd., 2020).

(Haarnoja vd., 2018) tarafından geliştirilen Soft Aktör-Kritik (Soft Actor-Critic, SAC) algoritması, modelden bağımsız DRL algoritmalarının iki temel zorluğunu-yüksek örnek karmaşıklığı ve hiperparametre hassasiyeti-aşmak için tasarlanmıştır. SAC, beklenen toplam ödülün yanı sıra politika entropisini de maksimize etmeyi hedefler. Maksimum entropi formülasyonu sayesinde keşif sürecini geliştirir ve farklı başlangıç koşulları altında kararlı öğrenme sağlar. Otomatik gradyan tabanlı sıcaklık ayarı ise hiperparametre hassasiyetini büyük ölçüde ortadan kaldırır. Karşılaştırmalı deneylerde (Hopper-v2, Walker2d-v2, HalfCheetah-v2, Ant-v2, Humanoid-v2), SAC algoritması DDPG, Proksimal Politika Optimizasyonu (Proximal Policy Optimization, PPO) ve TD3 gibi yöntemlere kıyasla üstün performans göstermiştir. Özellikle DDPG'nin başarısız olduğu Ant-v1 ve Humanoid-v1 problemlerinde SAC başarılı öğrenme sağlamış, PPO'ya göre ise daha hızlı yakınsamıştır. Gerçek dünya uygulamalarında SAC daha da dikkat çekicidir. Minitaur adlı dört ayaklı robotun yürüme becerisini yalnızca 160 bin çevre etkileşimi (yaklaşık 2 saatlik eğitim) ile simülasyonsuz doğrudan öğrenmeyi başaran ilk DRL algoritması olmuştur. Bu sonuçlar, SAC'ın hem örnek verimliliği hem de öğrenme performansı açısından etkili ve uygulanabilir bir yöntem olduğunu göstermiştir.

(Xu vd., 2022) çalışmasında, hibrit enerji depolama sistemlerine (Hybrid Energy Storage System, HESS) sahip elektrikli araçlar için enerji yönetimini optimize etmek amacıyla SAC algoritması önerilmiştir. Geliştirilen enerji yönetim stratejisinin (Energy Management Strategy, EMS) temel hedefi, HESS sistemindeki enerji kayıplarını en aza indirerek genel verimliliği artırmaktır. Simülasyon sonuçlarına göre, SAC tabanlı EMS enerji kaybını DQN'ye kıyasla %8.75, DDPG'ye kıyasla ise %6.09 oranında azaltmıştır. Ayrıca yakınsama hızı DDPG'ye göre %205.66 daha hızlı gerçekleşmiştir. Uyarlanabilirlik testlerinde ise SAC yöntemi, DQN ve DDPG'ye kıyasla %32.24 oranında daha yüksek enerji tasarrufu sağlamıştır.

(Nwachukwu vd., 2025) çalışmasında, FV sistemlerde kısmi gölgelenme altında MPPT kontrolü için SAC algoritması önerilmiştir. Performans karşılaştırması için DDPG ve P&O yöntemleri kullanılmıştır. Simülasyon sonuçlarına göre SAC, DDPG'ye göre %58.47 daha hızlı yakınsamış ve aldığı ödül değeri 31.246 ile DDPG'yi %10.15 geçmiştir. Standart test koşulları altında SAC %99.996 (1004.67 W), DDPG %99.973 (1004.44 W) ve P&O %99.800 (1003 W) güç takibi gerçekleştirmiştir. Kısmi gölgelenme senaryosunda ise SAC %99.86, DDPG %98.17 ve P&O %58.41 verimlilik göstermiştir. Sonuçlar, SAC algoritmasının kısmi gölgelenme altındaki MPPT uygulamalarında yüksek takip verimliliği, güç salınımlarının ortadan kaldırılması ve eğitim kararlılığı açısından önemli avantajlar sağladığını göstermiştir.

(Liu vd., 2020) çalışmasında, aktif dağıtım şebekelerinde evirici tabanlı enerji kaynaklarında Volt/VAr kontrolü için iki aşamalı DRL yöntemi önerilmiştir. Yöntem, çevrim dışı ve çevrim içi olarak iki aşamadan oluşur. Çevrim dışı aşamada, düşmanca Markov karar süreci ve ortak düşmanca SAC (Jointly Adversarial Soft Actor-Critic, JASAC) algoritması kullanılır. Bu algoritma, sistemdeki model hatalarını bozucu etki olarak değerlendirerek ajanı model uyumsuzluklarına karşı daha dayanıklı hale getirir. Çevrim dışı eğitim sırasında yaklaşık model bilgileriyle ön eğitim yapılması, çevrim içi uygulamada güvenliği ve öğrenme verimliliğini önemli ölçüde artırır. IEEE 33-bara, 69-bara ve 123-bara test sistemleriyle yapılan deneyler, JASAC'ın hem çevrim dışı yakınsamada hem de çevrim içi performansta SAC ve ASAC gibi algoritmalara üstün olduğunu göstermiştir. 33-bara sisteminde JASAC, gerilim düşüş oranını %40, aktif güç kaybını ise ideal çözüme göre %70'in üzerinde azaltmıştır. Test süresi açısından DRL yöntemleri çok daha hızlıdır. Adım başına test süresi JASAC ve SAC için 0.9 milisaniye iken, VVO için 27 milisaniyedir.

DDPG algoritması, deterministik bir politika üretirken sürekli aksiyon uzaylarında düşük keşif kapasitesi ve yüksek varyans gibi dezavantajlara sahiptir. TD3 algoritması bu problemleri çözmek için çift Q-ağı ve gecikmeli politika güncellemeleri gibi iyileştirmeler sunsa da, deterministik politika yapısından kaynaklanan sınırlamalar taşır. SAC algoritması ise DDPG ve TD3'ten farklı olarak maksimum entropi yaklaşımını benimser. Bu yaklaşım, yalnızca beklenen ödülü değil, aynı zamanda politika entropisini de maksimize etmeyi hedefler. Böylece ajan daha fazla keşif yapar ve öğrenme kararlılığı artar. Bu nedenle bu tez kapsamında, gölge etkili FV sistemin şebeke entegrasyonunda enerji sürekliliği için DRL tabanlı yöntemler arasından SAC önerilmiştir.

1.3. Tezin Amacı

Bu tez çalışmasında, gölge etkili FV sistemin şebeke entegrasyonu için optimizasyon ve öğrenme tabanlı denetleyiciler kullanılarak sistemin LVRT yeteneğinin iyileştirilmesi amaçlanmıştır. Bu amaç doğrultusunda:


- İki aşamalı, üç fazlı şebeke bağlantılı FV sistemin Matlab/Simulink ortamında modellenmesi,
- Dengeli ve dengesiz arıza durumlarında enerji sürekliliğini sağlamak için DRL tabanlı denetleyicilerin geliştirilmesi ve hem kendi aralarında hem optimizasyon tabanlı PI denetleyici ile karşılaştırılması,
- Gölgeleme etkisi analizi için DRL tabanlı denetleyici geliştirilerek geleneksel yöntem olan P&O algoritması ile karşılaştırılması,
- FV sistemin değişen çevre koşulları ve şebeke parametrelerinde analizi,
- Opal-RT simülatörü ile sistemin gerçek zamanlı uygulaması ele alınmıştır.

1.4. Fotovoltaik Sistem

FV kaynaklar, düşük işletme maliyeti, güvenilir, temiz ve sıfır emisyon özellikleri sayesinde güneş enerjisinden elektrik üretiminde en gelecek vadeden yenilenebilir enerji kaynaklarından biridir. Güneş ışınımı, FV paneller aracılığıyla doğrudan elektrik enerjisine dönüştürülür. Bu panellerin ürettiği güç, güneş ışınımı ve sıcaklık gibi çevresel faktörlere bağlı değişir. Bu nedenle FV panellerin şebeke entegrasyonu, enerji depolama birimleriyle bağlantısı veya doğrudan yük besleme uygulamalarında güç elektroniği çeviricileri

gereklidir. Bu çeviriciler aynı zamanda maksimum güç noktası izleme, harmonik filtreleme ve koruma gibi kontrol işlevlerini de üstlenir.

Bir FV hücrenin tek diyot modeline ait eşdeğer devre şeması Şekil 1’de gösterilmiştir (Çavli, 2021).



Şekil 1. FV hücreye ait tek diyot modeli eşdeğer devresi

İlgili modele göre akım-gerilim (I-V) karakteristiği ile bu karakteristiği tanımlayan değişkenler ve sabitler eşitlik (1-5)’te verilmiştir. Bu eşitliklerde kullanılan semboller şunlardır: I_{pv} fotovoltaiik akım, I_s diyot ters doyum akımı, η diyot idealite faktörü, T p-n jonksiyon sıcaklığı, V_{pv} fotovoltaiik gerilim, V_d diyot gerilimi, V_t termal gerilim, I_{ph} foton akımı, R_p paralel direnç, I_d Shockley diyot akımı, R_s seri direnç, k boltzmann sabiti, q elektron yükü.

$$I_{pv} = I_{ph} - I_d - \frac{V_d}{R_p} \quad (1)$$

$$I_d = I_s \left[e^{\frac{V_d}{\eta V_t}} - 1 \right] \quad (2)$$

$$V_d = V_{pv} + I_{pv} R_s \quad (3)$$

$$V_t = \frac{kT}{q} \quad (4)$$

$$I_{pv} = I_{ph} - I_s \left[e^{\frac{V_{pv} + I_{pv} R_s}{\eta V_t}} - 1 \right] - \frac{V_{pv} + I_{pv} R_s}{R_p} \quad (5)$$

FV hücreden elde edilen gerilim ve akım değerleri oldukça düşüktür. Gerekli güç kapasitesine ulaşmak için FV hücreler, seri, paralel veya seri/paralel bağlanarak FV modüllerini oluşturur. Bu modüller de benzer konfigürasyonlarla birleştirilerek FV panelleri, paneller de benzer şekilde gruplanarak FV dizinleri meydana getirir.

Bir FV dizinin I-V ve P-V eğrileri çevresel faktörlere bağlı olarak değişir. Ortam sıcaklığındaki artış çıkış gerilimini düşürerek gücü azaltır, güneş ışınımındaki artış ise çıkış gücünü artırır. Ayrıca ağaç, bulut ve binalar nedeniyle FV panel ve dizinlerde kısmi gölgelenme durumu meydana gelir. Gölgelenen hücre veya panel bir yük gibi davranır ve diğer panellerden güç çeker. Bu durum güç kaybına ve sıcak nokta oluşumuna yol açar. Sonuç olarak, FV sistemlerden elde edilen verim önemli ölçüde azalır. Bu sorunu çözmek için günümüzde panellerin tasarımı yapılırken bypass diyotlar bağlanır. Gölgelenme durumunda bu diyotlar iletme geçer ve akım diyot üzerinden akar. Bu çözüm panellerin zarar görmesini önler, ancak verim hâlâ düşüktür. Çünkü bypass diyotlar P-V eğrisinde birden fazla güç noktası oluşturur. Bu güç noktalarından biri küresel maksimum, diğerleri yerel maksimum güç noktalarıdır. FV panellerden en verimli şekilde faydalanmak için küresel maksimum güç noktasının elde edilmesi gerekir.

Ancak FV sistemlerin çıkış gücündeki değişim, şebeke tarafında gerilim kalitesi sorunlarına yol açmaktadır. Bu sorunlar arasında gerilim dengesizliği, frekans dalgalanması ve harmonik bozulma yer almaktadır. Bu nedenle, FV sistemlerin şebeke entegrasyonuna yönelik ulusal ve uluslararası şebeke yönetmelikleri güç kalitesini iyileştirmeyi ve şebeke kararlılığını artırmayı amaçlamaktadır.

Şebeke yönetmelikleri başlangıçta senkron generatörlerin karakteristiklerine göre düzenlenmiştir. Ancak güç elektroniği tabanlı FV sistemlerin anlık üretim dalgalanmaları, geleneksel iletim sistemleri üzerinde farklı dinamik etkiler oluşturmaktadır. FV sistemlerin penetrasyon oranındaki artış, bu etkileri daha belirgin hale getirmiş ve iletim sistemi operatörlerini mevcut şebeke yönetmeliklerini güncellemeye yönlendirmiştir. Güncellenen bu yönetmelikler kapsamında, aktif güç kontrolü ve frekans kararlılığı, reaktif güç kontrolü ve gerilim regülasyonu, güç kalitesi gereksinimi ve arıza sonrası sisteme katkı öne çıkmaktadır.

Elektrik şebekelerinde frekans kararlılığı, üretilen aktif gücün yük talebiyle dengelenmesine bağlıdır. Üretim ve tüketim arasındaki dengesizlik, şebeke frekansında dalgalanmalara neden olarak güç kalitesini düşürür. Geleneksel enerji santrallerinde (termik santral gibi) bu dalgalanmalara karşı otomatik hız regülatörleri kullanılır. Ancak

yenilenebilir enerji sistemlerinde doğrudan hız regülatör kontrolü olmadığından frekans kararlılığı açısından yeni zorluklar ortaya çıkar.

Bu nedenle ulusal ve uluslararası şebeke yönetmelikleri, yenilenebilir enerji kaynaklarının frekans değişimine göre aktif güç üretimini düzenleyebilmesini zorunlu kılar. Örneğin Almanya şebeke yönetmeliği, frekans 50.2 Hz ile 51.5 Hz arasında olduğunda aktif güç çıkışının %40 oranında azaltılmasını gerektirir. Frekans 50.2 Hz'in altına düştüğünde güç çıkışı nominal seviyeye geri döndürülmelidir. Frekans 51.5 Hz'in üzerine çıkarsa veya 47.5 Hz'in altına düşerse kaynak şebekeden ayrılmalıdır.

Farklı ülkelerde yenilenebilir enerji kaynaklarının aktif gücü azaltmadan normal işletimde kalması gereken frekans değişim aralıkları Tablo 1'de verilmiştir (Al-Shetwi vd., 2020).

Tablo 1. Çeşitli ülkelerdeki standart çalışma frekans sınırları

Ülke	Frekans (Hz)	Frekans sınırları
Almanya	50	$47.5 < f < 51.5$
Danimarka	50	$48.5 < f < 51$
İspanya	50	$47.5 < f < 51.5$
Kanada	60	$59.4 < f < 60.6$
Çin	50	$49.5 < f < 50.2$
Güney Afrika	50	$49 < f < 51$
Malezya	50	$47 < f < 52$
İrlanda	50	$49.5 < f < 50.5$
Romanya	50	$47.5 < f < 52$

Geleneksel enerji sistemlerinde iletim seviyesindeki gerilim dalgalanmaları senkron generatör ile, dağıtım seviyesindeki gerilim dalgalanmaları ise dağıtım transformatörü ile düzeltilmektedir. Ancak yenilenebilir enerji kaynaklarının şebeke entegrasyonunda penetrasyon seviyesinin artması, gerilim kararlılığı üzerinde önemli etkilere yol açmaktadır. Bu nedenle, farklı işletme koşullarında gerilimi güvenli sınırlar içinde tutmak bir sorun haline gelmiştir. Bu soruna yönelik çözümlerden biri, şebeke bağlantı noktasında aktif güç akışı veya terminal gerilime bağlı güç faktörü düzenlemesi uygulanmasıdır. Almanya şebeke yönetmeliğine göre, alçak gerilim seviyesine bağlı bir FV veya rüzgar enerji santralinin $\pm$

0.95 güç faktörü aralığı dışında reaktif güç sağlaması gerekmektedir. Aynı gereklilikler İtalya, Çin ve Güney Afrika'da da uygulanmaktadır (Al-Shetwi, 2020).

Yenilenebilir enerji sistemlerinde yaygın olarak kullanılan güç elektroniği tabanlı dönüştürücüler, akım ve gerilim dalga şekillerinde bozulmalara neden olarak harmonik oluşturur. Bu nedenle, şebeke bağlantı noktasında harmonik bozunum seviyesinin belirli sınırlar içinde tutulması için düzenlemeler yapılmıştır. Güç kalitesi, gerilim ve akımın THD değeri kullanılarak ölçülür ve eşitlik (6)'daki gibi tanımlanır.

$$THD = \frac{\sqrt{\sum_{n=2}^k h_n^2}}{h_1} \quad (6)$$

burada h_1 temel bileşeni, h_n ise 2. dereceden k 'ya kadar olan harmonik etkin değerlerini temsil eder. k ve n sırasıyla son harmonik seriyi ve harmonik derecesini gösterir.

Gerilim ve akım dalga şeklinin şebeke ile senkronize olmasını sağlamak için uluslararası standartlar, hem gerilim hem de akım THD değerlerini sınırlandırmıştır. IEEE 519-2014, IEEE 1547 ve IEC standartları, şebeke bağlantı noktasında gerilim ve akım THD oranlarının %5'in altında olmasını zorunlu kılar. Ancak Romanya gibi bazı ülkeler, THD'nin maksimum %3 olmasını gerektiren daha katı düzenlemeler uygular. Çoğu ülke IEEE veya IEC standartlarını takip eder (Al-Shetwi vd., 2020).

Yenilenebilir enerji kaynaklarının şebeke entegrasyonu düşüken, şebeke yönetmelikleri arıza durumlarında bu kaynakların şebekeden ayrılmasını teşvik ediyordu. Ancak günümüzde özellikle rüzgar ve FV enerji kaynaklarının şebekeye entegrasyon oranı hızla artmaktadır. Arıza sırasında bu kaynakların şebekeden ayrılması, şebeke frekansı ve gerilim kararlılığını olumsuz etkilemektedir. Bu nedenle yeni şebeke yönetmelikleri FRT gerekliliği getirmiştir. Yenilenebilir enerji kaynaklarının arıza sırasında şebekeye bağlı kalması ve gerilim desteği sağlaması beklenmektedir. Bu destek, şebekeye enjekte edilen veya şebekeden absorbe edilen reaktif güç ile sağlanmaktadır. Reaktif güç miktarı ve süresi, ülkeye özgü şebeke yönetmeliklerine göre belirlenmektedir.

FRT gerekliliği üç gruba ayrılır: LVRT (düşük gerilimde şebekede kalabilme), ZVRT (sıfır gerilimde şebekede kalabilme) ve HVRT (yüksek gerilimde şebekede kalabilme). LVRT, gerilim seviyesi nominal değer %90'ının altına düştüğünde kaynağın belirli bir süre boyunca şebeke bağlantısını sürdürmesidir. ZVRT, gerilimin tamamen sıfıra düştüğü

durumda eviricinin şebeke bağlantısını sürdürmesini ifade ettiği için LVRT yeteneğinin özel bir hâli olarak da değerlendirilebilir. HVRT ise gerilim nominal değerine çıktığında kaynağın şebekeye bağlı kalabilmesidir. Güç sistemlerinde kısa devre kaynaklı gerilim düşmeleri en sık karşılaşılan arıza türüdür. Bu nedenle LVRT yeteneği, şebeke kararlılığının korunmasında kritik bir gereklilik olarak öne çıkmaktadır.

1.4.1. Düşük Gerilimde Şebekede Kalma Yeteneği

Yüksek penetrasyon oranına sahip yenilenebilir enerji kaynaklarının arıza sırasında şebekeden ayrılması, şebeke kararlılığını olumsuz etkilediğinden birçok ülke LVRT yeteneğini zorunlu kılmaktadır. LVRT yeteneği, gerilim seviyesi %90'ın altına düştüğünde belirli bir süre arızaya dayanarak çalışmaya devam etmesini sağlar. Arıza giderildikten sonra, kaynağın aktif ve reaktif güç üretimini hızla arıza öncesi seviyeye döndürmesi beklenmektedir.


Bazı ülkelerin LVRT standartları Tablo 2'de verilmiştir. Örneğin Danimarka şebeke yönetmeliğine göre, şebeke bağlantı noktasındaki gerilim %80 oranında düştüğünde rüzgar ve FV sistemler 0.5 saniye boyunca çalışmaya devam etmelidir. Arızadan sonra gerilim 1.5 saniye içinde nominal değer %90'ına yükselirse sistem çalışmaya devam eder; aksi takdirde kaynak şebekeden ayrılır. Diğer ülkelerde LVRT gereklilikleri benzer şekilde uygulanmakta olup yalnızca süre ve gerilim seviyesi açısından farklılık göstermektedir (Al-Shetwi vd., 2020).

Tablo 2. Farklı ülkelerdeki LVRT parametreleri

Ülke	Arıza sırası		Arıza sonrası	
	V_{min} (%)	t_{maks} (s)	V_{maks} (%)	t_{maks} (s)
Danimarka	20	0.5	90	1.5
Çin	20	0.625	90	2
Japonya	20	1	80	1.2
Romanya	15	0.625	90	3


Almanya'nın LVRT gerekliliğine ilişkin uyguladığı şebeke yönetmeliği literatürde yaygın olarak kabul görmektedir (Rai vd., 2022). Şekil 2, bu yönetmelikte tanımlanan LVRT

yeteneğini göstermektedir. Düzenlemeye göre, şebeke gerilimi 0 pu değerine düştüğünde kaynağın 150 milisaniye boyunca şebeke ile bağlantıda kalması gerekir.



Şekil 2. Almanya şebeke yönetmeliğine göre LVRT yeteneği

Şekil 3'te gösterildiği gibi arıza süresince reaktif akım enjeksiyonu ile gerilim desteği sağlanır. Gerilim kontrolü ± 0.1 pu ölü bant aralığına sahiptir. Kazanç (k) 0-10 pu arasında değer alabilir ve varsayılan değeri 2 pu'dur (Neuman vd., 2012). Uygulanan reaktif akımın adım tepkisi iki standardı karşılamalıdır: 30 milisaniyenin altında bir yükselme süresi (t_r) ve 60 milisaniyenin altında da bir oturma süresi (t_s). t_r , reaktif akımın ilk kez tolerans aralığına girmesi için gereken süreyi ifade eder. t_s ise reaktif akımın bu aralıkta kalması için gereken süreyi gösterir. Tolerans bant aralığı, referans değer -%10 ile +%20'si arasındadır. Bu gereklilik ve zamanlama kriterleri pozitif bileşen akımı için geçerlidir (Neuman vd., 2012).



Şekil 3. Gerilim değerine bağlı reaktif akım değeri

1.4.2. Düşük Gerilimde Şebekeye Bağlı Kalma Yöntemleri


Düşük gerilimde şebekeye bağlı kalma yöntemleri arasında Non-MPP kontrol, seri dinamik frenleme direnci ve DA kısıyıcı devresi yöntemleri bulunmaktadır.

Non-MPP kontrol yönteminin temel hedefi, arıza sırasında FV sistemin ürettiği aktif gücü tüketilen güce göre düzenleyerek şebekede aşırı gerilim ve akım oluşumunu önlemektir. Bu yöntemde sistem normal koşullarda MPP'de çalışır, ancak bir arıza tespit edildiğinde non-MPP moduna geçer (Lin vd., 2020). Non-MPP durumunda evirici, aktif gücü azaltır ve şebeke geriliminin toparlanmasını desteklemek için reaktif güç enjeksiyonunu artırır. Böylece şebeke daha hızlı toparlanır ve eviricinin aşırı akım veya gerilim limitleri nedeniyle devre dışı kalması önlenir (Radwan vd., 2019). Ancak bu yöntem, kısa süreli de olsa FV sistemin ürettiği gücü azalttığı için ekonomik kayıplara yol açabilir. Arızanın tespiti ve non-MPP moduna geçişin zamanlaması da kritik öneme sahiptir; çünkü geç veya hatalı geçişler hem evirici koruma mekanizmalarını tetikleyebilir hem de şebekede istenmeyen dinamik davranışlara neden olabilir.

FV sistemlerde LVRT yeteneğini desteklemek için kullanılan seri dinamik frenleme direnci (Series Dynamic Breaking Resistor, SDBR), bir yarı iletken anahtar ve ona paralel bağlı dirençten oluşur. Evirici tarafına seri bağlanan bu devre, arıza anında fazla enerjiyi ısı olarak dağıtır ve böylece eviricide aşırı gerilim ve aşırı akımı önler (Hong-jian, 2015). Basit bir yapıya sahip olan bu uygulama, bazı alternatif çözümlere kıyasla daha düşük maliyetlidir.

Ancak SDBR kullanımının bazı dezavantajları vardır. İlk olarak, ısıya dönüştürülen fazla enerji sistem verimliliğini düşürür. İkinci olarak, direnç değerinin sabit olması, farklı arıza türlerine veya sürelerine uyum sağlamada yetersiz kalabilir. Son olarak, bu yöntemin sık veya uzun süreli kullanımı, direnç bileşenlerinde termal stres oluşturur ve zamanla aşınmaya yol açar (Causebrook vd., 2007).

Arıza sırasında FV sistem ile şebeke arasındaki güç dengesizliği, DA bara geriliminde artışa neden olur ve eviricinin şebekeden ayrılmasına yol açar. Bu sorunun çözülmesi için yaygın yöntemlerden biri, DA kıyıcı devresidir. Devre, DA bara kapasitörlerine paralel bağlanan bir direnç ve yarı iletken anahtardan oluşur. Şekil 4'te gösterilen bu devre, arıza sırasında devreye girer ve FV dizin tarafından üretilen fazla gücü direnç üzerinde tüketir. Böylece aşırı gerilim önlenirken FV dizinin MPP'de çalışması da sağlanır. DA kıyıcı devresi, eviriciyi etkili şekilde koruması, hızlı tepki vermesi ve basit yapısı sayesinde LVRT uygulamalarında sıklıkla tercih edilmektedir. Genellikle optimum performans için hibrit veya gelişmiş koruma şemalarının bir parçası olarak kullanılmaktadır (Xu, 2024).



Şekil 4. DA kıyıcı devresinin eşdeğer devresi

1.5. FV Sistemin Düşük Gerilimde Şebekede Kalma Yeteneği

1.5.1. Simbiyotik Organizma Arama Algoritması

Simbiyotik organizma arama (Symbiotic Organism Search, SOS) algoritması, ekosistemdeki canlılar arasındaki simbiyotik ilişkilerden ilham alan bir meta-sezgisel optimizasyon yaklaşımıdır. Algoritma, bir organizmanın çevresindeki diğer türlerle olan etkileşimlerinden yola çıkarak en uygun organizmayı arar (Cheng ve Prayogo, 2014). Popülasyon temelli diğer optimizasyon yöntemlerine benzer şekilde SOS algoritması da

arama uzayındaki aday çözümleri iteratif olarak değerlendirir ve global optimuma ulaşmayı hedefler.

Algoritma, ekosistemde yaygın olarak gözlenen üç simbiyotik ilişki türü üzerine kuruludur: mutualizm, kommensalizm ve parazitizm. Her iterasyonda bir organizma, rastgele seçilen başka bir organizma ile simbiyotik bir ilişki kurar. Bu etkileşim sonucunda yeni çözümler üretilir ve elde edilen çözümler mevcut uygunluk değerleriyle karşılaştırılarak popülasyon güncellenir. Süreç, genellikle maksimum iterasyon sayısı olarak belirlenen durdurma kriteri sağlanana kadar devam eder.

Mutualizm aşamasında, iki farklı tür karşılıklı fayda sağlar. Bu aşamada, ekosistemde yer alan X_i organizması ile rastgele seçilen başka bir organizma X_j arasında etkileşim kurulur. Etkileşimin amacı, her iki organizmanın da ekosistemdeki varlığını sürdürme olasılığını karşılıklı olarak artırmaktır. X_i ve X_j organizmaları için oluşturulan yeni aday çözümler, aralarındaki mutualizm ilişkisiyi matematiksel olarak yansıtan eşitlik (7) ve eşitlik (8)'deki gibi hesaplanmaktadır.

$$X'_i = X_i + rand(0,1) * (X_{best} - MV * BF_1) \quad (7)$$

$$X'_j = X_j + rand(0,1) * (X_{best} - MV * BF_2) \quad (8)$$

Burada BF_1 ve BF_2 , rastgele 1 veya 2 olarak belirlenen fayda faktörlerini temsil eder. X_{best} ise ekosistemdeki en yüksek uygunluk değerine sahip organizmayı gösterir. Ortak vektörü (mutual vector, MV), X_i ve X_j organizmaları arasındaki ilişkiyi ifade eden bir vektördür ve eşitlik (9)'da tanımlanmıştır.

$$MV = \frac{X_i + X_j}{2} \quad (9)$$

Kommensalizm aşamasında, birlikte yaşayan iki türden biri diğerine zarar vermeden ondan yararlanır. Bu aşamada, X_i bu iki organizmanın beraberliğinden fayda görürken X_j etkilenmez. Eşitlik (10)'da verildiği gibi, yeni aday çözümler yalnızca X_i için hesaplanır.

$$X'_i = X_i + rand(-1,1) * (X_{best} - X_j) \quad (10)$$

Parazitizm aşamasında, bir tür diğerine zarar vererek yarar sağlar. Bu aşamada, X_i organizması yapay parazitin (parazit vektörü) oluşturulmasında kullanılır. X_j organizması ise parazit konağı olarak ekosistemden rastgele seçilir. Parazit vektör oluşturulurken X_i önce çoğaltılır, ardından arama uzayı sınırlarında rastgele değiştirilir. Parazit vektör, uygunluk değerlendirmesinde X_j 'den daha iyi bir çözüm sunuyorsa ekosistemde onun yerini alır. Aksi durumda, X_j bu parazite karşı bağışıklık kazanır ve parazit vektörün ekosistemdeki yerini kaybeder.

SOS algoritmasının üç aşamalı yapısı, onu diğer evrimsel hesaplama tekniklerinden ayırır. Mutualizm ve kommensalizm aşamaları keşfe odaklanır ve algoritmanın yeni potansiyel çözümler bulmasını sağlar. Bu keşif sayesinde algoritma, arama uzayında daha yüksek uygunluk değerlerine sahip bölgelere yoğunlaşır. Parazitizm aşaması ise mutasyon mekanizması aracılığıyla değişkenlik ekler ve algoritmanın yerel optimumda sıkışmasını önler (Han vd., 2019). SOS algoritmasının önemli bir diğer avantajı, algoritmaya özgü özel parametreler gerektirmemesidir. Bu özellik, yanlış parametre ayarlaması nedeniyle yerel optimuma takılma riskini azaltır ve hesaplama süresini kısaltır (Tran vd., 2016). Tüm bu avantajlar göz önünde bulundurulduğunda, SOS algoritması birçok mühendislik problemi için uygulanabilir ve verimli bir çözüm yöntemi olarak öne çıkmaktadır.

1.6. Pekiştirmeli Öğrenme

RL, canlıların biyolojik öğrenme süreçlerinden ilham alarak geliştirilmiş bir makine öğrenmesi yöntemidir. Bu yaklaşımda öğrenme, etiketlenmiş eğitim verisi olmadan gerçekleşir. Ajan çevreyle etkileşime girer, bulunduğu ortamdaki durumlara tepki verir ve karşılığında ödül alır. Amaç, bu ödülü maksimum edecek davranışı deneme-yanılma yoluyla öğrenmektir (Baysal, 2022).

RL'yi diğer makine öğrenme yöntemlerinden ayıran temel unsurlar vardır. Birincisi, uygulanan aksiyonların sistemin gelecek girişlerini etkilemesidir. Bu da yöntemi kapalı çevrim problemler için uygun hale getirir. İkincisi, ajanın hangi aksiyonu uygulayacağını ödüle göre keşfetmesi beklenir. Üçüncüsü ise gecikmeli ödüllerdir: bir aksiyon anlık ödüle katkı sağlamazken gelecekteki toplam ödülü artırabilir (Sutton ve Barto, 2018).


RL yönteminin danışmanlı öğrenme ve danışmansız öğrenmeden farklı yönleri bulunmaktadır. Danışmanlı öğrenmede etiketli veri kümesi kullanılır ve giriş-çıkış eşleşmeleri açıkça tanımlanır. Ağ, istenen çıkışları oluşturabilmek için bu girişlere göre

çıkışlarını günceller. Bu sayede daha önce karşılaşmadığı benzer durumlara genelleme yapabilir. Ancak çevreyle etkileşimli problemlerde, tüm olası durumlar ve uygun aksiyonları içeren etiketli veri kümesini oluşturmak pratik değildir. Bu nedenle danışmanlı öğrenme bu tür problemlerde yetersiz kalır (Sutton ve Barto, 2018).

Danışmansız öğrenmede, ağı yalnızca giriş verileri verilir. Sistemin bu veriler arasındaki yapısal benzerlikleri keşfetmesi ve benzer örnekleri gruplayarak kümeler oluşturması beklenir. RL’de ise ajana, seçtiği aksiyona doğru ya da yanlış olduğuna dair açık bir geri bildirim verilmeden yalnızca çevreden alınan ödül sinyali üzerinden beklenen toplam ödülü maksimize edecek bir politika öğrenmesi beklenir. Bu yönüyle RL, danışmansız öğrenmeden ayrılır (Baysal, 2022).

1.6.1. Pekiştirmeli Öğrenme Modelinin Bileşenleri

Ajan, çevreden gözlemlediği duruma bağlı bir aksiyon üretir. Çevrenin bu aksiyona verdiği tepki, önceden tanımlanmış bir ödül sistemiyle değerlendirilerek ajan eğitilir. RL, bu temel bileşenlere ek olarak opsiyonel bir çevre modeli bileşeni de içermektedir (Sutton ve Barto, 2018). Modelin genel yapısı Şekil 5’te gösterilmiştir.



Şekil 5. RL modeline ait genel yapı blok diyagramı

Politika (π), ajanın mevcut durumuna göre hangi aksiyonu seçeceğini belirleyen stratejidir. Eşitlik (11) ve (12)’de sırasıyla ifade edildiği gibi, stokastik politika fonksiyonu ajanın belirli bir s durumunda a aksiyonunu seçme olasılığını tanımlar. Deterministik politika fonksiyonu ise ajanın s durumunda doğrudan a aksiyonunu seçmesini ifade eder.

$$\pi(a / s) = P[a_t = a | s_t = s] \quad (11)$$

$$a = \pi(s) \quad (12)$$

Ödül (r), ajanın çevreyle etkileşimi sonucunda aldığı sayısal bir değerdir. Ajan, uyguladığı aksiyonu bu ödülle değerlendirir. Uzun vadede aldığı toplam ödülü artırmayı hedeflediği için çevreden aldığı bu ödüllere göre hangi stratejinin daha etkili olduğunu belirleyip politikayı buna göre değiştirebilir.

Değer fonksiyonu, bir ajanın mevcut durumundan başlayarak gelecekte elde etmesi beklenen ödüllerin toplamıdır. Eşitlik (13)'te verilen durum değer fonksiyonu (V), ajanın belirli bir durumdayken π politikasını izlediğinde elde etmeyi beklediği gelecek ödülü ifade eder.

$$\begin{aligned} V^\pi(s) &= E[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots | s_0 = s, \pi] \\ &= E_\pi \{R_t | s_t = s\} = E_\pi \left\{ \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} | s_t = s \right\} \end{aligned} \quad (13)$$

Bu eşitlikteki γ , $[0-1]$ aralığında değer alan azaltma faktörüdür. γ 'nın 0'a yakın olması ajanın yalnızca anlık ödülleri değerlendirmesine yol açarken, 1'e yakın olması ajanın uzun vadeli yüksek bir ödül almasını sağlayacaktır.

Eşitlik (14)'te ifade edilen aksiyon değer fonksiyonu (Q), ajan belirli bir durumdayken seçtiği a aksiyonu sonucunda beklenen gelecek ödülü tanımlar.

$$\begin{aligned} Q^\pi(s, a) &= E_\pi \{R_t | s_t = s, a_t = a\} = E_\pi \left\{ \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} | s_t = s, a_t = a \right\} \\ &= E_\pi \left\{ r_{t+1} + \gamma \sum_{k=0}^{\infty} \gamma^k r_{t+k+2} | s_t = s, a_t = a \right\} \end{aligned} \quad (14)$$

Model, bazı RL yöntemlerinde gelecekte oluşacak durumu ve alınacak ödülü tahmin etmek için kullanılan dördüncü bileşendir (Baysal, 2022).

1.6.2. Markov Karar Süreci

Markov özelliği, gelecekteki durumların yalnızca şu anki duruma bağlı olması, yani geçmişe dair ek bilgiye ihtiyaç olmamasıdır. Çevrenin Markov özelliği taşıması için çevredeki tüm durumların bu özelliği sağlaması gerekir. Böyle bir çevrede tanımlanan RL

problemi, Markov karar süreci (Markov Decision Process, MDP) olarak ifade edilir. Matematiksel olarak, eşitlik (15)'te bir sonraki durumun geçiş olasılığının yalnızca şu anki durum ve eyleme bağlı olduğu gösterilmiştir (Baysal, 2022).

$$p(s' | s, a) = P[s_{t+1} = s' | s_t = s, a_t = a] \quad (15)$$

Eşitlik (16) ise ajanın mevcut durumu s , seçilen aksiyon a ve gelecek durum s' iken elde edilmesi beklenen gelecek ödülün ifadesini göstermektedir.

$$r(s, a, s') = E[r_{t+1} | s_t = s, a_t = a, s_{t+1} = s'] \quad (16)$$

Markov özelliği, RL'de büyük öneme sahiptir. Ajanın bir aksiyonu seçip öğrenmesi yalnızca şu andaki durum bilgisine bağlıdır. Mevcut durum geçmişteki tüm bilgileri kapsadığından, geçmişe dair verilerin ayrıca tutulmasına gerek yoktur. Bu sayede sistemin gelecekteki davranışı yalnızca mevcut durum üzerinden tahmin edilebilir (Baysal, 2022).

1.6.3. Optimal Politika

Optimal politika (π^*), ajanın her durumda hangi aksiyonu seçmesinin uzun vadede toplam ödülü maksimum yapacağını belirleyen politikaadır. Politikanın değerlendirilmesi değer fonksiyonları ile yapılır. Optimal politikayı tanımlamak için Bellman eşitlikleri kullanılır. Optimal durum değer fonksiyonu $V^*(s)$, bir s durumunda en yüksek toplam ödül beklentisini ifade eder ve eşitlik (17)'deki gibi tanımlanır.

$$V^*(s) = \max_{a \in A(s)} \sum_{s' \in S} p(s' | s, a) [r(s, a, s') + \gamma V^*(s')] \quad (17)$$

Benzer biçimde, optimal aksiyon değer fonksiyonu $Q^*(s)$ eşitlik (18)'deki gibi tanımlanır ve bu eşitlik ise belirli bir durumda belirli bir aksiyon seçildiğinde elde edilecek toplam ödül beklentisini ve gelecekteki en iyi aksiyonların katkısını içerir.

$$Q^*(s, a) = \sum_{s' \in S} p(s' | s, a) [r(s, a, s') + \gamma \max_{a' \in A(s')} Q^*(s', a')] \quad (18)$$

Elde edilen bu Bellman eşitliklerinde optimal politika, $V^*(s)$ ve $Q^*(s, a)$ cinsinden eşitlik (19) ve (20)'deki gibi ifade edilir.

$$\pi^*(s) = \arg \max_{a \in A(s)} \sum_{s' \in S} p(s' | s, a) [r(s, a, s') + \gamma V^*(s')] \quad (19)$$

$$\pi^*(s) = \arg \max_{a \in A(s)} \sum_{s' \in S} p(s' | s, a) [r(s, a, s') + \gamma \max_{a' \in A(s')} Q^*(s', a')] \quad (20)$$

1.6.4. Pekiştirmeli Öğrenme Algoritmaları

Model tabanlı öğrenme algoritmaları, çevreyi keşfederek $p(s'|s, a)$ ve $r(s, a, s')$ fonksiyonlarını tahmin eder ve optimal politikayı bulur. Bu tahmin sürecinde, her durum-aksiyon çiftinin keşfedilmesi gerektiğinden bu algoritmaların yüksek durum-aksiyon uzayına sahip problemlerdeki uygulanabilirliği sınırlıdır. Model tabanlı öğrenme algoritmaları arasında değer iterasyon ve politika iterasyon algoritmaları yer alır (Baysal, 2022).

Modelsiz öğrenme algoritmaları, ajan ile çevre arasındaki etkileşimden elde edilen deneyimlere dayanarak optimal politikayı öğrenmeyi amaçlar. Bu algoritmalar, çevre hakkında önceden bilgi sahibi olmayı gerektirmez. İki gruba ayrılabilir: değer tabanlı ve politika tabanlı algoritmalar.

Değer tabanlı algoritmalarda ajan, durum değer fonksiyonunu tahmin ederek politikayı öğrenmeye çalışır. Politika tabanlı algoritmalarda ise gelecekte maksimum ödül elde edebileceği aksiyonları veren politikayı öğrenmeye çalışır. Değer tabanlı algoritmalar arasında zamansal fark (Temporal Difference, TD) öğrenimi (Sutton, 1988), Q öğrenme (Watkins, 1989) ve SARSA (State Action Reward State Action) (Rummery ve Niranjan, 1994) algoritmaları bulunur. Politika tabanlı algoritmalar arasında ise politika gradyanı (Policy Gradient, PG) (Williams, 1992), güven bölgesi politika optimizasyonu (Trust Region Policy Optimization, TRPO) (Schulman vd., 2015) ve PPO (Schulman vd., 2017) algoritmaları yer alır. Ayrıca bu iki yaklaşımın avantajlarını birleştiren aktör-kritik (Actor-Critic, AC) yöntemleri de yaygın olarak kullanılmaktadır.

Aktif politikalı öğrenmede, ajan mevcut politikadan türettiği aksiyona göre öğrenir ve politika güncellemesinde kendi topladığı verileri kullanır. Pasif politikalı öğrenmede ise tampon bellek kullanılarak politika güncellemesi bu bellekten örneklenen veriler ile yapılır.

Bu yaklaşım, önceki politikalar aracılığıyla elde edilen geçmiş örneklerin değerlendirilmesine olanak tanır.

1.7. Derin Öğrenme

DL, giriş verisinden ayırt edici özellikleri çok katmanlı yapay sinir ağları aracılığıyla kendiliğinden öğrenebilen bir makine öğrenmesi yaklaşımıdır. Geleneksel makine öğrenmesi yöntemlerinde bu özellikler genellikle bir uzman tarafından önceden belirlenir ve modele sunulur. DL ise bu süreci doğrudan veri üzerinden gerçekleştirir. İnsan müdahalesine olan bağıllığın ortadan kalkması, özellikle karmaşık ve yüksek boyutlu veri setlerinde DL yaklaşımlarının başarısını belirgin şekilde artırmaktadır. Bu özellik öğrenme sürecinin başarılı olması, sistemin yeterince eğitilmesine bağlıdır.

Derin sinir ağı (Deep Neural Network, DNN), ileri beslemeli çok katmanlı algılayıcı mimarisine dayanır. Bu ağda, giriş verisi birinci gizli katmana iletilir ve her katmanda ağırlık matrisleri (W) ve bias vektörleri (b) aracılığıyla doğrusal olmayan bir dönüşümden geçirilir. Bu dönüşüm genellikle doğrultulmuş lineer birim (Rectified Linear Unit, ReLU), sigmoid ve tanh gibi aktivasyon fonksiyonlarıyla gerçekleştirilir. Matematiksel ifadesi eşitlik (21)'de verilen sigmoid fonksiyonu, $[0-1]$ aralığında değer üretir. Bu fonksiyonun sıfıra yakın kısmında küçük bir değişim çıkışta büyük bir değişime neden olduğu için sınıflayıcı olarak yaygın kullanılır. Ancak sigmoid fonksiyonunda uçlara doğru türev değerleri çok küçüktür ve sıfıra yakınsadığı için gradyanların ölmesi problemine yol açar. Bu durum, öğrenme sürecini yavaşlatarak lokal minimuma takılmasına neden olabilir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (21)$$

Tanh fonksiyonu, sigmoid fonksiyonuna yapısal olarak benzer ancak $[-1,1]$ aralığında çıkış üretir. Bu daha geniş aralık sayesinde sınıflandırma uygulamalarında öne çıkar. Türevi daha büyük değerler için öğrenme işlemini hızlandırır. Ancak sigmoid fonksiyonunda olduğu gibi gradyan ölmesi problemi taşır. Fonksiyonun matematiksel ifadesi eşitlik (22)'de verilmiştir.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (22)$$

DNN mimarilerinde yaygın olarak tercih edilen ReLU fonksiyonu, $[0, \infty)$ aralığında çıkış üretir. Giriş değeri negatif olduğunda sıfır, pozitif olduğunda ise girişin kendisi kadar çıktı verir. Bu özellik, öğrenme sürecini hızlandırır. Ancak negatif giriş değerlerinde türevin sıfır olması, öğrenmenin gerçekleşmemesine neden olur. Genellikle ara katmanlarda kullanılan ReLU fonksiyonunun matematiksel ifadesi eşitlik (23)'te verilmiştir.

$$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (23)$$

Ağın eğitim süreci, hedef çıktı ile elde edilen çıktı arasındaki hatayı minimize etmeyi amaçlayan geriye yayılım algoritmasına dayanır. Bu süreçte, hata fonksiyonunun ağ parametrelerine (θ) göre gradyanı hesaplanır. Parametreler, eşitlik (24)'te verildiği gibi gradyan azaltma (Gradient Descent, GD) yöntemine göre güncellenir. Bu tez çalışmasında, GD tabanlı çeşitli optimizasyon algoritmaları arasında momentum (Qian, 1999) ve ortalama karesel yayılımın karekökü (Hinton vd., 2012) yöntemlerinin birleştirilmesi ile elde edilen adaptif moment tahmini (Adaptive Moment Estimation, Adam) (Kingma ve Ba, 2014) algoritması kullanılmıştır.

$$\theta^{t+1} = \theta^t - \alpha_n \frac{\partial E(X, \theta^t)}{\partial \theta} \quad (24)$$

1.8. Derin Pekiştirmeli Öğrenme

RL yönteminde ajan, politikayı öğrenmek için tablo gibi basit modeller kullanır. DRL yönteminde ise derin sinir ağları kullanılır. Tablo kullanımı, RL'yi düşük boyutlu durum uzaylarıyla sınırlar ve uygulama alanını daraltır. DRL'de derin sinir ağları fonksiyon yaklaşımı olarak kullanılır ve yüksek boyutlu problemlerin çözülmesine olanak tanır. Bu sayede DRL, robotik, doğal dil işleme, otonom sürüş, oyun gibi pek çok alanda kullanılmaktadır.

1.8.1. Derin Q Ağı

DQN, DNN'nin Q öğrenme yöntemiyle birleştirilmesiyle elde edilmiştir. Q öğrenme yönteminde ajan, çevreden edindiği deneyimlere dayanarak her durum-aksiyon çifti için bir Q değeri hesaplar ve bu değerlerle bir tablo oluşturulur. Ancak bu yaklaşım, yüksek boyutlu durum uzaylarında ölçeklenemez. DQN bu sınırlamayı aşmak için derin bir sinir ağı kullanır. Bu ağ, çevreden edinilen bilgilere göre olası aksiyonlara karşılık gelen Q değerlerini çıktı olarak üretir. Ağ parametreleri ödül değerine göre sürekli güncellenir ve ajan, maksimum Q değerine sahip aksiyonu seçer.

RL'de değişken veri dağılımı ve veriler arasındaki korelasyon, öğrenme sürecinde kararsızlığa neden olur. DQN bu sorunu deneyim tekrarı yöntemiyle (Lin, 1993) çözer. Bu yaklaşımda, geçmişte edinilen deneyimler rastgele örneklendirilerek veri dağılımındaki değişkenlik dengelenir.

Algoritmada öğrenme sağlamak için sinir ağı parametrelerinin optimize edilmesi gerekir. Eşitlik (25)'te bu amaçla kullanılan kayıp fonksiyonu (L), Bellman eşitliğinden türetilen Q değerini güncellemeye dayanır. GD algoritmasına dayanan geriye yayılım algoritması, hedef değer ve gerçek değer arasındaki farka dayanan bu fonksiyonu optimize eder.

$$L_i(\theta_i) = (r + \gamma \max_{a'} Q(s', a'; \theta_i^-) - Q(s, a; \theta_i))^2 \quad (25)$$

Bu eşitlikte θ_i ve θ_i^- parametreleri sırasıyla Q ağının i . iterasyondaki parametrelerini ve aynı iterasyonda hedefi hesaplamak için kullanılan hedef ağın parametrelerini temsil eder.

1.8.2. Derin Deterministik Politika Gradyanı

DQN algoritması ayrık ve düşük boyutlu aksiyon uzayında kullanılabilir, ancak sürekli aksiyon uzayına sahip kontrol uygulamalarında yetersiz kalmaktadır. Bu sorunu çözmek için Lilicrap vd. (2016), sürekli ve yüksek boyutlu aksiyon uzaylarında politikaları öğrenebilen DDPG algoritmasını geliştirmiştir. DDPG, modelsiz ve pasif politikalı bir AC yöntemidir.

Bu algoritmada aktör fonksiyonu $\mu(s|\theta^\mu)$, belirli bir durumda alınması gereken aksiyonu öğrenir. Kritik fonksiyonu $Q(s,a)$ ise aktör tarafından belirlenen politikayı

değerlendirir. Optimal politikayı bulmak için aktör politikası, deterministik politika gradyan yöntemi ile eşitlik (26)'daki gibi güncellenir.

$$\begin{aligned}\nabla_{\theta^\mu} J &\approx E_{s_t: \rho^\beta} [\nabla_{\theta^\mu} Q(s, a | \theta^Q) |_{s=s_t, a=\mu(s_t | \theta^\mu)}] \\ &= E_{s_t: \rho^\beta} [\nabla_a Q(s, a | \theta^Q) |_{s=s_t, a=\mu(s_t)} \nabla_{\theta^\mu} \mu(s | \theta^\mu) |_{s=s_t}] \end{aligned} \quad (26)$$

Burada, θ^μ gerçek aktör ağ parametrelerini, θ^Q gerçek kritik ağ parametrelerini, ρ^β durum ziyaret dağılımını temsil eder.

Kritik fonksiyonunda ise Q öğrenmedeki gibi Bellman eşitlikleri kullanılarak L fonksiyonu eşitlik (27)'de verildiği gibi minimize edilerek güncellenir.

$$\begin{aligned}L &= (y_t - Q(s_t, a_t | \theta^Q))^2 \\ y_t &= r(s_t, a_t) + \gamma Q(s_{t+1}, \mu'(s_{t+1} | \theta^\mu) | \theta^Q) \end{aligned} \quad (27)$$

Bu eşitlikte kullanılan $\mu'(s | \theta^{\mu'})$ ve $Q'(s, a | \theta^{Q'})$ ifadeleri, sırasıyla aktör ve kritik için tanımlanan hedef ağlarıdır. Hedef ağlar, DQN algoritmasında olduğu gibi öğrenme sürecinde meydana gelebilecek kararsızlıkları azaltmak amacıyla kullanılır. Ancak burada hedef ağ parametrelerinin güncellenmesi, doğrudan kopyalama yerine eşitlik (28)'de verilen yumuşak güncelleme ile yapılır. Bu eşitlikte τ , yumuşak hedef güncelleme katsayısı olup $\tau \ll 1$ 'dir. Hedef değerlerin yavaş değişmesi öğrenme sürecini biraz yavaşlatsa da, bu yumuşak güncelleme öğrenme kararlılığını artırmaktadır (Lilicrap vd., 2016).

$$\begin{aligned}\theta^{Q'} &\leftarrow \tau \theta^Q + (1 - \tau) \theta^{Q'} \\ \theta^{\mu'} &\leftarrow \tau \theta^\mu + (1 - \tau) \theta^{\mu'} \end{aligned} \quad (28)$$

Ajanın çevreyle etkileşimi sonucunda elde edilen değişken grubu (s_t, a_t, r_t, s_{t+1}) sonlu boyuttaki bir bellekte depolanır. Bellek dolduğunda, en eski örnekler silinir ve yeni örnekler yer açılır. Öğrenme sırasında bu bellekten rastgele örneklenen küçük bir veri kümesi (mini-batch) kullanılarak aktör ve kritik güncellemeleri gerçekleştirilir. DQN'de olduğu gibi bu tekrarlama belleğinin kullanılması, değişken veri dağılımı ve veriler arasındaki korelasyon problemini çözmeye yarar.

Sürekli aksiyon uzayına sahip öğrenme sürecinde keşif, temel zorluklardan biridir. DDPG algoritması bu sorunu, eşitlik (29)'da verildiği gibi aktör politikasına gürültü

ekleyerek (N) çözmeyi amaçlar. Bu algoritmada Ornstein-Uhlenbeck (OU) aksiyon gürültüsü aktör politikasına eklenir. Bu gürültü modeli, sürtünme etkisine maruz kalan büyük bir parçacığın Brown hareketi altındaki hızını tanımlamak amacıyla önerilmiştir (Uhlenbeck ve Ornstein, 1930). OU süreci matematiksel olarak eşitlik (30)'da verilmiştir.

$$\mu'(s_t) = \mu(s_t | \theta_t^\mu) + N \quad (29)$$

$$dx_t = \theta(\mu - x_t)dt + \sigma dW_t \quad (30)$$

Burada x_t gürültü sinyalini, μ gürültü modelinin ortalamasını, θ gürültü model çıkışının ortalamaya ne kadar hızlı döneceğini belirleyen bir sabiti, σ ise gürültü modelinin standart sapmasını temsil eder. Standart sapma, her adımda belirlenen azalma oranına göre eşitlik (31)'deki gibi güncellenir.

$$\begin{aligned} \sigma_d &= \sigma(k) * (1 - \alpha_\sigma) \\ \sigma(k+1) &= \max(\sigma_d, \sigma_{\min}) \end{aligned} \quad (31)$$

Sürekli aksiyon uzayında ajanın etkili bir şekilde keşif yapabilmesi için gürültünün standart sapması oldukça önemlidir. Bu amaçla, eşitlik (32)'de tanımlanan ifadenin problemin aksiyon uzay aralığının (A_r) %1 ile %10'u arasında belirlenmesi önerilir.

$$0.01 * A_r \leq \sigma \sqrt{T_s} \leq 0.1 * A_r \quad (32)$$

Bu gürültü doğrudan aksiyon uzayına eklenebileceği gibi parametre uzayına da eklenebilir. Ancak parametre uzayına eklenen gürültünün daha tutarlı keşif davranışları sağladığı belirtilmektedir (Plappert vd., 2017).

1.8.3. İkiz Gecikmeli Derin Deterministik Politika Gradyanı

TD3, DDPG algoritmasının değer tabanlı diğer RL yöntemlerindeki gibi fonksiyon yaklaşım hatalarından kaynaklanan dezavantajlarını gidermek için geliştirilmiş modelsiz, pasif politikalı bir algoritmadır (Fujimoto vd., 2018). Bu hatalardan kaynaklanan aşırı

tahmin yanlılığı ve yüksek varyans problemlerini çözebilmek için TD3 algoritmasına üç ana özellik eklenmiştir.

Q değer fonksiyonunun tahmini sırasında ortaya çıkan aşırı tahmin yanlılığı, bir sonraki politika güncellemesinde optimal olmayan aksiyonları seçerek politika güncellemelerinin etkinliğini azaltır ve ajanın yerel optimum çözüme sıkışmasına neden olur. TD3 algoritması bu problemi çözmek için kırılmış çift Q-öğrenme yaklaşımını benimser. Bu yöntemde iki ayrı Q değer fonksiyonu kullanılır: bir fonksiyonun seçtiği aksiyon, diğer fonksiyonun değer tahmini üzerinden tarafsız olarak değerlendirilir. Çift Q-öğrenme yönteminin matematiksel ifadesi eşitlik (33)'te verilmiştir.

$$\begin{aligned} y_1 &= r + \gamma Q_{\theta_2}(s', \pi_{\phi_1}(s')) \\ y_2 &= r + \gamma Q_{\theta_1}(s', \pi_{\phi_2}(s')) \end{aligned} \quad (33)$$

Bu eşitlikte görüldüğü gibi, kritik ağların hedef güncellemesinde diğer hedef kritik ağın kullanılması bağımsız bir tahmin yapılmasını sağlar. Ancak güncelleme sürecinde aynı deneyim belleği ve diğer hedef kritik ağın kullanılması bu bağımsızlığı kısmen ortadan kaldırmaktadır. Bu sorunu çözmek için eşitlik (34)'te verildiği gibi, hedef güncellemesi yapılırken iki kritik ağın Q değerlerinden küçük olanı kullanılmaktadır.

$$y = r + \gamma \min_{i=1,2} Q_{\theta_i}(s', a) \quad (34)$$

Fonksiyon yaklaşım hatasının sonucu olarak ortaya çıkan yüksek varyans problemi, politika güncellemeleri için gürültülü bir gradyan oluşturarak öğrenme hızını yavaşlatır. Bu problemi çözmek için gecikmeli politika güncellemesi yaklaşımı önerilmiştir. Bu yaklaşımda politika ağı, kritik ağdan daha az sıklıkla güncellenir. Böylece politika güncellemesinden önce kritik ağın değer tahmin hatası azaltılmaya çalışılır. Bu durum, düşük varyanslı değer tahminleri sağlayarak daha iyi politikalar geliştirilmesini ve etkili bir eğitim sürecini mümkün kılar.

Hedef ağların güncellenmesi, TD hatasını düşük tutmak için eşitlik (35)'te verildiği gibi yumuşak bir şekilde yapılır.

$$\theta' \leftarrow \tau\theta + (1-\tau)\theta' \quad (35)$$

Diğer bir çözüm yöntemi olan hedef politika yumuşatmasında, hedef değer güncellemesi eşitlik (36)'da gösterildiği gibi yapılır. Hedef aksiyona küçük bir rastgele gürültü eklenir (ε) ve mini paketler üzerinden ortalama alınır. Eklenen gürültü kırpılarak hedef, orijinal aksiyona yakın tutulur. Gürültünün seçimi keşif politikasından bağımsızdır.

$$\begin{aligned} y &= r + \gamma Q_{\theta'}(s', \pi_{\phi'}(s')) + \varepsilon \\ \varepsilon &: \text{clip}(N(0, \sigma), -c, c) \end{aligned} \quad (36)$$

Bu eşitlikte, $[-c, c]$ aralığında kırpılan $N(0, \sigma)$ Gauss gürültüsü hedef aksiyona eklenir. Gauss aksiyon modeli, normal (gauss) dağılıma eşit gürültü üretir. Eşitlik (37)'de belirtildiği gibi, Gauss aksiyon gürültüsü her k adımında örneklenir.

$$\begin{aligned} w &= \mu + \text{rand}(a_n) \cdot \sigma(k) \\ x(k+1) &= \min(\text{maks}(w, -c), c) \end{aligned} \quad (37)$$

Burada a_n aksiyon boyutunu, $-c$ ve c ise gürültü örneğinin sınır değerlerini temsil eder. Standart sapma, OU aksiyon gürültüsünde olduğu gibi her k adımda azalma oranına göre eşitlik (31)'deki gibi güncellenir.

1.8.4. Soft Aktör-Kritik Algoritması

SAC, DDPG ve TD3 algoritmaları gibi modelsiz ve pasif politikalı bir AC yöntemidir. Bu algoritma, durum-aksiyon uzaylarının hem ayrık hem de sürekli olduğu problemlere uygulanabilir. SAC algoritması, yalnızca beklenen ödül maksimum yapmayı amaçlayan diğer DRL yöntemlerinden farklı olarak, keşfi artırmak amacıyla maksimum entropi yaklaşımını benimser. Eşitlik (38)'de verilen amaç fonksiyonuna entropi terimi eklenmiştir. Bu yaklaşımla ajan, hem beklenen ödül hem de politika dağılımının entropisini maksimize ederek öğrenme kararlılığını artırır (Haarnoja vd., 2018).

$$J(\pi) = \sum_{t=0}^T E_{(s_t, a_t) \sim \rho_\pi} [r(s_t, a_t) + \alpha H(\pi(\cdot | s_t))] \quad (38)$$

Burada, $H(\pi(\cdot | s_t))$ politikaya ait entropi ölçüsüdür ve matematiksel ifadesi eşitlik (39)'da verilmiştir. α , entropi terimi ile beklenen ödül arasındaki dengeyi sağlayan sıcaklık parametresidir ve optimal politikanın stokastikliğini kontrol eder. Bu parametrenin artırılması politikayı daha rastgele, azaltılması ise daha az rastgele hale getirir (Türkmen, 2022).

$$H(\pi(\cdot | s_t)) = E_{a \sim \pi(\cdot | s_t)} [-\log \pi(a_t | s_t)] \quad (39)$$

Bu algoritmada, maksimum entropi yaklaşımı için V ve Q fonksiyonlarında değişiklikler yapılmıştır. (Haarnoja vd., 2018) çalışmasında, yazarlar ilk olarak politika iterasyonu (policy iteration) yönteminin maksimum entropi varyantını türetmiş olup algoritmanın yakınsadığını göstermiştir. Eşitlik (40)'ta türetilen soft Q ve soft V fonksiyonları verilmiştir (Haarnoja vd., 2018).

$$\begin{aligned} Q(s_t, a_t) &= r(s_t, a_t) + \gamma E_{s_{t+1} \sim \rho} [V(s_{t+1})] \\ V(s_t) &= E_{a_t \sim \pi} [Q(s_t, a_t) - \log \pi(a_t | s_t)] \end{aligned} \quad (40)$$

Politika güncelleme süreci, Q değerlerinin yüksek olduğu aksiyonlara daha yüksek olasılık atayan bir politika dağılımını öğrenir. Ancak Q fonksiyonu bir olasılık dağılımı olmadığı için, Q fonksiyonunun üssü alınır ve softmax fonksiyonuna benzer şekilde bir normalizasyon faktörü Z ile bölünür. Ayrıca politika, genellikle Gauss gibi olasılık dağılımı ile sınırlandırılır. Bu hedeflere ulaşmak amacıyla Kullback-Leibler ayrıklığı (KL-ayrıklığı) eşitlik (41)'deki gibi kullanılır (Türkmen, 2022).

$$\pi_{\text{yeni}} = \arg \min_{\pi \in \Pi} D_{KL} \left(\pi(\cdot | s_t) \parallel \frac{\exp(Q^{\pi_{\text{eski}}}(s_t, \cdot))}{Z^{\pi_{\text{eski}}}(s_t)} \right) \quad (41)$$

SAC algoritması, DDPG ve TD3 algoritmalarında olduğu gibi fonksiyon yaklaşımları kullanır. Eşitlik (40) ve (41)'de verilen denklemler için kullanılacak notasyonlar sırasıyla

θ, φ ve $\emptyset$ olarak belirlenmiştir. Soft V fonksiyonu ve soft Q fonksiyonunun ağ parametrelerini optimize etmek için kullanılan kayıp fonksiyonları eşitlik (42)'de verilmiştir.

$$\begin{aligned} J_Q(\theta) &= E_{(s_t, a_t): D} \left[\frac{1}{2} (Q_\theta(s_t, a_t) - Q_{\bar{\theta}}(s_t, a_t))^2 \right] \\ J_V(\varphi) &= E_{s_t: D} \left[\frac{1}{2} (V_\varphi(s_t) - E_{a_t: \pi_\phi} [Q_\theta(s_t, a_t) - \log \pi_\phi(a_t | s_t)])^2 \right] \end{aligned} \quad (42)$$

Bu kayıp fonksiyonları da eşitlik (43)'te ifade edilen stokastik gradyan kullanılarak optimize edilir.

$$\begin{aligned} \nabla_\theta J_Q(\theta) &= \nabla_\theta Q_\theta(s_t, a_t) (Q_\theta(s_t, a_t) - r(s_t, a_t) - \gamma V_\varphi(s_{t+1})) \\ \nabla_\varphi J_V(\varphi) &= \nabla_\varphi V_\varphi(s_t) (V_\varphi(s_t) - Q_\theta(s_t, a_t) + \log \pi_\phi(a_t | s_t)) \end{aligned} \quad (43)$$

Ayrıca, politika parametreleri eşitlik (41)'de verilen KL-ayrıklığını minimize ederek eşitlik (44)'te verildiği gibi öğrenilir.

$$J_\pi(\phi) = E_{s_t: D} \left[D_{KL} \left(\pi_\phi(\cdot | s_t) \parallel \frac{\exp(Q_\theta(s_t, \cdot))}{Z_\theta(s_t)} \right) \right] \quad (44)$$


Bu kayıp fonksiyonu, eşitlik (45)'te verilen daha düşük varyans tahmini sağlayan yeniden parametrizasyon tekniği (reparameterization trick) kullanılarak yeniden yazılabilir.

$$a_t = f_\phi(\epsilon_t; s_t) \quad (45)$$

Burada ϵ_t , sabit bir dağılımdan örneklenen bir gürültü vektörüdür. Bu ifadeye göre $J_\pi(\emptyset)$ ve $J_\pi(\emptyset)$ 'nin gradyanı eşitlik (46)'da verildiği gibi elde edilir (Haarnoja vd., 2018).

$$\begin{aligned} J_\pi(\phi) &= E_{s_t: D, \epsilon_t: N} [\log \pi_\phi(f_\phi(\epsilon_t; s_t) | s_t) - Q_\theta(s_t, f_\phi(\epsilon_t; s_t))] \\ \nabla_\phi J_\pi(\phi) &= \nabla_\phi \log \pi_\phi(a_t | s_t) + (\nabla_{a_t} \log \pi_\phi(a_t | s_t) - \\ &\quad \nabla_{a_t} Q(s_t, a_t)) \nabla_\phi f_\phi(\epsilon_t; s_t) \end{aligned} \quad (46)$$

SAC algoritmasında TD3'te olduğu gibi, kırpılmış çift-Q ağı yöntemi kullanılarak iki Q değerinden minimum olanı alınır. Bu sayede fonksiyon yaklaşım hatasından kaynaklanan aşırı tahmin yanlılığı azaltılır (Türkmen, 2022). SAC algoritmasının yapısı Şekil 6'da gösterilmiştir.



Şekil 6. SAC algoritma yapısının blok diyagramı

1.8.5. Transfer Öğrenme

Transfer öğrenme, bir model üzerinde önceden edinilmiş parametrelerin ilgili fakat farklı bir problemin çözümünde kullanılmasıyla genelleme yeteneğini artırmayı amaçlar. Daha çok DL'de kullanılan bu yöntem, RL'de de bazı çalışmalarda denenmiştir. Bu çalışmalar, transfer öğrenmenin daha az veriyle daha hızlı öğrenme sağladığını, daha karmaşık çevrelerde öğrenmeyi kolaylaştırdığını ve genelleme yeteneğini artırdığını göstermiştir (Baysal, 2022).

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

Yenilenebilir enerji kaynaklarının şebeke entegrasyonunda LVRT yeteneği önem taşımaktadır. Geleneksel denetleyicilerin genelleme kapasitesi düşük olduğundan, bu tez çalışmasında LVRT yeteneğini geliştirmek için DRL tabanlı denetleyiciler geliştirilmiştir.

Bu amaçla, iki aşamalı üç fazlı şebeke bağlantılı FV sistem Matlab/Simulink ortamında modellenmiştir. LVRT yeteneği için şebeke tarafında oluşan dengeli ve dengesiz arıza durumlarında ilgili şebeke yönetmeliğinin sağlanması amacıyla DDPG, TD3 ve SAC algoritmaları kullanılmıştır. Bu denetleyiciler hem kendi aralarında hem de geleneksel denetleyici olan PI denetleyici ile karşılaştırılarak performansları analiz edilmiştir. PI denetleyici parametreleri SOS algoritması ile optimize edilmiştir.

FV sistemde çevresel faktörlerin etkisini araştırmak için sıcaklık sabit tutularak gün ışığı değişimine bağlı gölgelenme analizi yapılmıştır. Gölgelenme analizinde geleneksel P&O algoritması ile bu tez kapsamında önerilen SAC algoritması karşılaştırmalı olarak sunulmuştur. FV sistemin dayanıklılığını artırmak için gölgelenme ve LVRT durumları birlikte ele alınmıştır. Öncelikle SAC ile dengeli arızada bu durum incelenmiş, ardından Transfer-SAC ile dengeli ve dengesiz arıza durumları ele alınarak çalışma kapsamı genişletilmiştir. Ayrıca güçlü şebeke ve zayıf şebeke koşullarında gerilimin iyileşme performansı incelenmiştir. Son olarak, sistemin gerçek zamanlı çalışması Opal-RT 4512 simülatörü kullanılarak analiz edilmiştir.

2.1. FV Sistemin Modellenmesi ve Simülasyonu

FV panelin modellenmesinde Şekil 1’de verilen tek diyot modeli kullanılmıştır. İki aşamalı üç fazlı şebeke bağlantılı FV sistem Matlab/Simulink ortamında tasarlanmıştır. Bir FV panele ait üretici bilgileri Tablo 3’te verilmiştir. FV panelin seri-paralel kombinasyonlarından oluşan FV dizin, DA-DA yükselten dönüştürücü ile gücü DA baraya iletir. Yükselten dönüştürücünün eşitlik (47)’de verilen doluluk-boşluk oranı (D) kontrol edilerek hem sabit bir DA bara gerilimi (V_{DA}) elde edilir hem de MPPT sağlanır.

İkinci aşamada iki seviyeli üç fazlı evirici kullanılarak DA gerilimi AA gerilime dönüştürülür. Elde edilen bu gerilim LC filtre ile kırpılarak 220 V üç faz gerilim elde edilmiştir. Yükseltici transformatör ile 220 V, 380 V’a yükseltilerek üç fazlı şebeke bağlantısı yapılmıştır. Modellenen sistemin blok diyagramı Şekil 7’de gösterilmiş olup


sistem parametreleri Tablo 4’te verilmiştir. Yükselten dönüştürücü ve LC filtre için parametreler, (Küçükilhan, 2017) ve (Dursun ve Döşoğlu, 2018) çalışmaları referans alınarak hesaplanmıştır.

Tablo 3. FV panel parametreleri

Açıklama	Değerleri
Optimum panel gerilimi (V_{fv})	36.72 V
Optimum panel akımı (I_{fv})	5.03 A
Açık devre gerilimi (V_{ad})	44.14 V
Kısa devre akımı (I_{kd})	5.43 A
Optimum panel gücü (P_{fv})	184.7016 W

$$D = 1 - \frac{V_{fv}}{V_{DA}} \quad (47)$$

İki seviyeli üç fazlı evirici, Şekil 7’de gösterilen geleneksel vektör kontrol yöntemiyle kontrol edilmektedir. Bu yöntem iç ve dış kontrol döngülerinden oluşur. Dış kontrol döngüsünde V_{DA} , iç kontrol döngüsünde ise akım değerleri PI denetleyici ile kontrol edilir. Bu çalışmada PI denetleyici parametreleri deneme-yanılma yöntemiyle belirlenmiştir. Akım denetleyicinin çıkışı, evirici anahtarlama sinyalleri (S) için gereken referans gerilim değerini üretir. Bu kontrol sürecinde hesaplama kolaylığı açısından eşitlik (48)’de verilen dq senkron referans çerçevesi kullanılmıştır. Üç faz sinyalin iki faz sinyale dönüştürülmesinde, faz kilitli çevrim (Phase Locked Loop, PLL) döngüsü ile elde edilen θ açısı kullanılmıştır. Şebeke tarafında elde edilen güç değerleri eşitlik (49)’da verilmiştir. Normal koşullar altında reaktif akım sıfıra ayarlanarak sistemin birim güç faktöründe çalışması sağlanır (Al-Shetwi vd., 2018).



Şekil 7. İki aşamalı üç fazlı şebeke bağlantılı FV sistem modeli

$$\begin{bmatrix} V_d \\ V_q \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \cos \theta & \cos(\theta - 2\pi/3) & \cos(\theta + 2\pi/3) \\ -\sin \theta & -\sin(\theta - 2\pi/3) & -\sin(\theta + 2\pi/3) \end{bmatrix} \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix} \quad (48)$$


$$P = \frac{3}{2} (V_{gd} I_d + V_{gq} I_q) \quad (49)$$

$$Q = \frac{3}{2} (-V_{gd} I_q + V_{gq} I_d)$$

Bu eşitlikte V_{gd} ve V_{gq} , I_d ve I_q sırasıyla dq senkron referans çerçevesindeki şebeke gerilimlerini ve şebeke akımlarını ifade eder.

Şebeke, Şekil 8’de verildiği gibi gerilim kaynağı ve hat empedansından oluşmaktadır. Hat empedans hesabı eşitlik (50)’de verilmiştir; burada S_n , sistemin kısa devre kapasite gücünü ifade eder. Hat empedansı ve kısa devre oranına (Short Circuit Ratio, SCR) bağlı olarak zayıf şebekede ortaya çıkan birkaç problem bulunmaktadır. İlk olarak, gerilim kaynağı denetleyicisinin zayıf izleme ve kararsızlık olasılığı ile kontrol edilmesinin daha zor olmasıdır. (Zhou ve Gole., 2012; Zhou vd., 2013; Zhang vd., 2014; Schmall vd., 2015) tarafından yapılan çalışmalarda zayıf şebeke kullanılarak kararlılık kaybı, zayıf referans izleme ve gerilim osilasyonlarının zayıf sönümlenmesi problemleri ele alınmıştır. İkinci problem aşırı gerilimdir. Bazı şebeke yönetmelikleri ve standartları, bozulmalar veya düşük gerilimler sırasında büyük reaktif akım enjeksiyonu gerektirir. Şebeke zayıf olduğunda bu

gereksinimi karşılamaya çalışmak, aşırı gerilim rölelerinin açma sinyalleri göndermesini tetikleyen geçici bir aşırı gerilime neden olabilir ve bu durum kaynağın şebekeden ayrılması ile sonuçlanır (Zhou vd., 2013). (Subburaja vd., 2016) tarafından yapılan çalışmada ise zayıf şebekelerde arıza temizlendikten sonra sistemin daha yavaş kararlı hale geçtiği belirtilmiştir. Şebeke yönetmeliklerinde ifade edilen bazı gereklilikler zayıf şebekede kararlılığı bozabilir. Bu nedenle çoğunlukla şebeke, güçlü şebeke olarak kabul edilir. Bu tez çalışmasında güçlü şebeke yapısı için SCR ve X/R sırasıyla 30 ve 7 olarak belirlenmiştir. Hat empedans parametreleri Tablo 4’te verilmiştir.



Şekil 8. Üç faz şebeke modeli blok diyagramı

$$R_h = \frac{V_{gff}^2 / S_n}{X / R}$$

$$L_h = \frac{V_{gff}^2 / S_n}{2\pi f_g}$$
(50)

Tablo 4. Üç fazlı şebeke bağlantılı FV sistem parametreleri

Parametreler	Değerleri
FV dizin gücü (P_{mp})	738 W
FV dizin gerilimi (V_{mp})	146.88 V
FV dizin akımı (I_{mp})	5.03 A
Seri bağlı panel sayısı (N_s)	4
Paralel bağlı panel sayısı (N_p)	1
DA bara gerilimi (V_{DA})	400 V
Yükselten dönüştürücü endüktans değeri (L_b)	3 mH
DA bara kapasitör değeri (C_{DA})	20 μ F
Faz-faz şebeke gerilimi (V_{gff})	380 V
Şebeke frekansı (f_g)	50 Hz
Şebeke hat direnci (R_h)	0.6876 Ω
Şebeke hat endüktansı (L_h)	0.015 H
LC filtre endüktansı (L_f)	16 mH
Evirici anahtarlama frekansı (f_{ah})	15 kHz
Akım denetleyici PI parametreleri (K_{pi}, K_{ii})	0.5, 30
Gerilim denetleyici PI parametreleri (K_{pv}, K_{iv})	7, 800
Trafo parametreleri	220/380 V, 50 Hz

2.2. LVRT Yeteneği için Kontrol Yöntemlerinin Tasarımı

Bu tez çalışmasında LVRT yeteneğini sağlamak için Bölüm 1.4.1’de bahsedilen Almanya şebeke yönetmeliğine bağlı reaktif akım enjeksiyonu ve Bölüm 1.4.2’de açıklanan DA kısıyıcı devresi kullanılmıştır. Bu devredeki direnç değeri (R_{DA}), eşitlik (51)’de verilen formülle hesaplanmış ve 400 V DA bara gerilimi ve 738 W güç için 217 Ω olarak bulunmuştur. Dirence seri bağlı bulunan yarı iletken anahtarın D ’si kontrol edilerek arıza sırasında aktif güç dengesizliğinden kaynaklanan gerilim yükselmesi önlenir ve FV sistemin sürekli MPPT’de çalışması sağlanır. Güç elektroniği cihazlarının zarar görmemesi ve kaynağın şebekeden ayrılması için V_{DA} eşik değeri, (Haidar ve Julai, 2019) çalışmasında olduğu gibi 1.1 pu olarak belirlenmiştir.

$$R_{DA} = \frac{V_{DA}^2}{P_{mp}} \quad (51)$$

Şebekeye reaktif akım enjekte edilirken, reaktif akım değeri (I_q) Bölüm 1.4.1 Şekil 3'te verilen karakteristiğe göre arıza anındaki gerilim değerine (V_{dip}) bağlı olarak eşitlik (52)'de verildiği gibi hesaplanır. V_{dip} , literatürde yaygın olarak kullanılan RMS metodu ile eşitlik (53)'te verildiği gibi hesaplanmaktadır (Al-Shetwi vd., 2018). Arıza sırasında hem aktif akım (I_d) hem I_q bileşenleri olduğundan dolayı evirici akımının maksimum değerini aşmaması için arıza sırasında I_d değerinin eşitlik (54)'te verildiği gibi azaltılması gerekir. Bu çalışmada maksimum evirici akımı (I_g), (Samarasekera, 2015) çalışmasında belirtildiği gibi 1.2 pu olarak alınmıştır. Arıza sırasında güç takibi için kullanılan referans aktif güç (P^*) ve referans reaktif güç (Q^*) değerleri ise eşitlik (55)'te verilmiştir. Bu tez çalışmasında tüm senaryolarda pozitif bileşen akım ve gerilim değerleri kullanılmıştır.

$$I_q = \begin{cases} 0 & V_{dip} \leq 0.1 \\ 2V_{dip} & 0.1 < V_{dip} < 0.5 \\ 1 & V_{dip} \geq 0.5 \end{cases} \quad (52)$$

$$V_{dip} = \sqrt{V_{gd}^2 + V_{gq}^2} \quad (53)$$


$$I_d = \sqrt{I_g^2 - I_q^2} \quad (54)$$

$$\begin{aligned} P^* &= \frac{3}{2}(V_{gd}I_d) \\ Q^* &= \frac{3}{2}(V_{gd}I_q) \end{aligned} \quad (55)$$

2.2.1. SOS-PI Tabanlı Denetleyici Uygulaması


SOS-PI tabanlı denetleyicinin LVRT yeteneği için uygulanması Şekil 9'da gösterilmiştir. SOS algoritması, P^* ve Q^* değerlerini takip etmek için D ve I_q değişkenlerini kontrol eden PI denetleyici parametrelerini optimize eder. Oransal kazançlar $K_p = [K_{pP}, K_{pQ}]$

olarak gösterilir. Burada K_{pP} aktif güç kontrolüne, K_{pQ} ise reaktif güç kontrolüne karşılık gelir. Benzer şekilde, integral kazançlar $K_i = [K_{iP}, K_{iQ}]$ şeklindedir. Amaç fonksiyonu olarak eşitlik (56)'da verilen zaman ağırlıklı mutlak hata integrali (ITAE) tanımlanmıştır. ITAE, hem hata büyüklüğünü hem de süresini en aza indirerek denetleyicinin geçici ve kararlı durum davranışlarını iyileştirir. Bu ölçüt, dinamik değişimlere karşı hassas ve hızlı tepki gerektiren şebekeye bağlı sistemlerde yaygın olarak kullanılır. Ayrıca amaç fonksiyonuna, $I_g > 1.5$ A ve $V_{DA} > 440$ V olarak tanımlı iki kısıt girilmiştir. Sistemde arıza uygulanması için şebeke kaynağı Şekil 10'da gösterildiği gibi modellenen zamana bağlı gerilim genliği değiştirilmiştir. Toplamda 2 saniye çalışan simülasyonda 0.5-0.65 saniye arasında 0.3 pu dengeli ve dengesiz arızalar uygulanmıştır. Algoritmanın başlangıç parametreleri Tablo 5'te verilmiştir.



Şekil 9. SOS-PI tabanlı denetleyicinin LVRT yeteneği için uygulama blok diyagramı

$$\min_{K_{pP}, K_{iP}, K_{pQ}, K_{iQ}} obj = \sum ITAE = \int t |(P^* - P)| + \int t |(Q^* - Q)| \quad (56)$$



Şekil 10. Bir faz için şebeke kaynağı modellemesi

Tablo 5. Optimizasyon parametre tablosu

Parametre	Değerleri
Organizma boyutu (n_d)	4
Organizma sayısı (n_o)	20
Maksimum iterasyon sayısı (N_{maks})	30
$[K_{pP}, K_{iP}, K_{pQ}, K_{iQ}]$ alt limit (l_b)	[0.001, 0.001]
$[K_{pP}, K_{iP}, K_{pQ}, K_{iQ}]$ üst limit (u_b)	[10, 500]

2.2.2. DRL Tabanlı Denetleyici Uygulaması

DRL tabanlı denetleyicinin LVRT yeteneği için uygulanması ve kullanılan çevre sırasıyla Şekil 11 ve Şekil 12’de gösterilmiştir. Şekil 11’de görüldüğü gibi, öğrenme ajanı bir DNN kullanarak politikayı öğrenir ve çevreden alınan durum değişkenlerine göre aksiyon üretir. Çevrenin bu aksiyonlara verdiği tepki, önceden tanımlanmış bir ödül sistemine tabi tutulur ve sinir ağına geri bildirim olarak verilerek ajanın daha iyi bir politika geliştirmesi sağlanır.

Bu çalışmada, iki kademeli üç fazlı şebeke bağlantılı FV sistem eşitlik (57)’de gösterildiği gibi ajana 12 adet tek boyutlu gözlem değeri sağlar. Ajan, bu 12 gözlemi eşitlik (58)’de verildiği gibi D ve I_q ’dan oluşan iki boyutlu aksiyon uzayına haritalar. Bu aksiyon sinyalleri sırasıyla $[0, 1]$ ve $[-1, 0]$ aralıklarında değişir. Ödül fonksiyonu, arıza sırasında gerilim değerine dayalı olarak referans güçleri takip edecek şekilde tasarlanmıştır. Aynı zamanda V_{DA} gerilimi ve I_g akımını belirlenen sınırlar içinde tutar. Sistem eğitiminde kullanılan bu ödül fonksiyonu eşitlik (59)’da tanımlanmıştır.

$$s_t = \{V_{DA}, P, e_P, e_{Pi}, Q, e_Q, e_{Qi}, I_d, V_g, I_g, D_{t-1}, I_{qt-1}\} \quad (57)$$

Bu eşitlikte e_{Pi} , e_{Qi} , V_g , D_{t-1} ve I_{qt-1} sırasıyla aktif güç hatasının integrali, reaktif güç hatasının integrali, şebeke gerilimi, bir önceki zaman adımındaki D değeri ve bir önceki zaman adımındaki I_q değerini temsil eder.

$$a_t = \{I_q, D\} \quad (58)$$

$$r_{tlvt} = -0.1e_P^2 - 0.1e_Q^2 + 3H_P + 3H_Q - 10F_1 - 5F_2 - 5F_3 - 10F_4 \quad (59)$$

e_P ve e_Q , eşitlik (60)'da tanımlanan aktif ve reaktif güç hatalarını ifade eder. Arıza sırasında güç takibi başarısız olduğunda, bu hatalar ödül fonksiyonunda ceza oluşturmak için kullanılır.

$$\begin{aligned} e_P &= P^* - P \\ e_Q &= Q^* - Q \end{aligned} \quad (60)$$

H_P ve H_Q , eşitlik (61)'de gösterildiği gibi güç hatası azaltımını teşvik eden lojik terimlerdir. Bu denklemlerde hata limiti 0.1 olarak belirlenmiştir ve Almanya şebeke yönetmeliğinin -%10, +%20 bant aralığındaki minimum değerini temsil eder. Sapmalar küçük kaldığında ve kabul edilebilir sınırlar içinde olduğunda, bu terimler ajana pozitif ödül sağlar.

$$\begin{aligned} H_P &= \begin{cases} 0 & e_P^2 > 0.01 \\ 1 & e_P^2 \leq 0.01 \end{cases} \\ H_Q &= \begin{cases} 0 & e_Q^2 > 0.01 \\ 1 & e_Q^2 \leq 0.01 \end{cases} \end{aligned} \quad (61)$$

F_1 , eşitlik (62)'de belirtildiği gibi maksimum evirici akım değerinin aşılması için ödül fonksiyonuna eklenen bir lojik terimdir. F_2 ve F_3 , Almanya şebeke yönetmeliğinde belirtilen -%10, +%20 tolerans bandını korumak için ödül fonksiyonuna eklenmiş lojik


terimlerdir ve eşitlik (63)'te verilmiştir. F_4 ise simülasyonun erken durması halinde ajana ceza verilen bir lojik terimdir. Tanımlanan koşullardan biri gerçekleşirse simülasyon duracaktır; $I_g > 1.5 \text{ A}$, $V_{DA} > 440 \text{ V}$, $(Q/Q^* > 2 \text{ pu veya } Q/Q^* < 0.1 \text{ pu})$, $(P/P^* > 2 \text{ pu veya } P/P^* < 0.1 \text{ pu})$.

$$F_1 = \begin{cases} 0 & I_g \leq 1.35 \text{ A} \\ 1 & I_g > 1.35 \text{ A} \end{cases} \quad (62)$$


$$F_2 = \begin{cases} 0 & 0.9 \leq Q/Q^* \leq 1.2 \text{ pu} \\ 1 & Q/Q^* < 0.9 \text{ veya } Q/Q^* > 1.2 \text{ pu} \end{cases} \quad (63)$$

$$F_3 = \begin{cases} 0 & 0.9 \leq P/P^* \leq 1.2 \text{ pu} \\ 1 & P/P^* < 0.9 \text{ veya } P/P^* > 1.2 \text{ pu} \end{cases}$$

Hata terimlerinin ceza katsayıları, aktif ve reaktif güç hatalarının sistem performansına etkisini sınırlamak için seçilmiştir. Daha büyük bir ceza katsayısı, öğrenme sürecinde kontrol hedeflerine aşırı öncelik vererek sistemin genel kararlılığını olumsuz etkileyebilir. Bu nedenle, hata azaltımını teşvik ederken öğrenme sürecinde denge sağlamak için -0.1 katsayısı belirlenmiştir. Ödül katsayıları, sistemin aktif ve reaktif güç referanslarına hızlı ulaşmasını teşvik eder. Pozitif bir katsayının seçilmesi, denetleyicinin sistem kararlılığını artırması için bir ödül mekanizması sağlar. +3 değeri, ödül teriminin ceza terimleriyle dengelenmesini ve öğrenmenin istikrarlı bir şekilde ilerlemesini sağlar. Ayrıca arıza sırasında şebekeden ayrılma sistem kararlılığını olumsuz etkileyeceğinden, -5 ve -10 ceza katsayıları girilmiştir. Bu sayede, her arıza koşulunda sistemin şebekeye bağlı kalmasını sağlayan bir kontrol yöntemi elde edilmiştir.



Şekil 11. DRL ile LVRT kontrol blok diyagramı



Şekil 12. DRL tabanlı denetleyicide LVRT kontrolü için kullanılan çevre

2.2.3. Dengeli Arıza Sonuçlarının Karşılaştırılması

Şebeke bağlantılı FV sistemde LVRT yeteneği için DRL algoritmalarından DDPG, TD3 ve SAC yöntemleri kullanılmıştır. DDPG ve TD3 ajanları, Tablo 6'daki eğitim parametreleri ve Tablo 7'deki ajan parametreleri kullanılarak eğitilmiştir. Aktör ağı 7 katmandan, kritik ağı ise gözlem ve aksiyonlar için ayrı girişlere sahip 9 katmandan oluşmaktadır. Ağ mimarisi, sırasıyla 400 ve 300 nöron içeren iki tam bağlı gizli katman kullanmaktadır. Her iki ağda da bu gizli katmanların ardından ReLU aktivasyon fonksiyonu uygulanmaktadır. Aktör ağının çıkışında tanh aktivasyon fonksiyonu kullanılmış olup, DA kıyıcı devresi için D değerini ve evirici için I_q değerini belirler. Kritik ağın çıkışı, elde edilen ödüle göre hem aktör hem kritik ağların güncellenmesinde kullanılır.

SAC algoritması için ise Şekil 13’te verilen ağ yapısı kullanılmış olup Tablo 6’daki eğitim parametreleri ve Tablo 8’deki ajan parametreleri ile eğitim yapılmıştır. SAC ağ mimarisi, 11 katmanlı bir aktör ağı ile gözlem ve aksiyon için iki ayrı girişi bulunan, her biri 9 katmandan oluşan iki kritik ağdan oluşmaktadır. Ağ mimarisinde sırasıyla 400 ve 300 nörondan oluşan tam bağlı gizli katmanlar kullanılmıştır. Her iki ağda da tam bağlı gizli katmanlardan sonra ReLU aktivasyon fonksiyonu uygulanmaktadır. Aktör ağında politikanın ortalama değeri ve standart sapma değeri birleştirilerek Gauss politika dağılımının parametreleri oluşturulur. Standart sapma için kullanılan softplus katmanı, bu değer her zaman sıfırdan büyük olmasını sağlar. Kritik ağın çıkışı, DDPG ve TD3’te olduğu gibi hem aktör hem de kritik ağların güncellemesinde kullanılır. Yapılan bütün eğitimler, Intel i7-12700 CPU @ 2.1 GHz, 16 GB RAM, Nvidia RTX 3060 GPU ekran kartına sahip bir bilgisayarda gerçekleştirilmiştir.

Tablo 6. DDPG, TD3 ve SAC ajanlarının eğitim parametreleri


Parametreler	Değerleri
Ajanın örnekleme zamanı (T_s)	0.002 s
Simülasyon zamanı (T_f)	2 s
Maksimum adım sayısı (T_f/T_s)	1000
Maksimum bölüm sayısı	20000
Ortalama pencere uzunluğu	250
Eğitim durdurma kriteri/değeri	Maksimum bölüm sayısı/20000
Ajan kaydetme kriteri/değeri	Bölüm sayısı/5700

Tablo 7. DDPG ve TD3 ajanlarına ait parametreler

Parametreler	Değerleri
Aktör için öğrenme hızı	$1e^{-3}$
Kritik için öğrenme hızı	$1e^{-3}$
Azaltma faktörü	$\gamma = 0.99$
Bellek boyutu	$1e^6$
Mini-paket boyutu	256
Keşif aksiyon gürültü modeli	OU
Keşif aksiyon gürültüsünün standart sapması	0.3
Keşif aksiyon gürültüsünün minimum standart sapması	$1e^{-3}$
Keşif aksiyon gürültüsünün standart sapma bozulma oranı	$1e^{-6}$
Hedef aksiyon gürültü modeli (TD3)	Gauss
Hedef aksiyon gürültüsünün standart sapması	0.32
Hedef aksiyon gürültüsünün alt ve üst sınırları	-0.3,0.3
Hedef aksiyon gürültüsünün standart sapma bozulma oranı	0
Hedef aksiyon gürültüsünün minimum standart sapması	0.1
Yumuşak hedef güncelleme katsayısı	$5e^{-3}$

Tablo 8. SAC ajanına ait parametreler

Parametreler	Değerleri
Aktör için öğrenme hızı	$1e^{-3}$
Kritik için öğrenme hızı	$1e^{-3}$
Azaltma faktörü	0.99
Yumuşak hedef güncelleme katsayısı	$5e^{-3}$
Bellek boyutu	$1e^6$
Mini-paket boyutu	256
Hedef entropi değeri	-2
Politika güncelleme frekansı	2
Hedef güncelleme frekansı	2




Şekil 13. SAC ağ mimarisi akış diyagramı


Şekil 14’te dengeli arıza için elde edilen eğitim eğrileri verilmiştir. Eşitlik (59)’da verilen ödül fonksiyonuna göre, her adımın maksimum ödül değeri yaklaşık 6 ve maksimum bölüm ödülü $6 \times 1000 = 6000$ ’dir. DDPG’nin eğitimi yaklaşık 87 saat sürmüş, maksimum bölüm ödülü 5999’a ulaşmış ve ortalama ödül 5554 olmuştur. TD3’ün eğitimi yaklaşık 154 saat sürmüş, maksimum bölüm ödülü 5999’a ulaşmış ve ortalama ödül 5965 olmuştur. SAC’ın eğitimi ise yaklaşık 45 saat sürmüş ve maksimum bölüm ödülü 5997’ye ulaşmış ve ortalama ödül 5793’e yakınsamıştır.

Ortalama ödül değerleri karşılaştırıldığında, üç yöntemin de öğrenme eğrisinin kararlı bir değere yakınsadığı, ancak yakınsama hızı ve kararlılık durumlarının farklı olduğu görülmektedir. SAC ajanı en hızlı yakınsamayı göstermiş ve bu düzeyi eğitim boyunca düşük genlikli dalgalanmalarla korumuştur. TD3, SAC’a göre öğrenmeye geç başlamış, ancak yakınsadıktan sonra kararlı durumunu sürdürmüştür. DDPG ajanı ise zaman zaman


negatif ödüllerle birlikte belirgin dalgalanmalar sergilemiştir. Ortalama ödül sonunda artırabilmiş olsa da bu artış yavaş ve tutarsız gerçekleşmiştir. SAC, maksimum entropi çerçevesinde beklenen ödülü politika entropisiyle birlikte optimize ettiği için stokastik politika ve sıcaklık katsayısı aracılığıyla keşif-sömürü dengesini düzenler. Bu sayede hızlı yakınsama ve kararlı öğrenme süreci sağlar.




(a)



(b)



(c)



(d)

Şekil 14. Dengeli üç faz arıza için eğitim eğrileri

Eğitim sürecinde genelleme yeteneğini artırmak amacıyla farklı gerilim değerlerinde (0.3 pu, 0.4 pu, 0.5 pu, 0.6 pu, 0.7 pu ve 0.8 pu) üç fazlı dengeli arıza uygulanmıştır. (Lin vd., 2020) ve (Bighash vd., 2018) çalışmalarından farklı olarak, bu çalışma denetleyicinin geniş bir aralıkta etkinliğini göstermektedir. Test aşamasında arıza sırasındaki dinamik tepkiyi analiz etmek için toplamda 2 saniye çalışan simülasyonda arıza, Şekil 10'da gösterildiği gibi 0.5-0.65 saniye aralığında uygulanmıştır. Tablo 9 ve Tablo 10, eğitim ve test verileri için ITAE performans ölçütü sonuçlarını ve SOS algoritmasıyla optimize edilmiş PI denetleyici sonuçlarını sunmaktadır. Optimize edilmiş PI parametreleri Tablo 11'de verilmiştir.

Tablo 9. Dengeli arıza eğitim verileri için ITAE performans ölçüt değerleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	SOS-PI	0.0059	0.0034	0.0047
	DDPG	0.0044	0.0025	0.0035
	TD3	0.0049	0.0018	0.0034
	SAC	0.004	0.0028	0.0034
0.4	SOS-PI	0.0096	0.0036	0.0066
	DDPG	0.0046	0.0019	0.0033
	TD3	0.0045	0.0021	0.0033
	SAC	0.0041	0.0029	0.0035
0.5	SOS-PI	0.0099	0.0039	0.0069
	DDPG	0.005	0.002	0.0035
	TD3	0.005	0.003	0.004
	SAC	0.0041	0.0027	0.0034
0.6	SOS-PI	0.0088	0.004	0.0064
	DDPG	0.0042	0.0021	0.0032
	TD3	0.0039	0.0024	0.0032
	SAC	0.0037	0.0025	0.0031
0.7	SOS-PI	0.0065	0.0037	0.0051
	DDPG	0.0046	0.0021	0.0034
	TD3	0.0041	0.0022	0.0032
	SAC	0.0042	0.002	0.0031
0.8	SOS-PI	0.0068	0.0031	0.005
	DDPG	0.0059	0.0049	0.0054
	TD3	0.0049	0.004	0.0045
	SAC	0.0037	0.0024	0.0031

Tablo 10. Dengeli arıza test verileri için ITAE performans ölçüt değerleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.35	SOS-PI	0.0088	0.0034	0.0061
	DDPG	0.0044	0.0021	0.0033
	TD3	0.0048	0.002	0.0034
	SAC	0.004	0.0029	0.0035
0.45	SOS-PI	0.0097	0.004	0.0069
	DDPG	0.0048	0.0023	0.0036
	TD3	0.0045	0.0024	0.0035
	SAC	0.0041	0.0026	0.0034
0.55	SOS-PI	0.0096	0.004	0.0068
	DDPG	0.0037	0.0018	0.0028
	TD3	0.0046	0.0023	0.0035
	SAC	0.0039	0.0027	0.0033
0.65	SOS-PI	0.007	0.0038	0.0054
	DDPG	0.004	0.0021	0.0031
	TD3	0.004	0.0022	0.0031
	SAC	0.0044	0.0022	0.0033
0.75	SOS-PI	0.0069	0.0036	0.0053
	DDPG	0.0052	0.0045	0.0049
	TD3	0.004	0.003	0.0035
	SAC	0.004	0.0024	0.0032

Tablo 11. Dengeli arıza için optimize edilmiş PI parametre değerleri

SOS-PI	K_{pP}	K_{iP}	K_{pQ}	K_{iQ}
	8.642	195.55	6.685	292.69

Eğitim ve test verileri için ortalama hata değerlerine bakıldığında SAC, SOS-PI'a kıyasla %27.66 ile %51.56 arasında değişen iyileşme performansı göstermiştir. DRL yöntemleri arasında bakıldığında;

$V_g = 0.3$ pu arızasında SAC, DDPG'ye göre %2.86 iyileşme gösterirken TD3 ile aynı performansı göstermiştir.

$V_g = 0.4$ pu arızasında ise DDPG ve TD3 aynı performansı gösterirken SAC %6.06 geriye düşmüştür.

$V_g = 0.5$ pu arızasında SAC tekrardan öne geçerek DDPG ve TD3'e kıyasla sırasıyla %2.86 ve %15 iyileşme göstermiştir.

$V_g = 0.6$ pu arızasında SAC, DDPG ve TD3'e göre %3.13 düzeyinde küçük ama tutarlı bir üstünlük göstermektedir.

$V_g = 0.7$ pu arızasında SAC, DDPG'ye göre %8.82, TD3'e göre %3.13 iyileşme ile üstünlüğünü korur.

$V_g = 0.8$ pu arızasında ise SAC, DDPG'ye göre %42.59, TD3'e göre %31.11 daha iyi sonuç vererek avantajını belirgin biçimde gösterir.

Benzer şekilde test verileri için de ortalama hata değerlerine bakıldığında, $V_g = 0.35$ pu ve 0.65 pu arızalarında sırasıyla SAC, DDPG'ye göre %6.06, TD3'e göre %2.94 ve hem DDPG hem TD3'e göre %6.45 zayıf performans göstermiştir.


$V_g = 0.45$ pu ve 0.75 pu arızalarında ise sırasıyla SAC, DDPG'ye göre %5.56, TD3'e göre %2.86 ve DDPG'ye göre %34.69, TD3'e göre %8.57 iyileşme göstermiştir.

Son olarak $V_g = 0.55$ pu arızasında SAC, DDPG'ye göre %17.86 geride kalırken TD3'e göre %5.71 daha iyi sonuç vermiştir.


Bununla birlikte t-test analizi, SAC ile SOS-PI kontrol yöntemleri arasındaki $ITAE_{ort}$ performans farkının istatistiksel olarak anlamlı olduğunu ortaya koymuştur ($p = 0.0009$) ve bu sonuç SAC'ın üstün performansını doğrulamaktadır.

Şekil 15-17 en şiddetli, orta şiddetli ve az şiddetli arızalar için sırasıyla 0.3 pu, 0.5 pu ve 0.7 pu gerilim değerlerinde şebeke aktif gücü, şebeke reaktif gücü, DA bara gerilimi ve şebeke akım yanıtlarını göstermektedir. $V_g = 0.3$ pu arızasında tüm denetleyiciler aktif ve reaktif güçleri kararlı durum hata sınırları (+%20 ile -%10) içinde tutmaktadır. Ancak performansları belirgin şekilde farklılık göstermektedir. DRL tabanlı denetleyiciler, kontrol parametrelerini dinamik olarak ayarlayarak I_q enjeksiyonu ve aktif güç azaltımını hızla entegre eder ve DA bara gerilimini minimum geçici salınımla kararlı tutmaktadır. Buna karşılık SOS-PI denetleyici daha yavaş tepki verir. Bu gerilim kararsızlığını uzatır ve evirici bağlantısının kesilme riskini artırarak şebeke kararlılığını tehlikeye atabilir. Şebeke akımında SOS-PI denetleyici, arıza başlangıcında geçici anda sınır değerini aşsa da kararlı durumda diğer yöntemler gibi 1.35 A sınır değerini sağlamıştır. 0.5 pu arıza değeri için Şekil 16'da görüldüğü gibi SOS-PI tabanlı denetleyici hata tolerans ve akım sınırlarını


karşılamamaktadır. DRL tabanlı denetleyiciler şebeke yönetmeliğini ve sınırları sağlasa da DDPG ve TD3'te özellikle 0.7 pu arıza değeri için SAC'a kıyasla daha fazla osilasyon olduğu görülmektedir.



Şekil 15. FV sistemin 0.3 pu dengeli arıza için yanıtları



Şekil 16. FV sistemin 0.5 pu dengeli arıza için yanıtları



Şekil 17. FV sistemin 0.7 pu dengeli arıza için yanıtları

Almanya şebeke yönetmeliği kapsamında Bölüm 1.4.1’de açıklanan t_r ve t_s süreleri, P ve Q için incelenerek kontrol yöntemlerinin dinamik tepkileri Tablo 12 ve Tablo 13’te verilmiştir.

Eğitim verisi sonuçlarında SAC, SOS-PI’a karşı aktif güç için t_r ’de ortalama %74.52, t_s ’de ortalama %84.36 azalma ile üstünlük göstermiştir. Reaktif güçte ise t_s ’de %78.54 daha hızlıyken, t_r ’de %5.8 yavaş kalmıştır.

DRL tabanlı yöntemler ile karşılaştırıldığında SAC, DDPG’ye kıyasla aktif güç ve reaktif güç için t_s ’de sırasıyla %54.22, %44.73 daha hızlıdır ancak aktif güç ve reaktif güç için t_r ’de sırasıyla %9.66, %48.18 yavaş kalmıştır.

TD3’te ise, SAC’ın aktif güç t_r ve t_s süreleri sırasıyla %9.38 ve %8.09 daha hızlıdır, buna karşın reaktif güç t_r ve t_s sürelerinde %29.34 ve %16.34 daha yavaş kalmıştır.

Test verisi sonuçları, eğitim verisine benzer sonuçlar vermiştir. Ancak sadece SAC ajanı tüm arıza durumlarını genelleleyebilmiştir. SAC, SOS-PI denetleyiciden belirgin şekilde daha iyi performans gösterirken, DDPG ve TD3 ile yakın performans sergilemiştir. SOS-PI denetleyicinin yavaş dinamik tepkisi, arıza sırasında ve sonrasında sistem kararlılığını tehlikeye atabilir. Hızlı tepki gerektiren senaryolarda SOS-PI ile gecikmeli denetim, enerji kaybının artmasına ve şebeke kararsızlığı riskinin yükselmesine yol açabilir.


Ortalama hata değeri en düşük olan SAC ajanının frekans tepkisi de incelenmiştir. Şekil 18’de görüldüğü üzere, arıza sırasında frekans değeri Almanya şebeke yönetmeliğinde belirtilen 47.5 Hz ile 51.5 Hz aralığında kalmıştır.

Tablo 12. Dengeli arıza eğitim verisi için aktif güç ve reaktif güç dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	SOS-PI	0.03	0.0392	0.0180	0.0468
	DDPG	0.015	0.0178	0.0076	0.0094
	TD3	0.0152	0.0180	0.0078	0.0096
	SAC	0.0138	0.0166	0.0198	0.0218
0.4	SOS-PI	0.0166	0.1468	0.0168	0.0430
	DDPG	0.0152	0.0180	0.0104	0.0124
	TD3	0.0162	0.0192	0.0116	0.0136
	SAC	0.0146	0.0176	0.0196	0.0218
0.5	SOS-PI	0.0466	0.1422	0.0170	0.0462
	DDPG	0.0150	0.0180	0.0130	0.0152
	TD3	0.0212	0.0244	0.0140	0.0162
	SAC	0.0156	0.0188	0.0182	0.0206
0.6	SOS-PI	0.0756	0.1408	0.0168	0.1418
	DDPG	0.0116	0.0258	0.0160	0.0182
	TD3	0.0232	0.0260	0.0182	0.0204
	SAC	0.0148	0.0180	0.0164	0.0188
0.7	SOS-PI	0.1356	0.1390	0.0160	0.1406
	DDPG	0.0116	0.0298	0.0152	0.0172
	TD3	0.0148	0.0172	0.0166	0.0276
	SAC	0.0150	0.0270	0.0164	0.0188
0.8	SOS-PI	0.0520	0.1476	0.0154	0.1388
	DDPG	0.0144	0.1488	0.0092	0.1440
	TD3	0.0096	0.0238	0.0136	0.0154
	SAC	0.0170	0.0202	0.0154	0.0178

Tablo 13. Dengeli arıza test verisi için aktif güç ve reaktif güç dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.35	SOS-PI	0.0164	0.1364	0.0174	0.0442
	DDPG	0.0152	0.0180	0.0088	0.0108
	TD3	0.0156	0.0186	0.01	0.0118
	SAC	0.0142	0.0170	0.02	0.0222
0.45	SOS-PI	0.0486	0.1466	0.0170	0.0446
	DDPG	0.0150	0.0180	0.0118	0.0140
	TD3	0.0174	0.0206	0.0128	0.0150
	SAC	0.0150	0.0182	0.0190	0.0212
0.55	SOS-PI	0.0488	0.1434	0.0170	0.1418
	DDPG	0.0144	0.0174	0.0134	0.0156
	TD3	0.0180	0.0210	0.0174	0.0196
	SAC	0.0152	0.0184	0.0170	0.0196
0.65	SOS-PI	0.0808	0.1398	0.0164	0.1410
	DDPG	0.0108	0.0298	0.0164	0.0186
	TD3	0.0158	0.0184	0.0170	0.0678
	SAC	0.0152	0.0182	0.0168	0.0192
0.75	SOS-PI	0.1046	0.1468	0.0158	0.1392
	DDPG	0.0130	0.1468	0.0164	0.1476
	TD3	0.0144	0.0276	0.0156	0.0306
	SAC	0.0154	0.0186	0.0162	0.0186



Şekil 18. Dengeli arıza için SAC ajanı frekans yanıtı


SAC, LVRT yeteneği için P ve Q kontrolünde ITAE değerleri açısından SOS-PI'ya göre çok daha düşük hata elde etmiştir. Bunun temel nedeni, SAC'ın kontrol eylemlerini adaptif olarak optimize edebilmesi, SOS-PI'nın ise sabit kontrol parametrelerine bağlı kalmasıdır. SOS-PI denetleyici çoğu arıza değerinde kabul edilebilir hata sınırlarını ve dinamik yanıt tepkilerini sağlayamadığı için genelleme yeteneği zayıf kalmıştır. Buna karşın SAC, tüm senaryolarda kararlı bir performans göstererek şebeke yönetmeliği gereksinimlerini karşılamaktadır. SAC bazı durumlarda DDPG ve TD3'e yakın veya zayıf performans gösterse de, nicel bulgular geniş çalışma koşulları altında daha iyi genelleme ve daha düşük ortalama hata ürettiğini ortaya koymaktadır. Maksimum entropi yaklaşımına dayalı politika öğrenimi, keşif-sömürü dengesini iyileştirerek öğrenme kararlılığını artırmaktadır. Bu sayede SAC, kararlı durum hatasını azaltmakta ve toparlanma sürelerini kısaltmaktadır.

2.2.4. Dengesiz Arızalar İçin Sonuçların Karşılaştırılması


Dengeli arıza ile yapılan eğitimler sonucunda, DRL yöntemleri arasında DDPG en yüksek hatayı vermiş ve tüm arıza değerleri için genelleme sağlayamamıştır. Bu nedenle dengesiz arıza için TD3 ve SAC yöntemleri kullanılmıştır. Her iki yöntem için de eğitim ve

ajan parametreleri dengeli arıza ile aynıdır. Dengesiz arızada sistemin öğrenmesi zorlaştığından, simülasyon durdurma koşulu olarak yalnızca $I_g > 1.5 \text{ A}$, $V_{DA} > 440 \text{ V}$ sınırları tanımlanmıştır. Genelleme yeteneğini artırmak amacıyla, eğitim sürecinde farklı gerilim değerlerinde (0.3 pu, 0.4 pu, 0.5 pu, 0.6 pu, 0.7 pu ve 0.8 pu) tek fazlı ve iki fazlı dengesiz arızalar uygulanmıştır. Elde edilen eğitim eğrileri Şekil 19’da gösterilmiştir. TD3’ün eğitimi yaklaşık 114 saat sürmüştür. Maksimum bölüm ödülü 5988’e ulaşmış ve ortalama ödül 5878 olmuştur. SAC’ın eğitimi ise yaklaşık 46 saat sürmüştür. Maksimum bölüm ödülü 5858’e ulaşmış ve ortalama ödül 5312’ye yakınsamıştır. SAC ajanı hızlı yakınsama göstermiş ve bu düzeyi eğitim boyunca düşük genlikli dalgalanmalarla korumaktadır. TD3 ajanı ise zaman zaman negatif ödüllerle birlikte belirgin dalgalanmalar sergilemiştir. Ortalama ödül sonunda artırabilmiş olsa da bu artış yavaş gerçekleşmiştir.

Test aşamasında arıza sırasındaki dinamik tepkiyi analiz etmek için toplamda 2 saniye çalışan simülasyonda arıza, 0.5-0.65 saniye aralığında uygulanmıştır. Eğitim verileri için ITAE performans ölçütü sonuçları ve SOS algoritmasıyla optimize edilmiş PI denetleyici sonuçları Tablo 14 ve Tablo 15’te verilmiştir. Optimize edilmiş PI parametreleri Tablo 16’da yer almaktadır.



(a)



(b)

Şekil 19. Dengesiz arıza için eğitim eğrileri

Tablo 14. Tek faz arızasında eğitim verileri için ITAE performans ölçütü değerleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	SOS-PI	0.0044	0.0031	0.0038
	TD3	0.0042	0.0033	0.0038
	SAC	0.0085	0.0043	0.0064
0.4	SOS-PI	0.0042	0.0033	0.0038
	TD3	0.0049	0.0029	0.0039
	SAC	0.0085	0.0049	0.0067
0.5	SOS-PI	0.0043	0.0031	0.0037
	TD3	0.0053	0.0025	0.0039
	SAC	0.0088	0.0046	0.0067
0.6	SOS-PI	0.0042	0.0025	0.0034
	TD3	0.013	0.0071	0.01
	SAC	0.005	0.0027	0.0039
0.7	SOS-PI	0.0041	0.0023	0.0032
	TD3	0.0133	0.0071	0.01
	SAC	0.0038	0.0024	0.0031
0.8	SOS-PI	0.0041	0.0021	0.0031
	TD3	0.0113	0.0051	0.0082
	SAC	0.0037	0.0018	0.0028

Tablo 15. İki faz arızasında eğitim verileri için ITAE performans ölçütü değerleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	SOS-PI	0.0087	0.0041	0.0064
	TD3	0.0114	0.013	0.012
	SAC	0.0061	0.0034	0.0048
0.4	SOS-PI	0.0095	0.0045	0.007
	TD3	0.0084	0.0097	0.0091
	SAC	0.0056	0.004	0.0048
0.5	SOS-PI	0.0082	0.004	0.0061
	TD3	0.0064	0.0061	0.0063
	SAC	0.0053	0.0046	0.005
0.6	SOS-PI	0.0072	0.0039	0.0056
	TD3	0.0048	0.0027	0.0038
	SAC	0.0048	0.0047	0.0048
0.7	SOS-PI	0.007	0.0035	0.0053
	TD3	0.0047	0.0022	0.0035
	SAC	0.0049	0.0037	0.0043
0.8	SOS-PI	0.0044	0.0024	0.0034
	TD3	0.012	0.0061	0.0091
	SAC	0.0042	0.0017	0.003


Tablo 16. Dengesiz arıza için optimize edilmiş PI parametre değerleri

SOS-PI	K_{pP}	K_{iP}	K_{pQ}	K_{iQ}
	4.04	409.62	2.3	242.8


Tek faz arıza için ortalama hata değerlerine bakıldığında SOS-PI denetleyici, $V_g = 0.3$ pu, 0.4 pu, 0.5 pu ve 0.6 pu arızalarında SAC ajanına göre sırasıyla %40.6, %43.3, %44.8 ve %12.8 iyileşme gösterirken TD3 ajanı, $V_g = 0.3$ pu, 0.4 pu ve 0.5 pu arızalarında SAC'a göre sırasıyla %40.6, %41.8 ve %41.8 iyileşme göstermiştir. $V_g = 0.7$ pu ve 0.8 pu arızalarında ise üstünlük SAC'a geçerek SOS-PI ve TD3'e göre sırasıyla %3.1, %69 ve %9.7, %65.9 iyileşme göstermiştir.

Benzer şekilde Tablo 15'teki iki faz arıza değerleri incelendiğinde SAC ajanı, $V_g = 0.3$ pu, 0.4 pu, 0.5 pu ve 0.8 pu arızalarında SOS-PI'a göre sırasıyla %25, %31.43, %18.03 ve %11.76 iyileşme gösterirken TD3'e göre sırasıyla %60, %47.25, %20.63 ve %67.03 iyileşme göstermiştir. $V_g = 0.6$ pu ve 0.7 pu arızalarında ise TD3 öne geçerek SOS-PI ve SAC'a göre sırasıyla %32.14, %20.83 ve %33.96, %18.6 iyileşme göstermiştir. Bununla birlikte t-test analizi, iki faz arızasında SAC ile SOS-PI kontrol yöntemleri arasındaki ITAE_{ort} performans farkının istatistiksel olarak anlamlı olduğunu ortaya koymuştur ($p = 0.006$).


Şekil 20-23 tek faz ve iki faz arızalarda en şiddetli 0.3 pu ve en hafif şiddetli 0.8 pu arızalarında şebeke aktif gücü, şebeke reaktif gücü, DA bara gerilimi ve şebeke akım yanıtlarını göstermektedir. Tablo 17 ve Tablo 18'de, tek faz ve iki faz arızalarda her bir denetleyici için elde edilen dinamik yanıtlar verilmiştir. Dengesiz arızada sistemin osilasyon miktarı artarak denetleyicilerin karar verme yapısını zorlaştırmış olup genelleme yeteneğini düşürmüştür. SAC ajanı, tek faz arıza için 0.6 pu ve 0.7 pu'da, iki faz arıza için 0.8 pu'da dinamik yanıt koşullarını karşılayamamıştır. Ayrıca 0.8 pu tek faz arızasında reaktif güçte kararlı durum hata sınırlarını (+%20,-%10) sağlayamamıştır. TD3 ajanı, tek faz arıza için 0.5 pu, 0.6 pu, 0.7 pu ve 0.8 pu'da, iki faz arıza için 0.6 pu ve 0.8 pu'da dinamik yanıt koşullarını karşılayamamıştır. Bunun yanında 0.3 pu, 0.4 pu ve 0.5 pu iki faz arızalarında reaktif güçte kararlı durum hata sınırlarını sağlayamamıştır. SOS-PI denetleyici ise 12 arızadan yalnızca optimizasyon koşulu olarak çalıştığı 0.3 pu tek faz arızasını genelleyebilmiştir.




Şekil 20. FV sistemin 0.3 pu dengesiz tek faz arıza için yanıtları



Şekil 21. FV sistemin 0.8 pu dengesiz tek faz arıza için yanıtları



Şekil 22. FV sistemin 0.3 pu dengesiz iki faz arıza için yanıtları



Şekil 23. FV sistemin 0.8 pu dengesiz iki faz arıza için yanıtları


Tablo 17. Tek faz arızasında eğitim verisi için aktif güç ve reaktif güç dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	SOS-PI	0.03	0.0374	0.012	0.0268
	TD3	0.03	0.037	0.019	0.0334
	SAC	0.0134	0.0472	0.017	0.0438
0.4	SOS-PI	0.0342	0.038	0.0116	0.0268
	TD3	0.03	0.059	0.0164	0.034
	SAC	0.013	0.0166	0.0172	0.0238
0.5	SOS-PI	0.0416	0.073	0.0118	0.0272
	TD3	0.036	0.1004	0.0152	0.0336
	SAC	0.0116	0.0378	0.0166	0.0348
0.6	SOS-PI	0.0386	0.1468	0.0114	0.0274
	TD3	0.0502	0.0538	0.0154	0.0352
	SAC	0.0056	0.0566	0.0104	0.1058
0.7	SOS-PI	0.041	0.1436	0.0114	0.028
	TD3	0.0802	0.0834	0.012	0.044
	SAC	0.0108	0.0672	0.0106	0.038
0.8	SOS-PI	0.0552	0.1482	0.0286	0.0478
	TD3	0.112	0.1136	0.0116	0.0450
	SAC	0.0052	0.0352	0.0102	0.0574

Tablo 18. İki faz arızasında eğitim verisi için aktif güç ve reaktif güç dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	SOS-PI	0.0736	0.1464	0.0164	0.0248
	TD3	0.0144	0.0168	0.0140	0.0180
	SAC	0.0196	0.0222	0.0198	0.0244
0.4	SOS-PI	0.0220	0.1482	0.0166	0.0482
	TD3	0.0208	0.0234	0.0146	0.0208
	SAC	0.0198	0.0224	0.0180	0.0226
0.5	SOS-PI	0.0204	0.1482	0.0158	0.0490
	TD3	0.0244	0.0270	0.0180	0.0272
	SAC	0.0204	0.0374	0.0172	0.0362
0.6	SOS-PI	0.0314	0.1478	0.0144	0.0482
	TD3	0.0224	0.1428	0.0170	0.1378
	SAC	0.0218	0.0242	0.0168	0.0216
0.7	SOS-PI	0.0316	0.1488	0.0136	0.1358
	TD3	0.0238	0.0432	0.0154	0.0314
	SAC	0.0114	0.0490	0.0140	0.0190
0.8	SOS-PI	0.0314	0.1472	0.0114	0.0256
	TD3	0.0502	0.0524	0.0126	0.0164
	SAC	0.0066	0.1166	0.0120	0.1036

Ayrıca Şekil 24'te genelleme yeteneği en yüksek olan SAC ajanının frekans tepkisi de incelenmiştir. Arıza sırasında frekans değeri, Almanya şebeke yönetmeliğinde belirtilen 47.5 Hz-51.5 Hz aralığında kalmıştır.




Şekil 24. SAC ajanı için dengesiz arıza frekans yanıtı


2.2.5. Transfer-DRL Sonuçlarının Karşılaştırılması

TD3 ve SAC ajanları dengesiz arıza için eğitildiğinde tüm arıza değerlerinde genelleme yapamadığından, transfer öğrenme yöntemiyle önceden dengeli olarak eğitilmiş ajanlar başlangıç noktası olarak kullanılmıştır. Eğitim ve ajan parametreleri iki yöntem için de dengeli arıza durumundakiyle aynıdır. Simülasyon durdurma koşulu olarak dengesiz arızada olduğu gibi $I_g > 1.5$ A ve $V_{DA} > 440$ V sınırları belirlenmiştir.

Dengeli ve dengesiz arızalardaki gibi eğitim sürecinde genelleme yeteneğini artırmak amacıyla farklı genlik değerlerinde (0.3 pu, 0.4 pu, 0.5 pu, 0.6 pu, 0.7 pu ve 0.8 pu) üç fazlı, iki fazlı ve tek fazlı arızalar uygulanmıştır. Elde edilen eğitim eğrileri Şekil 25'te gösterilmiştir. TD3'ün eğitimi yaklaşık 91 saat sürmüştür. Maksimum bölüm ödülü 5973'e ulaşmış ve ortalama ödülü 5794 olmuştur. SAC'ın eğitimi ise yaklaşık 104 saat sürmüştür. Maksimum bölüm ödülü 5946'ya ulaşmış, ortalama ödül 5472 değerine yakınsamıştır. Ortalama ödül değerlerinden görüldüğü gibi her iki ajan da öğrenme eğrisinde kararlı bir değere yakınsamaktadır. Ancak Transfer-SAC, Transfer-TD3'e göre daha hızlı öğrenmektedir. Ayrıca Transfer-TD3 ajanı tüm eğitim boyunca negatif ödüller alarak belirgin dalgalanmalar göstermiştir.



(a)



(b)


Şekil 25. Dengeli-dengesiz arızalar için transfer ajanlarına ait eğitim eğrileri

Test aşamasında, arıza sırasındaki dinamik tepkiyi analiz etmek için 2 saniyelik bir simülasyon çalıştırılmıştır. Arıza 0.5-0.65 saniye aralığında meydana gelecek şekilde ayarlanmıştır. Tek faz arıza için eğitim verisinin ITAE performans ölçütü sonuçları Tablo 19’da verilmiştir. $V_g = 0.3$ pu ve 0.4 pu arızalarında ortalama hata değerine bakıldığında Transfer-SAC, Transfer-TD3’e göre hata değerini sırasıyla %36.99 ve %38.89 azaltmıştır. $V_g = 0.5$ pu arızasında Transfer-SAC, Transfer-TD3’e göre %3.57 geriye düşmüştür. $V_g = 0.6$ pu, 0.7 pu ve 0.8 pu arızalarında ise Transfer-SAC tekrar öne geçerek sırasıyla %6.67, %59.76 ve %72.73 oranlarında hatayı azaltmıştır.


Tablo 19. Transfer-DRL için tek faz arızasında ITAE performans ölçütü değerleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	Transfer-TD3	0.0099	0.0047	0.0073
	Transfer-SAC	0.0058	0.0034	0.0046
0.4	Transfer-TD3	0.0094	0.005	0.0072
	Transfer-SAC	0.0054	0.0034	0.0044
0.5	Transfer-TD3	0.0074	0.0037	0.0056
	Transfer-SAC	0.0078	0.0038	0.0058
0.6	Transfer-TD3	0.0062	0.0028	0.0045
	Transfer-SAC	0.0053	0.0031	0.0042
0.7	Transfer-TD3	0.0107	0.0057	0.0082
	Transfer-SAC	0.004	0.0025	0.0033
0.8	Transfer-TD3	0.0115	0.006	0.0088
	Transfer-SAC	0.0033	0.0014	0.0024


Dengeli arızada olduğu gibi burada da 0.3 pu, 0.5 pu ve 0.7 pu arıza gerilim değerleri için şebeke aktif gücü, şebeke reaktif gücü, DA bara gerilimi ve şebeke akımı yanıtları Şekil 26-28 arasında gösterilmiştir. Transfer-SAC ajanı, tüm arıza değerlerinde hata tolerans aralığını ve akım-gerilim sınırlarını sağlamıştır. Transfer-TD3 ajanı ise yalnızca 0.3 pu arıza değeri için gerekli koşulları karşılayabilmiştir. Ayrıca, Transfer-TD3 ajanının arıza sonrası toparlanma süresi Transfer-SAC'a göre daha uzun sürmüştür.



Şekil 26. FV sistem için 0.3 pu tek faz arıza Transfer-DRL yanıtları



Şekil 27. FV sistem için 0.5 pu tek faz arıza Transfer-DRL yanıtları




Şekil 28. FV sistem için 0.7 pu tek faz arıza Transfer-DRL yanıtları

Tablo 20’de verilen tek faz arıza dinamik yanıtlarında tüm arıza değerlerinin ortalamasına bakıldığında, Transfer-SAC aktif güç için t_r ve t_s sürelerinde sırasıyla %18.83 ve %60.63 daha hızlı yanıt vermiştir. Reaktif güç için t_s süresinde %72.45 daha hızlı, t_r süresinde ise %15.05 daha yavaş yanıt vermiştir. Transfer-TD3 ajanı yalnızca 0.3 pu ve 0.6 pu arıza değerlerinde t_r ve t_s sürelerini sağlayabilmiştir.

Tablo 20. Transfer-DRL için tek faz arızasında aktif güç ve reaktif güç dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	Transfer-TD3	0.0132	0.0172	0.0120	0.06
	Transfer-SAC	0.0142	0.0376	0.0120	0.0376
0.4	Transfer-TD3	0.0136	0.1450	0.0128	0.1484
	Transfer-SAC	0.0136	0.0584	0.0114	0.0380
0.5	Transfer-TD3	0.0124	0.1448	0.0112	0.1476
	Transfer-SAC	0.0132	0.0168	0.0122	0.0182
0.6	Transfer-TD3	0.0138	0.0582	0.0112	0.0540
	Transfer-SAC	0.0122	0.0568	0.0114	0.0286
0.7	Transfer-TD3	0.0380	0.1258	0.0110	0.1456
	Transfer-SAC	0.0122	0.0448	0.0112	0.0276
0.8	Transfer-TD3	0.0046	0.1156	0.0016	0.0868
	Transfer-SAC	0.0122	0.0244	0.0106	0.0270

Son olarak, düşük ortalama hata değerine sahip Transfer-SAC ajanının frekans tepkisi incelenmiştir. Şekil 29’da görüldüğü üzere, frekans arıza sırasında 47.5 Hz-51.5 Hz sınır aralığında kalmıştır.



Şekil 29. Transfer-SAC ajanına ait tek faz arıza frekans yanıtı

Aynı ajanlar için iki faz arızası da incelenmiş olup eğitim ve test verileri için ITAE performans ölçütü sonuçları Tablo 21 ve Tablo 22’de verilmiştir.

Eğitim verileri sonuçlarında, $V_g = 0.3$ pu arızasında iki ajan da aynı performansı göstermiştir.

$V_g = 0.4$ pu ve 0.5 pu arızalarında Transfer-SAC, Transfer-TD3’e göre sırasıyla %5.13 ve %10 geri kalmıştır.

$V_g = 0.6$ pu, 0.7 pu ve 0.8 pu arızalarında Transfer-SAC, Transfer-TD3’e göre sırasıyla %31.67, %15.79 ve %55.71 iyileşme göstermiştir.

Test verileri sonuçlarında ise $V_g = 0.35$ pu arızasında iki ajan aynı performansı göstermiştir.

$V_g = 0.45$ pu ve 0.55 pu arızalarında Transfer-SAC, Transfer-TD3’e göre %7.5 geri kalmıştır.

$V_g = 0.65$ pu ve 0.75 pu arızalarında ise Transfer-SAC sırasıyla %19.57 ve %13.51 iyileşme göstermiştir.

Tablo 21. Transfer-DRL için iki faz arızasında eğitim verileri ITAE performans ölçütü


V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	Transfer-TD3	0.0046	0.0028	0.0037
	Transfer-SAC	0.0045	0.0029	0.0037
0.4	Transfer-TD3	0.0054	0.0023	0.0039
	Transfer-SAC	0.005	0.0031	0.0041
0.5	Transfer-TD3	0.0055	0.0023	0.004
	Transfer-SAC	0.0053	0.0034	0.0044
0.6	Transfer-TD3	0.0084	0.0034	0.006
	Transfer-SAC	0.0048	0.0033	0.0041
0.7	Transfer-TD3	0.0053	0.0022	0.0038
	Transfer-SAC	0.0039	0.0024	0.0032
0.8	Transfer-TD3	0.0093	0.0046	0.007
	Transfer-SAC	0.0041	0.002	0.0031

Tablo 22. Transfer-DRL için iki faz arızasında test verileri için ITAE performans ölçütü


V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.35	Transfer-TD3	0.0049	0.0025	0.0037
	Transfer-SAC	0.0048	0.0026	0.0037
0.45	Transfer-TD3	0.0056	0.0023	0.004
	Transfer-SAC	0.0051	0.0035	0.0043
0.55	Transfer-TD3	0.006	0.002	0.004
	Transfer-SAC	0.0054	0.0031	0.0043
0.65	Transfer-TD3	0.0068	0.0024	0.0046
	Transfer-SAC	0.0045	0.0028	0.0037
0.75	Transfer-TD3	0.0048	0.0026	0.0037
	Transfer-SAC	0.0043	0.002	0.0032

Şekil 30-32 iki faz arızalarında elde edilen şebeke aktif gücü, şebeke reaktif gücü, DA bara gerilimi ve şebeke akımı yanıtlarını göstermektedir. Her iki ajan da tüm arızalar için hata tolerans aralıklarını ve akım-gerilim sınırlarını karşılamaktadır. Ancak özellikle 0.7 pu


arızasında görüldüğü gibi Transfer-TD3 ajanı, arıza sırasında fazla osilasyon yapmakta ve bu durum arıza sonrası toparlanma süresini geciktirmektedir.



Şekil 30. FV sistem için 0.3 pu iki faz arıza Transfer-DRL yanıtları



Şekil 31. FV sistem için 0.5 pu iki faz arıza Transfer-DRL yanıtları



Şekil 32. FV sistem için 0.7 pu iki faz arıza Transfer-DRL yanıtları

Tablo 23'teki iki faz arıza dinamik yanıtlarında, tüm arıza değerlerinin ortalamasına bakıldığında aktif güç için t_r ve reaktif güç için t_s sürelerinde Transfer-SAC sırasıyla %19.08 ve %1.72 daha hızlı yanıt verirken, aktif güç için t_s ve reaktif güç için t_s sürelerinde sırasıyla %17.51 ve %32.08 yavaş kalmıştır.

Tablo 24'teki test verisi dinamik yanıtlarında ise aktif güç için t_r , t_s ve reaktif güç için t_r sürelerinde Transfer-SAC sırasıyla %5.96, %17.15 ve %4.52 daha hızlı yanıt verirken, reaktif güç için t_s 'de %31.58 yavaş kalmıştır. Ayrıca Transfer-TD3 ajanı, 0.75 pu arızasında aktif gücün t_s kriterini karşılayamamıştır.


Tablo 23. Transfer-DRL için iki faz arızasında eğitim verileri dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	Transfer-TD3	0.0160	0.0188	0.0146	0.0174
	Transfer-SAC	0.0138	0.0314	0.0142	0.0278
0.4	Transfer-TD3	0.0166	0.0196	0.0142	0.0170
	Transfer-SAC	0.0142	0.0326	0.0142	0.0284
0.5	Transfer-TD3	0.0148	0.0176	0.0144	0.0170
	Transfer-SAC	0.0144	0.0336	0.0142	0.0322
0.6	Transfer-TD3	0.0126	0.0234	0.0134	0.0158
	Transfer-SAC	0.0140	0.0354	0.0138	0.0334
0.7	Transfer-TD3	0.0142	0.0496	0.0140	0.0436
	Transfer-SAC	0.0136	0.0304	0.0136	0.0274
0.8	Transfer-TD3	0.0274	0.0478	0.0132	0.0276
	Transfer-SAC	0.0122	0.0444	0.0124	0.0336

Tablo 24. Transfer-DRL için iki faz arızasında test verileri dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.35	Transfer-TD3	0.0152	0.0180	0.0140	0.0168
	Transfer-SAC	0.0140	0.0306	0.0140	0.0280
0.45	Transfer-TD3	0.0152	0.0182	0.0144	0.0170
	Transfer-SAC	0.0144	0.0330	0.0144	0.0284
0.55	Transfer-TD3	0.0142	0.0170	0.0140	0.0164
	Transfer-SAC	0.0140	0.0352	0.0134	0.0340
0.65	Transfer-TD3	0.0140	0.0166	0.0138	0.0160
	Transfer-SAC	0.0136	0.0590	0.0134	0.0336
0.75	Transfer-TD3	0.0152	0.1460	0.0146	0.0478
	Transfer-SAC	0.0134	0.0210	0.0124	0.0260

İki faz arızasında da Transfer-SAC ajanının frekans tepkisi, Şekil 33'te gösterildiği gibi 47.5-51.5 Hz aralığında kalmıştır.




Şekil 33. Transfer-SAC ajanına ait iki faz arıza frekans yanıtı

2.3. Maksimum Güç Noktası Takibi

Bu bölümde, FV sistemde MPPT için geleneksel yöntemlerden P&O algoritması ile bu tez kapsamında önerilen SAC algoritması karşılaştırılmıştır. Tüm senaryolarda sıcaklık 25 °C’ de sabit tutulmuştur. İlk olarak 1000 W/m², 800 W/m², 600 W/m² ve 400 W/m² güneş ışınımı değerleri için homojen gölgelenme senaryosu statik durumda uygulanmıştır. Ayrıca, homojen gölgelenme koşulları altında güneş ışınımının dinamik değişimi incelenmiştir.


2.3.1. P&O Algoritmasının MPPT İçin Uygulanması

P&O algoritması, MPPT için literatürde yaygın kullanılan geleneksel yöntemlerden biridir. Algoritmanın akış diyagramı Şekil 34’te verilmiştir. Yöntem, D ’nin adım değişikliği ile maksimum güç elde edilmesine dayanır.



Şekil 34. P&O algoritması akış diyagramı


Şekil 35'te verilen P&O tabanlı MPPT kontrolü sabit adımlı yapılmıştır. D 'nin başlangıç değeri 0.47, alt limiti 0.45, üst limiti 0.65 ve ΔD değeri $200e^{-6}$ olarak belirlenmiştir.




Şekil 35. P&O tabanlı MPPT denetleyici sistemi

2.3.2. SAC Algoritmasının MPPT İçin Uygulanması

Bu tez kapsamında LVRT için önerilen SAC algoritması, MPPT kontrolü için de Şekil 36 ve Şekil 37'de gösterildiği gibi uygulanmıştır. MPPT için tanımlanan gözlem uzayı Tablo 25'te verilmiştir. D 'nin başlangıç değeri, P&O algoritmasında olduğu gibi 0.47 alınmıştır. Aksiyon uzayı olarak ΔD değişim miktarı alınmış olup $[0, 0.4]$ aralığında bir değer almaktadır. Ajanın öğrenmesi için her adımda geri döndürülen ödül fonksiyonu ise eşitlik (64)'te verilmiştir.



Şekil 36. DRL ile FV sistemde MPPT kontrolü blok diyagramı



Şekil 37. MPPT kontrolü için kullanılan çevre blok diyagramı

Tablo 25. MPPT için SAC denetleyici gözlem uzayı

Sembol	Açıklama	Boyut
V_{fv}	FV dizin gerilimi	1
I_{fv}	FV dizin akımı	1
eP_{fv}	FV dizin güç hatası	1
ΔD	D adım değişikliği	1
D	Dönüştürücü doluluk-boşluk oranı	1

$$r_{tmp} = -0.1eP_{fv}^2 + 2H_{Pfv} + 5H_{Pfv} \quad (64)$$

eP_{fv} , eşitlik (65)'te tanımlanan FV dizinin güç hatasını temsil eder. Bu parametre, değişen güneş ışınımında güç takibi başarısız olduğunda ödül fonksiyonuna ceza oluşturmak için kullanılır.

$$eP_{fv} = P_{fv}^* - P_{fv} \quad (65)$$

H_{Pfv} , eşitlik (66)'da verildiği gibi ödül fonksiyonundaki güç hatasını azaltmayı teşvik eden lojik terimdir. Hata sınırları 0.1 ve 0.05 olarak belirlenmiş ve ajanı motive etmek için kademeli bir ödül yapısı kullanılmıştır.

$$\begin{aligned}
H_{p_{fv}} &= \begin{cases} 0 & e_{p_{fv}}^2 > 0.01 \\ 1 & e_{p_{fv}}^2 \leq 0.01 \end{cases} \\
H_{p_{fv}} &= \begin{cases} 0 & e_{p_{fv}}^2 > 0.003 \\ 1 & e_{p_{fv}}^2 \leq 0.003 \end{cases}
\end{aligned} \tag{66}$$

Tablo 26, ajanın eğitimi için gerekli parametreleri ve bu çalışmada kullanılan değerleri göstermektedir.

Tablo 26. MPPT için SAC eğitim parametreleri


Parametreler	Değerleri
Örnekleme zamanı (T_s)	0.002 s
Simülasyon zamanı (T_f)	2 s
Maksimum adım sayısı (T_f/T_s)	1000
Maksimum bölüm sayısı	20000
Ortalama pencere uzunluğu	250
Eğitim durdurma kriteri/değeri	Maksimum bölüm sayısı/20000
Ajan kaydetme kriteri/değeri	Bölüm ödülü/6700

2.3.3. Yöntemlerin Karşılaştırılması

Yöntemlerin karşılaştırılmasında ilk olarak MPPT analizi için statik durumda 4 farklı homojen ışınlam değeri uygulanmıştır. Tablo 26'daki eğitim parametreleri ve Tablo 27'deki ajan parametreleri kullanılarak FV sistemde MPPT kontrolü için SAC ajanı eğitilmiş olup eğitim eğrisi Şekil 38'de gösterilmiştir. Eşitlik (64)'teki ödül fonksiyonuna göre ajanın alabileceği maksimum ödül değeri 7000'dir. Eğitim sonucunda elde edilen maksimum ödül 6932 olmuştur. Yakınsama sağlandıktan sonra eğitim durdurulmuştur. Yaklaşık 51 saat süren eğitimde en iyi ajanın denetleyici performansı P&O algoritması ile karşılaştırılmıştır.


Tablo 27. MPPT için SAC ajanına ait parametreler

Parametreler	Değerleri
Aktör için öğrenme hızı	$1e^{-3}$
Kritik için öğrenme hızı	$1e^{-3}$
Azaltma faktörü	0.99
Yumuşak hedef güncelleme katsayısı	$5e^{-3}$
Bellek boyutu	$1e^6$
Mini-paket boyutu	256
Hedef entropi değeri	-3
Politika güncelleme frekansı	2
Hedef güncelleme frekansı	2



Şekil 38. MPPT için SAC ajanına ait eğitim eğrisi

Her bir güneş ışıınım değeri için elde edilen güç değerleri Şekil 39'da, güç verimliliği, maksimum güç noktasına ulaşma hızı ve sürekli durum hata performans ölçütleri Tablo 28'de verilmiştir. Sürekli durum hatası için performans ölçütü olarak ITAE kullanılmıştır. Elde edilen sonuçlara göre, statik durumda homojen ışıınım altında iki algoritma güç verimliliği açısından yakın performans göstermektedir. MPP'ye ulaşma hızı açısından, 1000 W/m^2 , 800 W/m^2 , 600 W/m^2 değerlerinde SAC algoritması P&O'ya göre sırasıyla %84.53, %86.26, %75.32 iyileşme sağlamıştır. Ancak 400 W/m^2 değerinde P&O algoritması SAC'a göre %45.38 daha iyi performans göstermiştir. Güç değeri için elde edilen hata değerlerinin ortalaması incelendiğinde, SAC ile P&O'ya kıyasla %30.77 daha düşük hata elde edilmiştir.




Şekil 39. Statik durumda homojen ışınlam altında elde edilen maksimum güç değerleri

Tablo 28. Statik durumda homojen ışınlam altında MPPT için performans ölçütleri

Güneş ışınlamı	MPPT algoritması	Teorik güç (kW)	Elde edilen güç (kW)	Güç izleme verimliliği (%)	İzleme hızı (s)	ITAE _{Ppv}
1000 W/m ²	SAC	0.738	0.738	100	0.0258	0.0013
	P&O	0.738	0.7378	99.97	0.1668	0.0037
800 W/m ²	SAC	0.590	0.59	100	0.0229	0.0012
	P&O	0.590	0.59	100	0.1667	0.0023
600 W/m ²	SAC	0.441	0.441	100	0.0349	0.0003
	P&O	0.441	0.441	100	0.1414	0.001
400 W/m ²	SAC	0.291	0.2898	99.58	0.0943	0.0026
	P&O	0.291	0.291	100	0.0515	0.0008

İkinci senaryoda, statik durumda eğitilmiş SAC ajanı ve P&O algoritması güneş ışınlamının zamana bağlı değişimi için incelenmiştir. Simülasyon toplamda 2 saniye sürerken, 0.5-0.65 saniye aralığında önceki senaryodaki 4 farklı güneş ışınlam değeri uygulanmıştır. Elde edilen güç grafikleri Şekil 40'ta gösterilmiştir. Sürekli durum hata performans ölçütleri ise Tablo 29'da verilmiştir. Sonuçlara göre SAC, ortalama hatada P&O'dan %59.43 daha iyi performans göstermiştir.



Şekil 40. Homojen güneş ışıınının dinamik değişiminde maksimum güç değerleri


Tablo 29. Dinamik değişen homojen ışıının altında performans ölçütleri

Güneş ışıınını	Denetleyici	ITAE _{Ppv}
1000 W/m ²	SAC	0.0013
	P&O	0.0037
800 W/m ²	SAC	0.0033
	P&O	0.0054
600 W/m ²	SAC	0.0053
	P&O	0.0074
400 W/m ²	SAC	0.0073
	P&O	0.0259


2.4. FV Sistemin Dayanıklılığının Artırılması

Bu tez kapsamında önerilen modelin gerçek zamanlı uygulamada dayanıklılığını artırmak için LVRT yeteneği ile gölgelenme durumu birlikte ele alınmıştır. Gölgeleme durumunda, önceden eğitilmiş SAC ajanı ve P&O algoritması FV dizinden gelen gücün değişimini kontrol etmektedir. Arıza sırasında bu gücün değişimine adapte olabilmek için SAC, dengeli arıza durumunda Bölüm 2.2.3'te anlatıldığı gibi tekrar eğitilmiştir. Eğitim ve

ajan parametreleri Tablo 6 ve Tablo 8 ile aynıdır. Elde edilen eğitim eğrileri Şekil 41’de gösterilmiştir.



(a)



(b)

Şekil 41. Gölgeleme varken SAC ajanı dengeli arıza eğitim eğrileri

Test aşamasında toplamda 2 saniye çalışan simülasyonda, 0.5-0.65 saniye arasında hem homojen gölgeleme hem dengeli arıza uygulanmıştır. Elde edilen sonuçlarda her bir

gün ışığı ve arıza değeri için ITAE hata değeri hesaplanırken FV dizin güç hatası, şebeke aktif gücü hatası ve şebeke reaktif gücü hatasının ortalama değerleri alınmış olup ITAE performans ölçütü sonuçları Tablo 30'da verilmiştir. Ortalama hata değerlerine bakıldığında, SAC ajanı P&O'ya kıyasla hatayı %56.47 oranında azaltmıştır. Her bir gün ışığı değeri için arıza değerlerinin dinamik yanıtlarının ortalaması ise Tablo 31'de sunulmuştur. Elde edilen sonuçlara göre;

400 W/m² değerinde SAC, P&O'ya göre aktif güç t_r , t_s ve reaktif güç t_s süreleri için sırasıyla %8.13, %1.02 ve %48.1 hızlı yanıt verirken, reaktif güç t_r 'de %1.39 yavaş kalmıştır.

600 W/m² değerinde SAC, P&O'ya göre aktif güç t_r , t_s ve reaktif güç t_r süreleri için sırasıyla %10.34, %9.52 ve %13.64 hızlı yanıt verirken, reaktif güç t_s 'de %20.57 yavaş kalmıştır.

800 W/m² değerinde SAC, P&O'ya göre aktif güç t_r , t_s ve reaktif güç t_s süreleri için sırasıyla %6.29, %6.19 ve %23.77 hızlı yanıt verirken, reaktif güç t_r 'de %5.79 yavaş kalmıştır.

Son olarak, 1000 W/m² değerinde SAC, P&O'ya göre aktif güç t_r ve reaktif güç t_r , t_s süreleri için sırasıyla %7.27, %16.06 ve %4.76 yavaş yanıt verirken, aktif güç t_s 'de %5.51 hızlı yanıt vermiştir.

Tablo 30. Gölgeleme ve dengeli arıza altında ITAE performans ölçütleri


V _g (pu)	Denetleyici	400 W/m ²	600 W/m ²	800 W/m ²	1000 W/m ²	Ort.
		ITAE				
0.3	P&O	0.0171	0.0063	0.0055	0.0047	0.0084
	SAC	0.0047	0.0037	0.0033	0.0023	0.0035
0.4	P&O	0.0172	0.0064	0.0057	0.0049	0.0086
	SAC	0.0047	0.0038	0.0037	0.0024	0.0036
0.5	P&O	0.0172	0.0068	0.0062	0.0054	0.0089
	SAC	0.0049	0.0043	0.0038	0.0027	0.0039
0.6	P&O	0.0169	0.0062	0.0065	0.0052	0.0087
	SAC	0.0047	0.0042	0.0035	0.0027	0.0038
0.7	P&O	0.0168	0.0059	0.0054	0.005	0.0083
	SAC	0.005	0.0039	0.0035	0.0025	0.0037
0.8	P&O	0.0171	0.0061	0.0053	0.0047	0.0083
	SAC	0.0049	0.0034	0.0029	0.0023	0.0034

Tablo 31. Gölgeleme ve dengeli arıza altında dinamik yanıtlar

G (W/m ²)	Denetleyici	P		Q	
		t_{rort} (s)	t_{sort} (s)	t_{rort} (s)	t_{sort} (s)
400	P&O	0.016	0.0196	0.0072	0.079
	SAC	0.0147	0.0194	0.0073	0.041
600	P&O	0.0174	0.021	0.011	0.0282
	SAC	0.0156	0.019	0.0095	0.034
800	P&O	0.0175	0.021	0.0121	0.0265
	SAC	0.0164	0.0197	0.0128	0.0202
1000	P&O	0.0165	0.0254	0.0137	0.0231
	SAC	0.0177	0.024	0.0159	0.0242

Genelleme yeteneği açısından SAC, hem gölgeleme hem dengeli arıza durumu koşullarının tümünü genelleylebilmiştir. Ancak P&O algoritması, 400 W/m²'de Q değerleri için t_s süre sınırını sağlayamamıştır.


Dengesiz arıza durumunun incelenmesi için Transfer-SAC ajanı kullanılarak dengeli ve dengesiz arızalarda gölgelenme durumu birlikte ele alınmıştır. Gölgeleme durumunda önceden eğitilmiş SAC ajanı, FV dizinden gelen gücün değişimini kontrol etmektedir. Arıza sırasında bu gücün değişimine adapte olabilmek için Transfer-SAC ajanı, Bölüm 2.2.5'te anlatıldığı gibi dengeli ve dengesiz arıza durumlarında tekrar eğitilmiştir. Eğitim ve ajan parametreleri Tablo 6 ve Tablo 8 ile aynıdır. Elde edilen eğitim eğrisi Şekil 42'de gösterilmiştir.




Şekil 42. Gölgeleme durumunda Transfer-SAC dengeli-dengesiz arıza eğitim eğrisi

Test aşamasında toplamda 2 saniye çalışan simülasyonda, 0.5-0.65 saniye arasında hem homojen gölgelenme hem dengeli ve dengesiz arızalar uygulanmıştır. Şekil 43-45 arasında 400 W/m^2 için en şiddetli arıza olan 0.3 pu'nun dengeli ve dengesiz arızalara verdiği yanıtlar gösterilmiştir. Önceden eğitilmiş SAC ajanı, üç arıza durumunda da FV dizin gücünü takip edebilmiş ve DA bara gerilim sınırını korumuştur. Ancak Transfer-SAC ajanı, dengeli ve tek faz dengesiz arıza durumlarında aktif güçte kararlı durum hata sınırını (+%20, -%10) sağlayamamıştır. Sonuçlarda, her bir gün ışığı ve arıza değeri için ITAE hata değeri hesaplanırken FV dizin güç hatası, şebeke aktif gücü hatası ve şebeke reaktif gücü hatasının ortalama değerleri alınmıştır. ITAE performans ölçütü sonuçları Tablo 32'de verilmiştir. Her bir gün ışığı değeri için arıza değerlerinin dinamik yanıtlarının ortalaması ise Tablo 33'te


verilmiştir. Elde edilen sonuçlara göre, toplamda 72 değerden 21’inde aktif ve reaktif güçlerin kararlı durum hata sınırları ve dinamik yanıtları sağlanamamıştır.



Şekil 43. FV sistemin hem gölgelenme hem arıza altında 0.3 pu dengeli arıza yanıtları



Şekil 44. FV sistemin hem gölgelenme hem arıza altında 0.3 pu iki faz arıza yanıtları



Şekil 45. FV sistemin hem gölgelenme hem arıza altında 0.3 pu tek faz arıza yanıtları


Tablo 32. Hem gölgelenme hem arıza altında FV sistemin ITAE performans ölçütleri

V _g (pu)	Denetleyici	400 W/m ²	600 W/m ²	800 W/m ²	1000 W/m ²	Ort.
		ITAE				
0.3	Transfer-SAC	0.0055	0.0039	0.0036	0.0032	0.0041
0.4	Transfer-SAC	0.006	0.0043	0.0035	0.0031	0.0042
0.5	Transfer-SAC	0.0063	0.0047	0.0037	0.0033	0.0045
0.6	Transfer-SAC	0.0065	0.0045	0.0032	0.0024	0.0042
0.7	Transfer-SAC	0.0065	0.0048	0.0036	0.0028	0.0044
0.8	Transfer-SAC	0.0081	0.0053	0.0033	0.0024	0.0048

Tablo 33. Hem gölgelenme hem arıza altında FV sistemin dinamik yanıtları

G (W/m ²)	Denetleyici	P		Q	
		t_{rort} (s)	t_{sort} (s)	t_{rort} (s)	t_{sort} (s)
400	Transfer-SAC	0.0152	0.0192	0.0143	0.05
600	Transfer-SAC	0.0156	0.0194	0.0117	0.033
800	Transfer-SAC	0.016	0.0218	0.0128	0.0291
1000	Transfer-SAC	0.0157	0.0241	0.014	0.0293

Son olarak, Transfer-SAC ajanı ile yapılmış bu eğitim kısmi gölgelenme durumu için test edilmiştir. Kısmi gölgelenme senaryosu olarak seri bağlı 4 panelden 3'üne 400 W/m², birine 600 W/m² uygulanmıştır. Elde edilen P-V eğrisi Şekil 46'da gösterilmiştir. Şekilden görüldüğü gibi bir yerel bir küresel MPP noktası oluşmuştur ve küresel MPP değeri 0.3 kW'tır. Bu senaryo için dengeli arızada elde edilen ITAE performans ölçütleri ve dinamik yanıtlar sırasıyla Tablo 34 ve Tablo 35'te verilmiştir. Önceden eğitilmiş SAC ajanı Şekil 47'de görüldüğü gibi FV dizin gücünü takip edebilmiştir. Transfer-SAC ajanı da 0.3 pu dengeli arıza koşullarını sağlamıştır.




Şekil 46. Kısmi gölgelenme altında P-V eğrisi

Tablo 34. Kısmi gölgelenme ve dengeli arızada ITAE performans ölçütleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{Ppv}	ITAE _{ort}
0.3	Transfer-SAC	0.0064	0.0021	0.0074	0.0037
0.4	Transfer-SAC	0.0069	0.0027	0.0074	0.0037
0.5	Transfer-SAC	0.0073	0.0029	0.0074	0.0037
0.6	Transfer-SAC	0.0079	0.0025	0.0074	0.0037
0.7	Transfer-SAC	0.0071	0.0024	0.0074	0.0037
0.8	Transfer-SAC	0.0056	0.0018	0.0074	0.0037

Tablo 35. Kısmi gölgelenme ve dengeli arızada dinamik yanıtlar


V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	Transfer-SAC	0.0148	0.0176	0.0054	0.0432
0.4	Transfer-SAC	0.0164	0.0196	0.0092	0.041
0.5	Transfer-SAC	0.0178	0.0214	0.0218	0.039
0.6	Transfer-SAC	0.016	0.0196	0.0208	0.0358
0.7	Transfer-SAC	0.014	0.0176	0.0212	0.0342
0.8	Transfer-SAC	0.014	0.024	0.0246	0.0488



Şekil 47. Kısmi gölgelenme ve dengeli arıza altında FV sistemin yanıtları

2.5. Şebeke Parametrelerinin Değişimi

Bu tez kapsamında güçlü şebeke modeli olarak ele alınan sistemin zayıf şebeke üzerindeki etkisini görebilmek için SCR değeri değiştirilmiştir. (Swandaru, 2020) çalışmasında, Almanya şebeke yönetmeliğine göre SCR değerinin 6'dan az olması durumunun zayıf şebeke olarak tanımlandığı belirtilmiştir. Bu nedenle zayıf şebeke modellemesi için SCR değeri 6 alınarak şebeke parametreleri $R_h = 3.44 \Omega$ ve $L_h = 0.077 \text{ H}$ olarak hesaplanmıştır. En şiddetli arıza türü olan dengeli arıza için eğitilmiş SAC ajanı bu sistemde test edilmiş ve elde edilen gerilim iyileşme miktarları Şekil 48 ve Tablo 36'da verilmiştir. Zayıf şebekede eviricinin reaktif akım desteğinin, güçlü şebekeye kıyasla şebeke gerilimine daha duyarlı olduğu gözlemlenmiştir. Tablo 37 ve Tablo 38'de sırasıyla zayıf şebeke için elde edilen ITAE performans ölçütleri ve dinamik yanıtlar sunulmuştur. Sonuçlara göre toplam hata değeri güçlü şebekede 0.0033 iken, zayıf şebekede 0.0063'e yükselmiştir. Ayrıca 0.3 pu ve 0.4 pu şiddetindeki arızalarda reaktif güç için kararlı durum hata sınırları (+%20, -%10) sağlanamamıştır.



Şekil 48. Dengeli arıza için güçlü ve zayıf şebekelerde gerilim iyileşme yanıtları

Tablo 36. Dengeli arıza için güçlü ve zayıf şebekelerde gerilim iyileşme değerleri

V_g (pu)	Denetleyici	Güçlü şebeke (%)	Zayıf şebeke (%)
0.3	SAC	8.33	42
0.4	SAC	6.4	32
0.5	SAC	5	25
0.6	SAC	3.7	18.17
0.7	SAC	2.57	12
0.8	SAC	1.85	8.4

Tablo 37. Zayıf şebekede dengeli arıza için ITAE performans ölçüt değerleri


V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	SAC	0.0060	0.0089	0.0075
0.4	SAC	0.0059	0.0084	0.0072
0.5	SAC	0.0063	0.0075	0.0069
0.6	SAC	0.006	0.0068	0.0064
0.7	SAC	0.0053	0.0051	0.0052
0.8	SAC	0.0047	0.004	0.0044

Tablo 38. Zayıf şebekede dengeli arıza için aktif ve reaktif güçlerin dinamik yanıtları

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	SAC	0.0134	0.0162	0.0212	0.0236
0.4	SAC	0.0144	0.0174	0.0196	0.0222
0.5	SAC	0.0158	0.0190	0.0182	0.021
0.6	SAC	0.0152	0.0182	0.0166	0.0196
0.7	SAC	0.015	0.0312	0.0162	0.019
0.8	SAC	0.0178	0.0208	0.0144	0.0272


2.6. Önerilen Sistemin Gerçek Zamanlı Testi

Bu tez çalışmasında önerilen DRL tabanlı LVRT sisteminin gerçek zamanlı etkisini incelemek için Şekil 49’da gösterilen RT-LAB döngü içi yazılım (software-in-the-loop) platformu kullanılmıştır. Platform, Opal-RT 4512 gerçek zamanlı simülatör cihazı ve bir bilgisayardan oluşmaktadır. Opal-RT 4512, Linux 3.5.4 işletim sistemi, Intel Xeon E3-1240 V6 Quad-çekirdekli 3.7 GHz CPU, 4 çekirdekli, 16 GB hafızaya sahip, 100-240 V, 60-50 Hz aralığına uyumlu bir gerçek zamanlı simülatördür.



Şekil 49. FV sistemin gerçek zamanlı modellenmesine ait test ortam fotoğrafı


RT-LAB programı Matlab/Simulink arayüzü ile uyumludur ve önceden tasarlanan sistem doğrudan bu ortama aktarılmıştır. Sistemin gerçek zamanlı çalışması için Şekil 50’de gösterildiği gibi hesaplama ve grafiksel kısımlar için iki alt sistem oluşturulmuştur. Bu sistemler arasındaki haberleşme opcomm bloğu ile sağlanmıştır.




Şekil 50. RT-LAB uyumlu sistem modeli

DRL tabanlı sistemin gerçek zamanlı çalışmasını test etmek için Transfer-SAC kullanılarak önceden eğitilmiş ajan Şekil 51’deki gibi modellenmiştir. Opal-RT simülatörü

RL kütüphanesini desteklemediğinden, eğitilmiş ajanın politikası DL kütüphanesindeki tahmin (predict) bloğu ile elde edilmiştir. En şiddetli arıza türü olan dengeli arızada 0.3 pu ve 0.4 pu değerleri için elde edilen aktif ve reaktif güç yanıtları Şekil 52’de gösterilmiştir. Bu arıza değerleri için elde edilen ITAE hata değerleri ise Tablo 39’da sunulmuştur. Transfer-SAC ajanının simülasyon sonuçları ve gerçek zamanlı sonuçlarındaki ortalama hata değerleri karşılaştırıldığında, 0.3 pu ve 0.4 pu arıza değerleri için ajan gerçek zamanlı çalışmaya göre sırasıyla %16.28 ve %21.74 daha iyi performans göstermiştir.



Şekil 51. Hesaplama (SM) alt sistem modeli



Şekil 52. Dengeli arıza için Transfer-SAC gerçek zamanlı çalışma yanıtları

Tablo 39. Simülasyon ve gerçek zamanlı çalışma için ITAE performans ölçüt değerleri

V_g (pu)	Denetleyici	ITAE _P	ITAE _Q	ITAE _{ort}
0.3	Transfer-SAC	0.0044	0.0027	0.0036
	Transfer-SAC-RT	0.0061	0.0025	0.0043
0.4	Transfer-SAC	0.0043	0.0029	0.0036
	Transfer-SAC-RT	0.0063	0.0029	0.0046

Tablo 40'ta verilen dinamik yanıt sonuçlarına bakıldığında, 0.3 pu dengeli arızada aktif güç için t_r , t_s ve reaktif güç için t_r ve t_s 'de Transfer-SAC, gerçek zamanlı çalışmaya göre sırasıyla %1.3, %1.1 ve %51.85, %73 daha yavaş kalmıştır. 0.4 pu dengeli arızasında ise aktif güç için t_r , t_s ve reaktif güç için t_s 'de Transfer-SAC, gerçek zamanlı çalışmaya göre sırasıyla %2.5, %0.52 ve %3.32 daha yavaşken, reaktif güç için t_r 'de %12.63 daha hızlıdır.

Tablo 40. Simülasyon ve gerçek zamanlı çalışma için dinamik yanıtlar

V_g (pu)	Denetleyici	P		Q	
		t_r (s)	t_s (s)	t_r (s)	t_s (s)
0.3	Transfer-SAC	0.0156	0.0184	0.0164	0.0218
	Transfer-SAC-RT	0.0154	0.0182	0.0108	0.0126
0.4	Transfer-SAC	0.0164	0.0194	0.0166	0.0218
	Transfer-SAC-RT	0.016	0.0193	0.019	0.0211

3. SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında, yenilenebilir enerji kaynakları arasında önemli bir gelecek vaat eden FV sistemlerin şebeke entegrasyonunda enerji sürekliliğini sağlamak için öğrenme tabanlı denetleyiciler geliştirilmiştir. Bu amaçla, iki aşamalı üç fazlı şebeke bağlantılı FV sistem Matlab/Simulink ortamında modellenmiştir.

FV sistemin arıza sırasında şebeke ile bağlantısını sürdürerek gerilim desteği sağlaması kritik öneme sahiptir. Bu nedenle LVRT yeteneğini geliştirmek için DRL tabanlı denetleyiciler kullanılmıştır. DDPG, TD3 ve SAC yöntemleri ile DDPG, TD3, SAC, Transfer-TD3 ve Transfer-SAC denetleyicileri geliştirilerek dengeli ve dengesiz arızalar altında hem kendi aralarında hem optimizasyon tabanlı PI denetleyici ile karşılaştırılmıştır. Sonuçlar, SAC ajanının DDPG ve TD3 ajanlarına göre daha erken yakınsayarak daha üstün performans sağladığını göstermiştir. Transfer-SAC ajanı, dengeli ve dengesiz arıza değerleri için genelleme yeteneğini artırmıştır. DRL tabanlı denetleyiciler ile SOS-PI denetleyici karşılaştırıldığında, SOS-PI denetleyicinin yalnızca optimize edildiği koşulda çalıştığı ve genelleme yeteneğinin oldukça zayıf olduğu görülmüştür.

FV sistemin değişen çevresel koşullar altında performansını analiz etmek için SAC tabanlı denetleyici geliştirilmiştir. Sıcaklık sabit tutularak statik ve dinamik homojen gölgelenme durumları altında P&O algoritması ile karşılaştırma yapılmıştır. Sonuçlar, statik durumda algoritmaların benzer performans gösterdiğini ancak SAC'ın oturma zamanının daha kısa, dinamik durumda ise SAC tabanlı denetleyicinin maksimum güç noktasını daha iyi yakaladığını göstermiştir.

Sistemin dayanıklılığını artırmak için arıza sırasında FV dizinin gölgelenme etkisine maruz kalması da incelenmiştir. Önceden eğitilmiş SAC ajanı ve P&O algoritması FV dizinin gücünü kontrol ederken şebeke tarafında bir arıza meydana geldiğinde sistemin adapte olabilmesi için dengeli arıza durumunda SAC ajanı tekrar eğitilmiştir. Sonuçlar, SAC tabanlı denetleyicinin P&O'ya göre tüm durumları genelleyerek sistemin dayanıklılığını artırdığını göstermiştir. Ayrıca gölgelenme durumu için önceden eğitilmiş SAC ajanı ile dengeli-dengesiz arızalar için önceden eğitilmiş Transfer-SAC ajanı yeniden eğitilerek hem gölgelenme hem dengeli-dengesiz arıza durumları incelenmiştir. Transfer-SAC ajanı %70.83 genelleme sağlamıştır. Ardından kısmi gölgelenme senaryosu oluşturularak bu eğitilmiş ajan 0.3 pu dengeli arıza için test edilmiş olup hem maksimum gücün takip edildiği hem de LVRT yeteneğinin sağlandığı görülmüştür.

Önceden dengeli olarak eğitilmiş SAC ajanı, zayıf şebeke için test edilmiştir. Zayıf şebeke koşullarında reaktif akım enjeksiyonunun şebeke gerilimine daha duyarlı olduğu görülmüştür. Zayıf şebekenin sebep olduğu zayıf referans izleme gibi problemler nedeniyle sürekli durum hata değerinin yükseldiği ve en şiddetli arıza durumlarında genelleme sağlayamadığı görülmüştür.

Son olarak Transfer-SAC ajanının Opal-RT simülatörü ile gerçek zamanlı çalışması analiz edilmiştir. Önerilen denetleyicinin dengeli arıza durumunda simülasyon sonuçları ile karşılaştırması yapılmıştır. Gerçek zamanlı çalışmada sürekli durum hata değerinin yükseldiği ancak dinamik yanıt tepkilerinin simülasyon sonuçlarına yakın olduğu görülmüştür.

Sonuç olarak, bu tez kapsamında önerilen DRL tabanlı denetleyici şebeke yönetmeliklerine uyum göstererek FV sistemde enerji sürekliliğine katkı sağlayacaktır. İlgili gerilim ve akım sınırları sağlanarak güç elektroniği cihazlarının zarar görmemesi ve şebeke bağlantısının devam etmesi sağlanırken, MPPT ile de FV sistemden en etkili şekilde faydalanılarak verimin artması sağlanacaktır.

4. ÖNERİLER

Bu doktora tezi çalışmasında, şebeke bağlantılı FV sistemde enerji sürekliliği sağlamak için DRL tabanlı denetleyici geliştirilmiştir. Gelecekte bu konuda çalışmak isteyen araştırmacılar için öneriler şunlardır:

- Bu çalışmada transfer öğrenme kapsamında yalnızca önceden eğitilen ajanın parametreleri aktarılmıştır. Parametrelerle birlikte deneyim belleğinin de aktarılması, öğrenme eğrisi ve denetleyici performansı üzerindeki etkileri analiz etme fırsatı sunar. Ancak bu yaklaşım, deneyim belleklerinin kaydedilmesini gerektirdiği için önemli miktarda bellek kaynağına ihtiyaç duyar.
- Çevresel faktörlerin analizinde, gün ışığı değerinin yanı sıra sıcaklık değişimi de incelenebilir. Bu, denetleyicinin genelleme yeteneğini artırabilir. Ayrıca kısmi gölgelenme durumu için daha fazla senaryo test edilebilir.
- Bu çalışmada zayıf şebeke analizi için yeniden eğitim yapılmadan önceden eğitilmiş ajan kullanılmıştır. Zayıf şebekedeki denetleyici başarısını artırmak amacıyla transfer öğrenme yöntemi uygulanabilir.

5. KAYNAKLAR

- Alaboudy, A. H. K., Elbaset, A. A., & Abdelsattar, M. (2023). A case study on the LVRT capability of an egyptian electrical grid linked to the Al-Zafarana wind park using series resistor. *International Journal of Renewable Energy Research (IJRER)*, 13(1), 36-48.
- Ali, S. W., Verma, A. K., Terriche, Y., Sadiq, M., Su, C. L., Lee, C. H., & Elsis, M. (2022). Finite-control-set model predictive control for low-voltage-ride-through enhancement of PMSG based wind energy grid connection systems. *Mathematics*, 10(22), 4266.
- Alijoyo, F. A. (2024). AI-powered deep learning for sustainable industry 4.0 and internet of things: Enhancing energy management in smart buildings. *Alexandria Engineering Journal*, 104, 409-422.
- Al-Shetwi, A. Q., Hannan, M. A., Jern, K. P., Mansur, M., & Mahlia, T. M. I. (2020). Grid-connected renewable energy sources: Review of the recent integration requirements and control methods. *Journal of Cleaner Production*, 253, 119831.
- Al-Shetwi, A. Q., Sujod, M. Z., & Blaabjerg, F. (2018). Low voltage ride-through capability control for single-stage inverter-based grid-connected photovoltaic power plant. *Solar Energy*, 159, 665-681.
- Artetxe, E., Uralde, J., Barambones, O., Calvo, I., & Martin, I. (2023). Maximum power point tracker controller for solar photovoltaic based on reinforcement learning agent with a digital twin. *Mathematics*, 11(9), 2166.
- Avila, L., De Paula, M., Trimboli, M., & Carlucho, I. (2020). Deep reinforcement learning approach for MPPT control of partially shaded PV systems in Smart Grids. *Applied Soft Computing*, 97, 106711.
- Baysal, Y. A. (2022). Yılan Robotun Öğrenme Tabanlı Adaptif Hareket Kontrolü, DT tez, Karadeniz Teknik Üniversitesi.
- Benali, A., Khiat, M., Allaoui, T., & Denai, M. (2018). Power quality improvement and low voltage ride through capability in hybrid wind-PV farms grid-connected using dynamic voltage restorer. *IEEE access*, 6, 68634-68648.
- Bighash, E. Z., Sadeghzadeh, S. M., Ebrahimzadeh, E., & Blaabjerg, F. (2018). Improving performance of LVRT capability in single-phase grid-tied PV inverters by a model-predictive controller. *International Journal of Electrical Power & Energy Systems*, 98, 176-188.
- Causebrook, A., Atkinson, D. J., & Jack, A. G. (2007). Fault ride-through of large wind farms using series dynamic braking resistors (March 2007). *IEEE Transactions on power systems*, 22(3), 966-975.
- Chakraborty, A., & Maity, T. (2023). Integrated control algorithm for fast and accurate detection of the voltage sag with low voltage ride-through (LVRT) enhancement for

- doubly-fed induction generator (DFIG) based wind turbines. *Control Engineering Practice*, 131, 105393.
- Chatzigeorgiou, N. G., Theocharides, S., Makrides, G., & Georghiou, G. E. (2024). A review on battery energy storage systems: Applications, developments, and research trends of hybrid installations in the end-user sector. *Journal of Energy Storage*, 86, 111192.
- Chen, X., Qu, G., Tang, Y., Low, S., & Li, N. (2021). Reinforcement learning for decision-making and control in power systems: Tutorial, review, and vision. *arXiv preprint arXiv:2102.01168*.
- Cheng, M. Y., & Prayogo, D. (2014). Symbiotic organisms search: a new metaheuristic optimization algorithm. *Computers & Structures*, 139, 98-112.
- Çakmak, R. 2018. Akıllı şebekelerde fotovoltaik güç üretimine sahip konutlar için akıllı talep yönetim sistemi, DT tez, Karadeniz Teknik Üniversitesi.
- Çavli, N. (2021). Fotovoltaik Uygulamalar için Çok Seviyeli Eviricide Modülasyon Tekniklerinin Karşılaştırmalı Analizi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- Desalegn, B., Gebeyehu, D., & Tamrat, B. (2022). Evaluating the performances of PI controller (2DOF) under linear and nonlinear operations of DFIG-based WECS: A simulation study. *Heliyon*, 8(12).
- Döşoğlu, M. K. (2023). Enhancement of LVRT capability in DFIG-based wind turbines with STATCOM and supercapacitor. *Sustainability*, 15(3), 2529.
- Dursun, M., & DÖŞOĞLU, M. K. (2018, October). LCL filter design for grid connected three-phase inverter. In *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-4). IEEE.
- Elazab, O. S., Debouza, M., Hasanien, H. M., Muyeen, S. M., & Al-Durra, A. (2020). Salp swarm algorithm-based optimal control scheme for LVRT capability improvement of grid-connected photovoltaic power plants: Design and experimental validation. *IET Renewable Power Generation*, 14(4), 591-599.
- Ellithy, H. H., Hasanien, H. M., Alharbi, M., Sobhy, M. A., Taha, A. M., & Attia, M. A. (2024). Marine predator algorithm-based optimal pi controllers for LVRT capability enhancement of grid-connected PV systems. *Biomimetics*, 9(2), 66.
- Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine learning and deep learning in energy systems: A review. *Sustainability*, 14(8), 4832.
- Fujimoto, S., Hoof, H., and Meger, D., (2018). Addressing function approximation error in actor-critic methods, In *International Conference on Machine Learning*, 15871596.
- Gencer, A. (2025). Low Voltage Ride-Through Improvement of a Grid-Connected PV Power System Using a Machine Learning Control System. *Applied Sciences*, 15(8), 4251.

- Gholipour, A., Farhadi-Kangarlu, M., Neyshabouri, Y., & Talavat, V. (2025). Low voltage ride through (LVRT) enhancement of a two-stage grid-connected photovoltaic system based on finite-control-set model predictive control strategy. *International Journal of Renewable Energy Development*, 14(3), 404-419.
- Glavic, M., Fonteneau, R., & Ernst, D. (2017). Reinforcement learning for electric power system decision and control: Past considerations and perspectives. *IFAC-PapersOnLine*, 50(1), 6918-6927.
- Haarnoja, T., Zhou, A., Hartikainen, K., Tucker, G., Ha, S., Tan, J., ... & Levine, S. (2018). Soft actor-critic algorithms and applications. *arXiv preprint arXiv:1812.05905*.
- Haidar, A. M., & Julai, N. (2019). An improved scheme for enhancing the ride-through capability of grid-connected photovoltaic systems towards meeting the recent grid codes requirements. *Energy for Sustainable Development*, 50, 38-49.
- Han, C., Zhou, G., & Zhou, Y. (2019). Binary symbiotic organism search algorithm for feature selection and analysis. *IEEE Access*, 7, 166833-166859.
- Han, T., Muhammad, K., Hussain, T., Lloret, J., & Baik, S. W. (2020). An efficient deep learning framework for intelligent energy management in IoT networks. *IEEE Internet of Things Journal*, 8(5), 3170-3179.
- Hinton, G., Srivastava, N. ve Swersky, K., (2012). Neural networks for machine learning, Coursera, video lectures, 264, 1, 2146-2153.
- Hossain, M. K., & Ali, M. H. (2014, April). Low voltage ride through capability enhancement of grid connected PV system by SDBR. In *2014 IEEE PES T&D Conference and Exposition* (pp. 1-5). IEEE.
- Jaalam, N., Rahim, N. A., Bakar, A. H. A., & Eid, B. M. (2016, November). LVRT capability based on PI-scanning for three-phase grid-connected photovoltaic system. In *4th IET Clean Energy and Technology Conference (CEAT 2016)* (pp. 1-5). IET.
- Kaced, K., Larbes, C., Ramzan, N., Bounabi, M., & elabadine Dahmane, Z. (2017). Bat algorithm based maximum power point tracking for photovoltaic system under partial shading conditions. *Solar Energy*, 158, 490-503.
- Kingma, D. P. ve Ba, J., (2014). Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980.
- Küçükilhan, G. (2017). Fotovoltaik güç sistemlerinin modellenmesi ve şebekeye etkilerinin incelenmesi, YL tez, Afyon Kocatepe Üniversitesi.
- Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., ... & Wierstra, D. (2015). Continuous control with deep reinforcement learning. *arXiv preprint arXiv:1509.02971*.
- Lin, F. J., Tan, K. H., Luo, W. C., & Xiao, G. D. (2020). Improved LVRT performance of PV power plant using recurrent wavelet fuzzy neural network control for weak grid conditions. *IEEE access*, 8, 69346-69358.

- Lin, L.J., (1993). Reinforcement learning for robots using neural networks, Technical report, DTIC Document.
- Liu, H., & Wu, W. (2020). Two-stage deep reinforcement learning for inverter-based voltage control in active distribution networks. *IEEE Transactions on Smart Grid*, 12(3), 2037-2047.
- Mbuwir, B., Ruelens, F., Spiessens, F., & Deconinck, G. (2017). Reinforcement learning-based battery energy management in a solar microgrid. *Energy-Open*, 2(4), 36.
- Monteiro Pereira, R. M., Pereira, A. J., Ferreira, C. M., & Barbosa, F. P. M. (2018). Influence of crowbar and chopper protection on DFIG during low voltage ride through. *Energies*, 11(4), 885.
- Mostafa, M. A., El-Hay, E. A., & Elkholy, M. M. (2023). Optimal low voltage ride through of wind turbine doubly fed induction generator based on bonobo optimization algorithm. *Scientific Reports*, 13(1), 7778.
- Muisyo, I. N., Muriithi, C. M., & Kamau, S. I. (2022). Enhancing low voltage ride through capability of grid connected DFIG based WECS using WCA-PSO tuned STATCOM controller. *Heliyon*, 8(8).
- Nabavi, S. A., Motlagh, N. H., Zaidan, M. A., Aslani, A., & Zakeri, B. (2021). Deep learning in energy modeling: Application in smart buildings with distributed energy generation. *IEEE Access*, 9, 125439-125461.
- Neumann, T., & Erlich, I. (2012, July). Modelling and control of photovoltaic inverter systems with respect to German grid code requirements. In *2012 IEEE Power and Energy Society General Meeting* (pp. 1-8). IEEE.
- Nie, Y., Zhang, J., Liu, T., Cui, J., & Zhang, L. (2023). Low-voltage ride-through handling in wind farm with doubly fed induction generators based on variable-step model predictive control. *IET Renewable Power Generation*, 17(8), 2101-2112.
- Nwachukwu, S. E., Folly, K. A., & Awodele, K. O. (2025). A Comparative Study Between Soft Actor-Critic (SAC) and Deep Deterministic Policy Gradient (DDPG) Algorithms for Solar PV MPPT Control Under Partial Shading Conditions. *IEEE Access*.
- Ozcanli, A. K., Yaprakdal, F., & Baysal, M. (2020). Deep learning methods and applications for electrical power systems: A comprehensive review. *International Journal of Energy Research*, 44(9), 7136-7157.
- Perera, A. T. D., & Kamalaruban, P. (2021). Applications of reinforcement learning in energy systems. *Renewable and Sustainable Energy Reviews*, 137, 110618.
- Phan, B. C., Lai, Y. C., & Lin, C. E. (2020). A deep reinforcement learning-based MPPT control for PV systems under partial shading condition. *Sensors*, 20(11), 3039.

- Plappert, M., Houthoofd, R., Dhariwal, P., Sidor, S., Chen, R. Y., Chen, X., ... ve Andrychowicz, M., (2017). Parameter space noise for exploration, arXiv preprint arXiv:1706.0190.
- Qais, M. H., Hasanien, H. M., & Alghuwainem, S. (2020). Optimal transient search algorithm-based PI controllers for enhancing low voltage ride-through ability of grid-linked PMSG-based wind turbine. *Electronics*, 9(11), 1807.
- Qais, M. H., Hasanien, H. M., & Alghuwainem, S. (2018). A grey wolf optimizer for optimum parameters of multiple PI controllers of a grid-connected PMSG driven by variable speed wind turbine. *IEEE Access*, 6, 44120-44128.
- Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), 145-151.
- Radwan, E., Nour, M., Awada, E., & Baniyounes, A. (2019). Fuzzy logic control for low-voltage ride-through single-phase grid-connected PV Inverter. *Energies*, 12(24), 4796.
- Rai, R., & Singh, B. (2022). Converter control during low voltage ride through operation for grid-interfaced solar PV battery assisted system. *IEEE Transactions on industrial electronics*, 70(9), 9181-9191.
- Rummery, G. A. ve Niranjan, M., (1994). On-line Q-learning using connectionist systems. Technical Report CUED/F-INFENG/TR 166, Engineering Department, Cambridge University.
- Samarasekera, K. (2015). Fault Ride-Through Capability of Grid Integrated Solar Power Plants. University of Toronto (Canada).
- Schmall, J., Huang, S. H., Li, Y., Billo, J., Conto, J., & Zhang, Y. (2015, July). Voltage stability of large-scale wind plants integrated in weak networks: An ERCOT case study. In *2015 IEEE Power & Energy Society General Meeting* (pp. 1-5). IEEE.
- Schulman, J., Levine, S., Abbeel, P., Jordan, M., & Moritz, P. (2015, June). Trust region policy optimization. In *International conference on machine learning* (pp. 1889-1897). PMLR.
- Schulman, J., Wolski, F., Dhariwal, P., Radford, A., & Klimov, O. (2017). Proximal policy optimization algorithms. *arXiv preprint arXiv:1707.06347*.
- Subburaja, A. S., Shamim, N., & Bayne, S. B. (2016, April). Battery connected DFIG wind system analysis for strong/weak grid scenarios. In *2016 IEEE Green Technologies Conference (GreenTech)* (pp. 112-117). IEEE.
- Sutton, R. S. (1988). Learning to predict by the methods of temporal differences, *Machine learning*, 3, 1, 9-44.
- Sutton, R. S. ve Barto, A. G., (2018). Reinforcement learning: An introduction, MIT press.

- Swandaru, A. (2020). Reactive power-based voltage support for the low voltage ride through capability of the distributed energy resource. PhD dissertation, University of Southampton.
- Şirin, İ. (2025). Yenilenebilir enerji destekli mikro şebeke tasarımı ve bölgesel bazda analizi: Kamu binası örneği. YL tez, Yalova Üniversitesi.
- Talha, M., Amir, A., Raihan, S. R. S., & Abd Rahim, N. (2021). Grid-connected photovoltaic inverters with low-voltage ride through for a residential-scale system: A review. *International Transactions on Electrical Energy Systems*, 31(10), e12630.
- Tiong, T., Saad, I., Teo, K. T. K., & bin Lago, H. (2020, November). Deep reinforcement learning with robust deep deterministic policy gradient. In *2020 2nd International Conference on Electrical, Control and Instrumentation Engineering (ICECIE)* (pp. 1-5). IEEE.
- Titri, S., Larbes, C., Toumi, K. Y., & Benatchba, K. (2017). A new MPPT controller based on the Ant colony optimization algorithm for Photovoltaic systems under partial shading conditions. *Applied Soft Computing*, 58, 465-479.
- Tran, D. H., Cheng, M. Y., & Prayogo, D. (2016). A novel Multiple Objective Symbiotic Organisms Search (MOSOS) for time–cost–labor utilization tradeoff problem. *Knowledge-Based Systems*, 94, 132-145.
- Türkmen, G. (2022). A Comparative Study Of Nonlinear Model Predictive Control And Reinforcement Learning For Path Tracking, YL tez, İstanbul Teknik Üniversitesi.
- Uhlenbeck, G. E. ve Ornstein, L.S, (1930). On the theory of the Brownian motion, *Physical review*, 36, 5,823.
- URL-1.(2025, Eylül 11). Enerji Günlüğü: <https://www.enerjigunlugu.net/2024te-turkiyenin-kurulu-gucu-yuzde-4-artti-61712h.htm> adresinden alındı.
- Watkins, C.J.C.H., 1989. Learning from Delayed Rewards, Ph.D. thesis, Cambridge University.
- Williams, R. J. (1992). Simple statistical gradient-following algorithms for connectionist reinforcement learning. *Machine learning*, 8(3), 229-256.
- Xu, D., Cui, Y., Ye, J., Cha, S. W., Li, A., & Zheng, C. (2022). A soft actor-critic-based energy management strategy for electric vehicles with hybrid energy storage systems. *Journal of Power Sources*, 524, 231099.
- Xu, K. (2024). LVRT Technology in Photovoltaic Power Generation. *Highlights in Science, Engineering and Technology*, 81.
- Yamparala, S., Lakshminarasimman, L., & Rao, G. S. (2023). Improvement of LVRT Capability for DFIG based WECS by Optimal Design of FoPID Controller using SLnO+ GWO Algorithm. *International Journal of Intelligent Engineering & Systems*, 16(1).

- Yang, B., Zhong, L., Zhang, X., Shu, H., Yu, T., Li, H., ... & Sun, L. (2019). Novel bio-inspired memetic salp swarm algorithm and application to MPPT for PV systems considering partial shading condition. *Journal of cleaner production*, 215, 1203-1222.
- Yin, X., & Lei, M. (2023). Jointly improving energy efficiency and smoothing power oscillations of integrated offshore wind and photovoltaic power: a deep reinforcement learning approach. *Protection and Control of Modern Power Systems*, 8(2), 1-11.
- Zhang, Y., Huang, S. H. F., Schmall, J., Conto, J., Billo, J., & Rehman, E. (2014, July). Evaluating system strength for large-scale wind plant integration. In *2014 IEEE PES General Meeting| Conference & Exposition* (pp. 1-5). IEEE.
- Zhou, J. Z., & Gole, A. M. (2012, December). VSC transmission limitations imposed by AC system strength and AC impedance characteristics. In *10th IET international conference on AC and DC power transmission (ACDC 2012)* (pp. 1-6). IET.
- Zhou, Y., Nguyen, D. D., Kjaer, P. C., & Saylors, S. (2013, July). Connecting wind power plant with weak grid-challenges and solutions. In *2013 IEEE Power & Energy Society General Meeting* (pp. 1-7). IEEE.

ÖZGEÇMİŞ

Lise öğrenimini Trabzon’da tamamladı ve 2012’de Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik–Elektronik Mühendisliği Bölümü’ne başladı. 2016’da bölüm üçüncüsü olarak mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda tezli yüksek lisans programına başladı. 2019’da “Şebeke Bağlantılı FV Sistemlerde Gölgeleme Etkisinin İncelenmesi ve Güç Kayıplarının Azaltılması” başlıklı tezini sunarak yüksek lisansını tamamladı ve doktora eğitimine başladı. 2018’den beri Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği, Elektrik Tesisleri Anabilim Dalı’nda araştırma görevlisi olarak görev yapmaktadır. Yabancı dil olarak İngilizce bilmektedir.

ÖZGENÇ, B., Aslanhan, Y. A., & Altas, I. H., (2025). Improving LVRT capability in grid connected PV system using DRL based controller. *IEEE Access*.