



T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANARAK YENİLENEBİLİR ENERJİ
GÜÇ ÜRETİM TAHMİNİ VE OPTIMUM HİBRİT GÜÇ SİSTEMİ TASARIMI

HALİL DEMOLLI

Şubat 2020

T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANARAK YENİLENEBİLİR ENERJİ
GÜÇ ÜRETİM TAHMİNİ VE OPTİMUM HİBRİT GÜÇ SİSTEMİ TASARIMI

HALİL DEMOLLI

Doktora Tezi

Danışman

Prof. Dr. Murat GÖKÇEK

Şubat 2020

Halil DEMOLLI tarafından **Prof. Dr. Murat Gökçek** danışmanlığında hazırlanan "**Makine Öğrenmesi Teknikleri Kullanarak Yenilenebilir Enerji Güç Üretim Tahmini ve Optimum Hibrit Güç Sistemi Tasarımı**" aldı bu çalışma jürimiz tarafından Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü **Makine Mühendisliği** Anabilim Dalında Doktora tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Ünal AKDAĞ, Aksaray Üniversitesi



Üye : Prof. Dr. Murat GÖKÇEK, Niğde Ömer Halisdemir Üniversitesi



Üye : Prof. Dr. Yahya Erkan AKANSU, Niğde Ömer Halisdemir Üniversitesi



Üye : Doç. Dr. Mustafa KILIÇ, Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi



Üye : Dr. Öğr. Üyesi Fuat KAYA, Niğde Ömer Halisdemir Üniversitesi



ONAY:

Bu tez, Fen Bilimleri Enstitüsü Yönetim Kurulunca belirlenmiş olan yukarıdaki jüri üyeleri tarafından/...../20.... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulu'nun/...../20.... tarihi ve sayılı kararıyla kabul edilmiştir.

...../...../2020

Prof. Dr. Murat Barut

MÜDÜR

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin bilimsel ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Halil DEMOLLI



ÖZET

MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANARAK YENİLENEBİLİR ENERJİ GÜÇ ÜRETİM TAHMİNİ VE OPTİMUM HİBRİT GÜÇ SİSTEMİ TASARIMI

DEMOLLI, Halil

Niğde Ömer Halisdemir Üniversitesi

Fen Bilimleri Enstitüsü

Makine Mühendisliği AnaBilim Dalı

Danışman: : Prof. Dr. Murat GÖKÇEK
İkinci Danışman : Dr. Öğr. Üyesi Ahmet Şakir DOKUZ

Şubat 2020, 127 sayfa

Bu çalışmada, öncelikle Türkiye’deki çeşitli lokasyonlar için meteorolojik ölçüm istasyonlarından alınan rüzgar hızı ve güneş radyasyonu gibi meteorolojik veriler kullanarak çeşitli makine öğrenmesi metotlarıyla rüzgar ve güneş gücü için kısa ve uzun dönem tahminleri yapılmış, daha sonra belirli bir yük talebi oluşturularak yine Türkiye’de ki farklı noktalarda kurulacağı düşünülen hibrit yenilenebilir enerji güç üretim sistemlerinin optimal boyutlarının belirlenmesi, Güç Tedariki Kaybı Olasılığı güvenilirlik göstergesi ile minimum bir değere getirilmiş maliyet değeri göz önünde bulundurularak zaman serisi analizi metoduyla deterministik bir yaklaşımla ve ayrıca yapay zeka yöntemleri kullanılarak yapılmıştır. Bu tez çalışması kapsamında geliştirilen rüzgar ve güneş enerjisi güç tahmini için kullanılan makine öğrenmesi modellerinin yüksek performansa sahip oldukları ve gerçek değerlere oldukça yakın sonuçlar üretebildikleri görülmüştür. Diğer taraftan belirlenen yük talebine göre kullanılan optimizasyon algoritmalarının farklı karakteristikteki lokasyonlar için en optimum sistem tasarımını başarıyla üretmişlerdir.

Anahtar Kelimeler: Rüzgar Enerjisi, Güneş Enerjisi, Makine Öğrenmesi, Optimal Sistem Tasarımı, Optimizasyon Algoritmaları.

SUMMARY

RENEWABLE ENERGY POWER GENERATION FORECASTING AND OPTIMAL HYBRID POWER SYSTEM DESIGN USING MACHINE LEARNING TECHNIQUES

DEMOLLI, Halil

Niğde Ömer Halisdemir University
Graduate School of Natural and Applied Sciences
Department of Mechanical Engineering

Supervisor : Prof. Dr. Murat GÖKÇEK
Co-Supervisor : Dr. Öğr. Üyesi Ahmet Şakir DOKUZ

February 2020, 127 pages

In this study, first of all, meteorological data, such as wind speed and solar irradiation, which are obtained from meteorological observation stations for different locations in Turkey are used for long term forecasting wind and solar energy power using machine learning methods, and then a load demand is generated and optimum sizing of hybrid renewable energy power production systems are performed using Loss of Power Supply Probability confidence measure and minimum cost of energy for potential establishment in two different locations from Turkey. For optimum sizing of the systems, a grid-search based deterministic algorithm is proposed and also artificial intelligence methods are used. The machine learning models on this thesis study that are used for wind and solar energy power forecasting have high performance and are close to the real values. On the other hand, the optimization algorithms could successfully produce optimum system sizing for a given load demand for locations that have different characteristics.

Keywords: Wind Energy, Solar Energy, Machine Learning, Optimal design, Optimization algorithms.

ÖN SÖZ

Bu çalışmada, öncelikle Türkiye'deki çeşitli lokasyonlar için meteorolojik ölçüm istasyonlarından alınan rüzgar hızı ve güneş radyasyonu gibi meteorolojik veriler kullanarak çeşitli makine öğrenmesi metotlarıyla rüzgar ve güneş gücü için kısa ve uzun dönem tahminleri yapılmış, daha sonra belirli bir yük talebi oluşturularak yine Türkiye'de ki farklı noktalarda kurulacağı düşünülen yenilenebilir enerji güç üretim sistemlerinin optimal boyutlarının belirlenmesi, Güç Tedariki Kaybı Olasılığı güvenilirlik göstergesi ile minimum bir değere getirilmiş maliyet değeri göz önünde bulundurularak zaman serisi analizi metoduyla deterministik bir yaklaşımla ve ayrıca yapay zeka yöntemleri kullanılarak yapılmıştır.

Doktora tezi çalışması süresince, çalışmalarına yön veren ve yardımlarını esirgemeyen doktora tez danışmanım sayın Prof. Dr. Murat GÖKÇEK, ikinci danışmanım sayın Dr. Öğr. Üyesi Ahmet Şakir DOKUZ ve Arş. Gör. Alper ECEMİŞ'e en içten teşekkürlerimi sunarım.

Ayrıca Doktora tez izleme komitesi üyeleri Prof. Dr. Ünal AKDAĞ ile Prof Dr. Yahya AKANSU'ya ve Niğde Ömer Halisdemir Üniversitesi Makine Mühendisliği Bölüm Öğretim Üyelerine teşekkür ederim.

Tezde fikir yardımlarından dolayı Prof. Dr. Blerim REXHA' a teşekkür ederim.

Tezde çalışmasında kullanılan meteorolojik verileri sağlayan Meteoroloji Genel Müdürlüğü Meteorolojik Veri İşlem Dairesi Başkanlığı'na teşekkür ederim.

Her zaman yanımda olan ve beni destekleyen aileme, özellikle eşim Arta'ya ve çocuklarım Dorela ve Dimal'e sonsuz teşekkürlerimi sunmak isterim.

İÇİNDEKİLER

ÖZET	iv
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SİMGE VE KISALTMALAR	xiv
BÖLÜM I GİRİŞ	1
BÖLÜM II LİTERATÜR ARAŞTIRMASI	8
2.1 Rüzgar ve Güneş Enerjisi Tahminleri İle İlgili Yapılan Çalışmalar	8
2.2 Hibrit Yenilenebilir Güç Sistemleri İle İlgili Yapılan Çalışmalar	12
BÖLÜM III MATERYAL VE METOT	19
3.1 Uygulama Alanları	19
3.2 Güneş ve rüzgar enerjisi tahminleri için enerji hesaplamaları	20
3.3 Makine Öğrenmesi	24
3.3.1 Regresyon Algoritmaları	26
3.3.1.1 LASSO Regresyon Algoritması	26
3.3.1.2 kNN Regresyon Algoritması	27
3.3.1.3 xGBoost Regresyon Algoritması	28
3.3.1.4 RastgeleOrman Regresyon Algoritması	29
3.3.1.5 Destek Vektör Regresyon Algoritması	29
3.3.2. Regresyon Algoritmalarıyla Güç Üretim Tahmini Yöntemi	30
3.3.3. Optimizasyon Algoritmaları	32
3.3.3.1 Önerilen Deterministik Algoritma	32
3.3.3.2 Genetik Algoritma	33
3.3.3.3 Yapay Arı Koloni Algoritması	36
BÖLÜM IV RÜZGAR VE GÜNEŞ ENERJİSİ TAHMİNİ DENEYSEL SONUÇLARI	39
4.1 Rüzgar ve Güneş Verileri	39
4.1.1 Rüzgar Verilerinin Analizi	39
4.1.2 Güneş Verilerinin Analizi	42

4.2 Rüzgar ve Güneş Enerjisi Tahmini Deneysel Sonuçları.....	45
4.2.1 Rüzgar Enerjisi Tahmini Deneysel Sonuçları.....	45
4.2.2 Güneş Enerjisi Tahmini Deneysel Sonuçları.....	55
BÖLÜM V OPTİMUM HİBRİT SİSTEM BOYUTLANDIRMASI DENEYSEL	
SONUÇLARI	65
5.1 Oluşturulan Hibrit Sistemin Özellikleri.....	65
5.1.1 Güneş Enerjisi Sistemi Teknik Özellikleri.....	66
5.1.2 Rüzgar Enerjisi Sistemi Teknik Özellikleri.....	66
5.1.3 Batarya Sistemi Teknik Özellikleri.....	67
5.1.4 Konvertör (Dönüştürücü) Teknik Özellikleri.....	68
5.1.5 Yük Talebi.....	69
5.1.6 Güneş/Rüzgar/Batarya Modeli.....	72
5.2 Güneş Enerjisi ve Batarya Hibrit Sistem Boyutlandırması.....	74
5.2.1 Niğde lokasyonu için güneş enerjisi ve batarya hibrit sistem boyutlandırması.....	74
5.2.2 Bozcaada lokasyonu için güneş enerjisi ve batarya hibrit sistem boyutlandırması.....	80
5.3 Güneş Enerjisi, Rüzgar Enerjisi ve Batarya Hibrit Sistem Boyutlandırması.....	89
5.3.1 Niğde lokasyonu için güneş enerjisi, rüzgar enerjisi ve batarya hibrit sistem boyutlandırması.....	89
5.3.2 Bozcaada lokasyonu için güneş enerjisi, rüzgar enerjisi ve batarya hibrit sistem boyutlandırması.....	97
BÖLÜM VI SONUÇLAR VE TARTIŞMA	110
KAYNAKLAR	113
ÖZ GEÇMİŞ	126

ÇİZELGELER DİZİNİ

Çizelge 3.1. Göz önünde bulundurulmuş türbinin teknik özellikleri.....	22
Çizelge 3.2. Seçilen lokasyonların enlem dereceleri	23
Çizelge 4.1. Seçilen lokasyonlarda Weibull dağılım parametreleri.....	41
Çizelge 4.2. Günlük rüzgar hızı ve standart sapma için algoritmaların 5 lokasyondaki tahmin doğruluğu	49
Çizelge 4.3. Günlük ortalama güneş radyasyonu ve ortam sıcaklığı için algoritmaların 5 lokasyondaki tahmin doğruluğu	59
Çizelge 5.1. Seçilen güneş panelinin teknik ve ekonomik özellikleri	66
Çizelge 5.2. Seçilen rüzgar türbininin teknik ve ekonomik özellikleri.	67
Çizelge 5.3. Seçilen bataryanın teknik ve ekonomik özellikleri.....	68
Çizelge 5.4. Seçilen dönüştürücünün teknik özellikleri	69
Çizelge 5.5. PV/batarya sisteminin kullanılan algoritmalara göre optimal sonuçları	88
Çizelge 5.6. PV/batarya sisteminin elektrik enerjisi değerleri.....	89
Çizelge 5.7. PV/rüzgar türbini/batarya sisteminin kullanılan algoritmalara göre optimal sonuçları	106
Çizelge 5.8. PV/rüzgar türbini/batarya sisteminin elektrik enerjisi değerleri.....	107
Çizelge 5.9. Algoritmaların işlem zamanı performans kıyaslaması	107
Çizelge 5.10. Pv/Batarya ile kurulan sistemde keşfedilen en optimum 10 konfigürasyon.....	108
Çizelge 5.11. PV/Batarya/Rüzgar Türbini ile kurulan sistemde keşfedilen en optimum 10 konfigürasyon	109

ŞEKİLLER DİZİNİ

Şekil 1.1. Türkiye'nin 50 m yükseklikte rüzgar hızı haritası.....	2
Şekil 1.2. Türkiye'nin güneş enerjisi haritası	2
Şekil 1.3. Optimizasyon yöntemlerinin sınıflandırılması.	5
Şekil 3.1. İncelen lokasyonlar	19
Şekil 3.2. 1 MW gücündeki rüzgar türbinin güç eğrisi.....	21
Şekil 3.2. Yatay ve eğik yüzeylerde güneş ışınımı.	23
Şekil 3.3. Çalışmada kullanılan genetik algoritmanın akış diyagramı	35
Şekil 3.4. Çalışmada kullanılan ABC algoritmasının akış diyagramı	38
Şekil 4.1. Seçilen 5 lokasyondaki günlük ortalama rüzgar hızı değerleri.....	40
Şekil 4.2. Seçilen lokasyonlarda rüzgar hızı frekans dağılımı.....	41
Şekil 4.3. Seçilen 5 lokasyondaki günlük ortalama güneş radyasyonu değerleri	43
Şekil 4.4. Seçilen 5 lokasyondaki günlük ortalama ortam sıcaklığı değerleri	44
Şekil 4.5. (a) Tahmin gücü ve (b) LASSO regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi	46
Şekil 4.6. (a) Tahmin gücü ve (b) kNN regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi	47
Şekil 4.7. (a) Tahmin gücü ve (b) xGBoost regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi	47
Şekil 4.8. (a) Tahmin gücü ve (b) RF regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi.....	48
Şekil 4.9. (a) Tahmin gücü ve (b) SVR regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi	48
Şekil 4.10. Niğde bölgesi için günlük gerçek rüzgargücü değerleri ve algoritmaların tahmini.....	50
Şekil 4.11. Çeşme bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini	51
Şekil 4.12. Silivri bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini.....	52
Şekil 4.13. Mamak bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini	53

Şekil 4.14. Bozcaada bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini	54
Şekil 4.15. (a) Tahmini güneş gücü ve (b) LASSO regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi.....	55
Şekil 4.16. (a) Tahmini güneş gücü ve (b) kNN regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi.....	56
Şekil 4.17. (a) Tahmini güneş gücü ve (b) xGBoost regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi.....	57
Şekil 4.18. (a) Tahmini güneş gücü ve (b) RF regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi.....	57
Şekil 4.19. (a) Tahmini güneş gücü ve (b) SVR regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi.....	58
Şekil 4.20. Niğde bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini	60
Şekil 4.21. Çeşme bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini	61
Şekil 4.22. Silivri bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini	62
Şekil 4.23. Mamak bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini	63
Şekil 4.24. Bozcaada bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini	64
Şekil 5.1. 2.5 kW rüzgar türbini için güç eğrisi.....	66
Şekil 5.2. Bir ev için saatlik yük talebi	69
Şekil 5.3. Güneş/batarya hibrit sisteminin tasarımı	70
Şekil 5.4. Güneş/rüzgar/batarya hibrit sistemin tasarımı	73
Şekil 5.5. Niğde'de fotovoltaik paneller tarafından bir yıl boyunca üretilen güç	74
Şekil 5.6. Niğde için kullanılan bataryaların saatlik şarj durumu.....	75
Şekil 5.7. Niğde içintalep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi	75
Şekil 5.8. Niğde için farklı aylarda üretilen güç, batarya ve yük talebi değerleri	76
Şekil 5.9. Niğde'de üretilen elektrik ve yük talebinin toplam aylık değerleri	77
Şekil 5.10. Niğde için kullanılan bataryaların ortalama aylık şarj durumu	77
Şekil 5.11. Niğde'de aylıktalep fazlası elektrik enerjisi üretimi	78

Şekil 5.12. Niğde'de karşılanamayan toplam aylık güç değerleri.....	78
Şekil 5.13. Niğde'de üretilen toplam güç ve yük talebinin mevsimsel değişimi	79
Şekil 5.14. Niğde lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu	79
Şekil 5.15. Niğde'de mevsimseltalep fazlası elektrik enerjisi üretimi	80
Şekil 5.16. Niğde'de karşılanamayan toplam gücün mevsimsel değerleri.....	80
Şekil 5.17. Bozcaada'da fotovoltaikpaneller tarafından bir yıl boyunca üretilen güç	81
Şekil 5.18. Bozcaada lokasyonu için kullanılan bataryaların saatlik şarj durumu	81
Şekil 5.19. Talep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi.....	82
Şekil 5.20. Bozcaada için farklı aylarda üretilen güç, batarya ve yük talebi değerleri...	83
Şekil 5.21. Bozcaada'da üretilen elektrik ve yük talebinin toplam aylık değerleri.....	84
Şekil 5.22. Bozcaada lokasyonu için kullanılan bataryaların ortalama aylık şarj durumu	84
Şekil 5.23. Bozcaada'da aylık talep fazlası elektrik enerjisi üretimi.....	85
Şekil 5.24. Bozcaada'da karşılanamayan toplam aylık güç değerleri	85
Şekil 5.25. Bozcaada'da üretilen elektrik ve yük talebinin toplam mevsimsel değerleri.....	86
Şekil 5.26. Bozcaada lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu.....	86
Şekil 5.27. Bozcaada'damevsimseltalep fazlası elektrik enerjisi üretimi.....	87
Şekil 5.28. Bozcaada'da karşılanmayan gücün toplam mevsimsel değerleri.....	87
Şekil 5.29. Niğde ve Bozcaada için PV/batarya sisteminin BNMdeğerleri	88
Şekil 5.30. Niğde'de fotovoltaik paneller tarafından bir yıl boyunca üretilen güç	90
Şekil 5.31. Niğde'de rüzgar türbini tarafından bir yıl boyunca üretilen güç.....	90
Şekil 5.32. Niğde lokasyonu için kullanılan bataryaların saatlik şarj durumu	91
Şekil 5.33. Niğde'detalep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi	91
Şekil 5.34. Niğde için farklı aylarda üretilen güç, batarya ve yük talebi değerleri	92
Şekil 5.35. Niğde'de üretilen elektrik ve yük talebinin toplam aylık değerleri	93
Şekil 5.36. Niğde'de PV panel ve rüzgar türbini tarafından üretilen toplam aylık güç değerleri	93
Şekil 5.37. Niğde lokasyonu için kullanılan bataryaların ortalama aylık şarj durumu	94
Şekil 5.38. Niğde'de aylık toplam aşırı güç değerleri.....	94

Şekil 5.39. Niğde'de karşılanmamış toplam aylık güç değerleri	95
Şekil 5.40. Niğde'de üretilen toplam güç ve yük talebinin mevsimsel değişimi	95
Şekil 5.41. Niğde'de fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam mevsimsel güç değerleri.....	96
Şekil 5.42. Niğde lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu	96
Şekil 5.43. Niğde'de mevsimsel talep fazlası elektrik enerjisi üretimi	97
Şekil 5.44. Niğde'de karşılanmayan gücün toplam mevsimsel değerleri	97
Şekil 5.45. Bozcaada'da PV paneli tarafından bir yıl boyunca üretilen güç	98
Şekil 5.46. Bozcaada'da rüzgar türbini tarafından bir yıl boyunca üretilen güç	98
Şekil 5.47. Bozcaada lokasyonu için kullanılan bataryaların saatlik şarj durumu	99
Şekil 5.48. Bozcaada lokasyonu içintalep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi	99
Şekil 5.49. Bozcaada için farklı aylarda üretilen güç, batarya ve yük talebi değerleri.....	100
Şekil 5.50. Bozcaada'da üretilen elektrik ve yük talebinin toplam aylık değerleri.....	101
Şekil 5.51. Bozcaada'da fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam aylık güç değerleri.....	101
Şekil 5.52. Bozcaada lokasyonu için kullanılan bataryaların ortalama aylık şarj durumu	102
Şekil 5.53. Bozcaada'da aylık toplam aşırı güç değerleri	102
Şekil 5.54. Bozcaada'da karşılanmamış toplam aylık güç değerleri.....	103
Şekil 5.55. Bozcaada'da üretilen toplam güç ve yük talebinin mevsimsel değişimi	103
Şekil 5.56. Bozcaada'da PV panel ve rüzgar türbini tarafından üretilen toplam mevsimsel güç değerleri.....	104
Şekil 5.57. Bozcaada lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu.....	104
Şekil 5.58. Bozcaada'da mevsimsel talep fazlası elektrik enerjisi üretimi	105
Şekil 5.59. Bozcaada'da karşılanmayan gücün toplam mevsimsel değerleri.....	105
Şekil 5.60. Niğde ve Bozcaada için PV/rüzgar türbini/batarya sisteminin BNMdeğerleri.....	106

SİMGE VE KISALTMALAR

Simgeler	Açıklama
$P_i(v)$	Rüzgar türbini güç çıktısı
a_n, a_{n-1}, a_1, a_0	Regrasyon sabitleri
v_{ci}	Rüzgar türbininin devreye girme hızı
v_R	Rüzgar türbinin nominal güç ürettiği rüzgar hızı
v_{co}	Rüzgar türbinin devreden çıktığı rüzgar hızı
P_R	Rüzgar türbinin nominal gücü
E_{WT}	Bir rüzgar türbininde göz önünde bulundurulan bir süre için enerji çıkışı
N	Yıllar
Δt	Zaman aralığıdır
V_{hub}	Hub yüksekliğine karşılık gelen rüzgar hızı
V_{anem}	Ölçüm yapılan yükseklikte rüzgâr hızı,
Z_{anem}	Ölçümün yapıldığı yükseklik
Z_{hub}	Rüzgâr türbininin hub yüksekliği (m)
α	Logaritmik yasada kullanılan
P_{pv}^t	Fotovoltaik panel güc
$P_{PV-rated}$	Fotovoltaik panelin anma gücü
F_{PV}	İndirgeme faktörü
G_T	PV panele gelen güneş radyasyonu
$G_{T,STC}$	Incident radiation at standard test conditions
α_p	Sıcaklık katsayısı
T_c	PV hücre sıcaklığı
$T_{C,STC}$	Standart koşullar altında PV hücresi sıcaklığıdır
E_{PV}	Fotovoltaik panel enerji üretimi
R_{bt}	Değeri ilişkiyi belirleyebilir
G_{Tilt}	Eğim açısı üzerinde güneş ışınımı
$G_{Horizontal}$	Yatay yüzeyde güneş ışınımı
β	Eğim, söz konusu yüzey ile yatay düzlem arasındaki açı

θ	Geliş açısı
θ_z	Zenith açısı
δ	Deklinasyon açısı
γ	Yüzey azimut açısı
ω	Saat açısı
K	Örnek sayısını
α_i, β_j	Korelasyon parametreleri
$\hat{\alpha}$	Tahmin
λ	Ceza parametresi
v	Sınıf değeri
y_i	i. komşunun sınıf değeri
$I(.)$	İçine aldığı değere göre, 1 veya 0 dönderen fonksiyon
$F_{obj}(\theta)$	Amaç fonksiyonu
$L(\theta)$	Kayıp fonksiyonu
\hat{y}_i	Tahmin edilen değerler
y_i	Gerçek değerler
$\Omega(\theta)$	Düzenleme Terimi
γ	Öğrenme katsayısı
T	Ağaç yaprak sayısı
λ	Düzenleme parametresi
w	Yaprak ağırlıkları
X,Y	Rastgele vektörler
mg	Sınır fonksiyonu
h_k	Sınıflandırıcılar
w	Giriş vektör uzayı
b	Bias
ε	Hassasiyet
ξ_i, ξ_i^*	Hata parametreleri
x_j^{\min}, x_j^{\max}	Parametrenin alt ve üst sınırını belirtir
v_{ij}, x_{ij}	Mevcut kaynak komşuluğundaki yeni bir çözüm

$\Theta_{ij}[1,-1]$	1,-1 aralığında seçilen rastgele bir değer
$p_i p_i$	Her bir çözüm için kaynak seçim olasılığı
fitness	i. çözümün kalite değeri
k	Şekil parametresi
c	Ölçek parametresi
$P_{Batt}(t)$	t zamanında pil durumu
$P_{Batt}(t-1)$	t-1 zamanındaki şarj miktarı
σ	Pilin kendi kendine deşarj oranı
N_{PV}	Fotovoltaik panel sayısı
η_{Inv}	Inverter verimliliği
η_{Con}	Dönüştürücü verimliliği
η_{REC}	Doğrultucu verimliliği
η_{batt}	Pil sisteminin şarj verimliliği
I_p	Güneş panelinin spesifik maliyetini
P_p	Panel kurulu gücünü
C_p	Panel maliyeti
C_{bat}	Batarya maliyeti
C_{con}	Konverter maliyeti
$C_{Bat/rep}$	Batarya deęiştirme maliyeti
P_{bat}	Batarya gücü
i	Faiz oranı
n	Yıl
$C_{T, sis}$	Toplam sistem maliyeti
$C_{p, o\&m}$	Fotovoltaik panel işletme bakım maliyeti
$C_{c, o\&m}$	Konverter işletme bakım maliyeti
$C_{b, o\&m}$	Batarya işletme bakım maliyeti
$C_{con, rep}$	Konverter deęiştirme maliyeti
$C_{bat, rep}$	Batarya deęiştirme maliyeti

Kısaltmalar

Açıklama

LASSO	Least absolute shrinkage selector operator
kNN	k En yakın komşu algoritması
RF	Rastgele orman

SVR	Destek vektör regresyonu
GA	Genetik algoritma
ABC	Yapay arı kolonisi algoritması
R^2	Korelasyon katsayısı
RMSE	Kök ortalama hata oranı
MAE	Ortalama hata oranı
DC	Dođru akım
AC	Alternatif akım
BNM	Bugünkü net maliyet
TGÜ	Toplam güç üretimi
TYT	Toplam yük talebi
TFEEÜ	Talep fazlası elektrik enerji üretimi
KEEM	Karşılanamayan elektrik enerji miktarı
PV	Fotovoltaik panel
WT	Rüzgar türbini
CRF	Yatırım ikame faktörü
LCOE	Bir değere getirilmiş elektrik maliyeti
AEP	Yıllık elektrik üretimi
LPSP	Güç tedariki kaybı olasılığı


BÖLÜM I

GİRİŞ

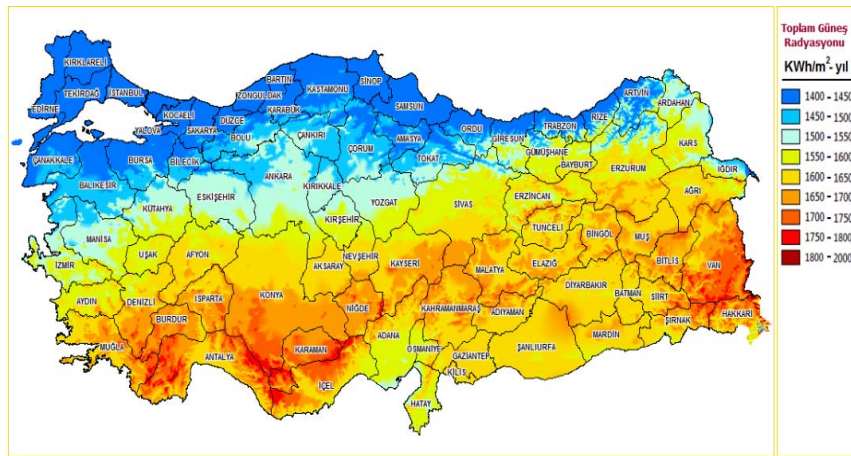
Enerji canlılığın devamı ve ülkelerin sosyo-ekonomik gelişimi için çok önemli rol oynayan stratejik bir kavram olarak kabul edilmektedir. Günümüzde enerji üretimi ağırlıklı olarak petrol, doğalgaz ve kömür gibi kaynağı sınırlı fosil yakıtlara dayanmakta, küresel elektrik talebinin %70'inden fazlası bu yakıtlarla sağlanmaktadır (Al-falahi vd., 2017). Diğer taraftan, teknolojik gelişmeler ve hızlı nüfus artışının sonucu olarak küresel enerji tüketimi de yılda yaklaşık %2.3 oranında artmaktadır (Abdin vd., 2020). Enerji arzının güvenliği, özellikle gelişmekte olan ülkelerin ekonomilerinde ekonominin işleyişi için büyük tehdit oluşturmaktadır (Pareek vd., 2020). Enerji arz güvenliğinin yanında, küresel ısınma ve sera gazı (GHG) emisyonları hakkında daha kısıtlayıcı hale gelen düzenlemeler nedeniyle enerji üretiminde yenilenebilir kaynaklarının kullanımı hızla artmaktadır (Martín ve Grossmann, 2018). Yenilenebilir enerji genellikle güneş ışığı, rüzgar, yağmur, gelgitler, dalgalar ve jeotermal ısı gibi bir zaman ölçeğinde doğal olarak yenilenen kaynaklardan gelen enerji olarak tanımlanmaktadır (Rahman ve Miah, 2017). Günümüzde güneş, rüzgar, hidro, biyoyakıt ve diğerleri de dahil olmak üzere yenilenebilir enerji kaynakları, düşük karbonlu ve daha sürdürülebilir bir enerji sistemine geçişin merkezinde yer almaktadır. Yenilenebilir enerji kaynaklarının üstünlükleri; (a) ya büyük rezervleri nedeniyle ya da doğa veya insanlar tarafından yenilenebildikleri için tükenmemeleri (b) kullanımları ile petrol gibi fosil kaynaklara bağımlılığın sınırlandırılmasında katkıda bulunmaları (c) ülkelerin iç enerji arzı olmaları ve çevreyi korumaları şeklinde sıralanabilir (Andreopoulou vd., 2018).

Rüzgar enerjisi, kurulum maliyetlerinde yaşanan azalmalar nedeniyle dünyada en hızlı büyüyen yenilenebilir enerji teknolojilerinden biri olmuştur. Uluslararası Yenilenebilir Enerji Ajansı'nın yayınladığı verilerine göre, karasal ve deniz üstü küresel kurulu rüzgar üretim kapasitesinin son yirmi yılda 75 kat arttığı, 1997'de 7,5 GW olan kurulu güç kapasitesinin 2018 yılının sonunda 564 GW'a yükseldiği görülmektedir. Rüzgar enerjisi santrallerinden elektrik üretimi miktarı 2009-2013 yılları arasında ikiye katlanmış ve 2016'da rüzgar enerjisi yenilenebilir enerjilerin ürettiği elektriğin % 16'sını oluşturmuştur. Güneş enerjisinin, elektrik enerjisi üretiminde, ısıtma işlemlerinde ve

desalinasyon sistemlerinde kullanımı giderek artmaktadır. Genel olarak güneş enerjisinden elektrik enerjisi üretimi iki yolla yapılmaktadır. Bunlardan biri güneş ışığını doğrudan elektrik enerjisine dönüştüren fotovoltaik hücreler, diğeri ise güneş ışığını yoğunlaştırıp elde edilen ısı ile bir aracı iş akışkanı ısıtarak konvansiyonel buhar santrallerinde olduğu gibi elektrik enerjisi üreten yoğunlaştırılmalı güneş santralleridir. 2018 yılı sonu itibariyle dünya güneş enerjisi kurulu gücü yaklaşık 486 GW olup, dünya yenilenebilir enerji kurulu gücünün %44'ünü rüzgar ve güneş enerjisi kurulu gücü oluşturmaktadır (irena.org). Fizibilite çalışmaları Türkiye'nin rüzgar enerjisinden elektrik üretimi için büyük bir potansiyele sahip olduğunu doğrulamıştır. Şekil 1.2 ve 1.2'te sırasıyla Türkiye'nin rüzgar ve güneş enerjisi haritaları görülmektedir.



Şekil 1.1. Türkiye'nin 50 m yükseklikte rüzgar hızı haritası




Şekil 1.2. Türkiye'nin güneş enerjisi haritası

Bu şekillerden de görüldüğü gibi rüzgar enerjisi potansiyeli Türkiye'nin ege bölgesi kıyılarında, güneş enerjisi ise güney bölümlerinde belirli seviyelerin üzerindedir. Teorik olarak, Türkiye'nin rüzgar enerjisi potansiyelinin yıllık 160 TWh olduğu tahmin edilmektedir. Bu potansiyelin yaklaşık 124 milyar kWh'i teknik olarak mümkündür ve bazı belirli yerler için net ekonomik potansiyel yılda yaklaşık 14 milyar kWh'e ulaşmaktadır. Ortalama güneş radyasyonu günlük 3,6 kWh/m² ve yıllık toplam radyasyon süresi 2610 saat civarında olan Türkiye'de güneş enerjisi bol miktarda bulunmaktadır. Teorik olarak, Türkiye'nin yıllık güneş enerjisi potansiyelinin 6150 TWh ve yıllık ekonomik potansiyelinin 305 TWh olduğu tahmin edilmektedir (Melikoglu, 2013). Türkiye'de ortalama güneşlenme süresi ise günlük 7,5 saattir. TEİAŞ-Yük Tevzi Dairesi Başkanlığı tarafından yayınlanan kurulu güç raporunda, Ağustos 2019 itibarıyla Türkiye'de 259 adet rüzgar enerjisi santrali bulunduğu ve toplam rüzgar enerjisi kurulu gücünün 7270 MW olduğu, 6430 adet ise güneş enerjisi santralini olduğu ve toplam güneş enerjisi kurulu gücünün 5528 MW olduğu bildirilmiştir.

Geleneksel enerji kaynaklarıyla karşılaştırıldığında, örneğin güneş ve rüzgar enerjisi gibi çoğu yenilenebilir enerji kaynakları genellikle kararsız ve değişken bir doğaya sahiptir. Güneş ışınımı ve rüzgar hızı değerleri saatler veya günler arasında büyük ölçüde değişiklikler gösterebilmektedir (Guo vd., 2018). Bu durum, özellikle yenilenebilir enerjinin büyük ölçekli entegrasyonu düşünüldüğünde enerji sistemlerinin güvenilirliğini ve istikrarını tehdit eden ölçülemeyen bir belirsizlik de ortaya çıkarmaktadır. Yenilenebilir enerji kaynaklarının değişken doğası ve oluşan belirsizlik nedeniyle yenilenebilir enerji elektrik enerjisi üretim sistemlerinin rezerv kapasitesi ve dolayısıyla güç üretim maliyeti artmaktadır (Wang vd., 2019). Bu nedenle, belirsizliği azaltmaya bir önlem olarak yenilenebilir enerji tahmini, elektrik güç ve enerji üretim sistemlerinin planlanması, yönetimi ve etkili bir şekilde işleyişini sağlamak için gerekli olmaktadır (Frias-Paredes, 2017). Yenilenebilir enerji potansiyelinin doğru bir şekilde tahmin edilmesi, yenilenebilir enerji verilerinin aralıklı, kaotik ve rastgele doğası nedeniyle zorlu bir süreçtir. Yenilenebilir enerji tahminlerini doğru bir şekilde ortaya koymak için çeşitli algoritmalar bulunmaktadır. Bunlar genellikle, fiziksel yöntemler, istatistiksel modeller, yapay zeka teknikleri ve melez yöntemler olmak üzere dört kategoriye ayrılmaktadırlar (Wang vd., 2019).

Ekonomik ya da coğrafi zorluklar nedeniyle dünyanın birçok yerinde ulusal ve bölgesel ölçekte elektrik şebekesi bulunmayan bölgeler bulunmaktadır. Enterkonnekte şebekeden bağımsız elektrik enerjisi üretimi, elektrik şebekelerine pratik olarak bağlanması imkansız olan uzak kullanıcılar için çekici bir alternatif olarak ortaya çıkmaktadır (Dasvd., 2017). Kırsal alan elektrifikasyonu, düşük enerji talebi ve kullanıcı yoğunluğu nedeniyle kişi başına yüksek başlangıç sermayesi yatırımları gerektirmektedir (Xu vd., 2016). Son zamanlarda yenilenebilir kaynaklarının ve enerji depolamasının azalan sermaye maliyeti, rüzgar ve güneş enerjisi gibi yenilenebilir enerji kaynaklarına sahip kırsal bölgelerdeki yük taleplerine elektrik enerjisi sağlamak amacıyla söz konusu teknolojilerin uygulanmasını teşvik etmektedir (Khodayar, 2017; Amutha ve Rajini, 2016). Güç talebini karşılamak için yenilenebilir enerji teknolojilerinin kullanılması, geleneksel şebeke genişletme yöntemine kıyasla hem elektrik maliyetini hem de çevresel endişeleri azaltabilmektedir (Hafez ve Bhattacharya, 2012). Daha öncede bahsedildiği gibi, yenilenebilir enerji kaynaklarının değişken doğası bu kaynakları kullanan yenilenebilir enerji sistemlerinin ürettiği elektrik enerjisi miktarını etkilemektedir. Bu değişkenlikten kaynaklanan sorun, bir Hibrit Yenilenebilir Enerji Sistemi (HYES) oluşturmak için iki veya daha fazla enerji kaynağını batarya gibi bir yedekleme birimi ile birleştirilerek çözülebilmektedir (Zahraee vd., 2016). Bir hibrit enerji sistemi, farklı yenilenebilir enerji kaynaklarının tek bir sistem oluşturmak için birleştirilmesinden meydana gelmekte ve genellikle tek enerji kaynağı tabanlı sistemlerden daha uygun maliyetli ve güvenilir olmaktadır. Son zamanlarda, hibrit yenilenebilir enerji güç sistemlerinin uygulanması dikkate değer bir artış göstermekte olup bu sistemlerin kurulması ve işletilmesi açısından optimum hibrit sistem tasarımının belirlenmesi, güvenilir ve ekonomik bir güç kaynağına sahip olmak için çok önemlidir. Talebin üzerinde elektrik arzı sağlayan sistem konfigürasyonu, HYES'in ilk yatırım maliyetini artırmakta, yetersiz kapasiteye sahip bir sistem konfigürasyonunda ise güç kaynağı güvenilirliğini sağlamak zordur. Bu nedenle, sistem kapasitesinin optimize edilmesi gerekir. Hibrit enerji sistemlerindeki her bir bileşenin uygun şekilde boyutlandırılması, bu sistemlerin tekno-ekonomik özelliği için önemli bir faktördür. Bu nedenle, yenilenebilir kaynaklarının enerji piyasasına girmesi, temel olarak bu tür hibrit enerji sistemlerini en uygun şekilde tasarlamak için kullanılan boyutlandırma yöntemlerine bağlıdır (Luna-Rubio vd., 2012). Bununla birlikte, güç sistemlerinin boyutlandırma tekniklerinin seçimi, hesaplama sadeliğinin yanı sıra mevcut kaynakların etkin kullanımı açısından kilit bir konudur (Sanajaoba ve Fernandez, 2016). Hibrit

yenilenebilir enerji güç santrallerinin çeşitli sistem bileşenlerini seçmek için, ekonomik kısıtlar ve optimizasyon yaklaşımları gibi farklı boyutlandırma kriterleri uygulanarak enerji üretim maliyeti ve performansını karşılaştırmak için kullanılmaktadır (Anoune vd., 2018). Sermaye yatırımı ve sistem güvenilirliği arasında iyi bir eşleşme elde etmek için, tüm hibrit yenilenebilir enerji sistemini oluşturan bileşenlerinin optimum bir şekilde boyutlandırılması gerekmektedir. Optimum bir boyutlandırma elde etme hedefi, birden fazla tipte enerji kaynağı ve enerji depolama kombinasyonu ile zorlu bir süreç haline gelir. Bu nedenle, boyutlandırma problemini çözmek için optimizasyon teknikleri gereklidir. Hibrit sistemlerde boyutlandırma aşamasıyla başa çıkmak için önerilen birçok algoritma bulunmaktadır. Genel olarak boyutlandırma yöntemleri, şekil 1.3'de görüldüğü gibi, karmaşıklık düzeylerine göre; olasılıksal, analitik, yinelemeli ve hibrit olarak dört grupta değerlendirilmektedir (Luna-Rubio vd., 2012; Rullo vd., 2019).



Şekil 1.3. Optimizasyon yöntemlerinin sınıflandırılması.

Diğer taraftan, bir başka sınıflandırmada HOMER ve HYBRIDS gibi yazılım araçları ile yapılan optimizasyon yöntemleri, olasılıksal, analitik ve yinelemeli optimizasyon yöntemlerini içine alan geleneksel yöntemler, yapay zeka (AI) yöntemleri ve hibrit yöntemler şeklinde yapılmaktadır (Lian vd., 2019).

Yenilenebilir enerji sistemlerinin kurulum maliyeti azaldıkça elektrik enerjisi üretiminde yenilenebilir enerji kaynaklarının kullanımının yaygınlaşması, kaynak bazlı olarak enerji üretiminde dışa bağımlı olan ülkeler için bir fırsat oluşturmaktadır. Bu nedenle, yenilenebilir enerji potansiyeline sahip ülkelerde gerek büyük ölçekli gerekse küçük ölçekli yenilenebilir enerji güç üretim santrallerinin kurulması enerji arz güvenliği açısından daha da önemlidir. Güneş ve rüzgar enerjisi gibi değişken bir doğaya sahip yenilenebilir kaynakların potansiyellerinin doğru olarak belirlenmesi ve gelecekteki karakteristiklerinin tahmini, bu kaynakları kullanacak güç üretim ünitelerinin seçilmesi ve kurulumu açısından çok önemli olmaktadır. Son zamanlarda,

makine öğrenmesi, bilgisayarlara öğrenme yeteneği sağlamaya çalışan bir bilgisayar bilimi alanı olarak karşımıza çıkmıştır. Makine öğrenmesi, verilerden öğrenmek ve verilere dayalı tahminleri öğrenmek için yöntemler ve algoritmalar geliştirmeyi amaçlamaktadır. Makine öğrenme algoritmaları, veri kümesinin davranışını, model girdi özelliklerini beklenen çıktıya ve model çıktı özelliklerini tarihsel kayıtlarına göre tanımlamak için başarıyla kullanılmaktadır. Makine öğrenimi algoritmaları, rüzgar hızı verilerine dayalı olarak rüzgar enerjisini ve güneş verilerine göre de güneş enerjisini tahmin etmenin alternatiflerinden biri olmuştur.

Yukarıda açıklanan gerekçelere paralel olarak bu tez çalışmasında, öncelikle Türkiye’de çeşitli noktalar için meteorolojik ölçüm istasyonlarından alınan rüzgar hızı ve güneş radyasyonu gibi meteorolojik verileri kullanarak çeşitli makine öğrenmesi metodlarıyla rüzgar hızı ve güneş radyasyonu değerlerinin kısa ve uzun dönem tahminleri yapılmış, daha sonra belirli bir yük talebi oluşturularak yine Türkiye’de ki farklı noktalarda kurulacağı düşünülen yenilenebilir enerji güç üretim sistemlerinin optimal boyutlarının belirlenmesi, Güç Tedariki Kaybı Olasılığı güvenilirlik göstergesi ile minimum bir değere getirilmiş maliyet değeri göz önünde bulundurularak zaman serisi analizi metoduyla deterministik bir yaklaşımla ve ayrıca yapay zeka yöntemleri kullanılarak yapılmıştır.

Bu bölümde açıklanan ve tez çalışmasında incelenecek konuyu ve tezin amacını ifade edengiriş bölümünden sonra, tez çalışmasında oluşturulan diğer bölümler ve kapsamaları aşağıda özetlenmiştir.

Bölüm 2’de, hem rüzgar hem de güneş enerjisi tahminleri için literatür araştırılması sunulmuş, hibrit yenilenebilir enerji güç üretim sistemleri konusunda yapılan çalışmalar özetlenmiştir.

Bölüm 3’te, incelenen lokasyonlar tanıtılmış, rüzgar ve güneş enerjisi tahminlerinde kullanılan teorik altyapı tanıtılmış, hibrit yenilenebilir enerji sistemleri için güç ünitelerinin özellikleri verilerek optimal sisteminin belirlenmesine yönelik hesaplama yöntemi sunulmuştur.

Bölüm 4’te, seçilen lokasyonlar için makine öğrenmesi algoritmaları kullanılarak rüzgar ve güneş enerjisinin kısa ve uzun dönem tahmini için elde edilen sonuçlar sunulmuştur.

Bölüm 5’te deterministik yöntem ve yapay zeka yaklaşımları kullanılarak oluşturulan optimal sistem boyutları ile ilgili sonuçlar karşılaştırılarak verilmiştir.

Bölüm 6’da ise genel sonuçlar verilerek tartışılmış ve öneriler sunulmuştur.



BÖLÜM II

LİTERATÜR ARAŞTIRMASI

Bu bölümde, istatistiksel yöntemler ve makine öğrenmesi yöntemleri kullanılarak kısa ve uzun vadeli rüzgar ve güneş enerjisi tahminlerinin yapıldığı literatürde bulunan çalışmalar sunulmuş, hibrit yenilenebilir enerji güç üretim sistemleri konusunda diğer araştırmacıların yaptığı çalışmalar özetlenmiştir.

2.1 Rüzgar ve Güneş Enerjisi Tahminleri İle İlgili Yapılan Çalışmalar

Rüzgar enerjisi tahmini ile ilgili çalışmalar, kısa vadeli rüzgar enerjisi tahmini ve uzun vadeli olmak üzere iki kategoride değerlendirilebilir. Kısa vadeli rüzgar enerjisi tahmin yöntemleri rüzgar enerjisini kısa zaman periyotlarına göre, yani 1 saat ile birkaç gün sonrasına göre tahmin etmeye çalışırken, uzun vadeli rüzgar enerjisi tahmin yöntemleri rüzgar gücünü daha uzun zaman periyotlarına, yani birkaç gün ile 1 yıl sonrasına göre tahmin etmeye çalışır. İstatistiksel ve makine öğrenimi yöntemleriyle ilgili olarak yürütülen çalışmalar aşağıda kısaca özetlenmiştir.

İstatistiksel yöntemler kullanarak kısa vadeli rüzgar enerjisi tahminleriyle ilgili olarak, (Rajagopalan ve Santoso, 2009), ARMA modelini rüzgar hızına uygulamış, zaman serisi verileri ve modelin bir saatlik tahminlerde ve bir grup rüzgar santrali verilerinde başarılı olduğunu gözlemlemişlerdir. Abdelaziz vd. (2012), ARIMA modeline dayanan bir yöntem önermiş ve sonuçları kalıcılık yöntemleriyle karşılaştırmıştır. Cadenas vd.(2016), rüzgar enerjisi tahmini için iki istatistiksel model, tek değişkenli bir ARIMA modeli ve çok değişkenli bir NARX modeli kullanmışlar ve NARX modelinin ARIMA modelinden daha iyi bir adım önde tahmin gerçekleştirdiği sonucuna varmışlardır. Dowell ve Pinson (2016), farklı uzamsal konumlardaki birçok rüzgar santralinin çok kısa vadeli rüzgar enerjisi tahmini için sVAR modelini kullanan bir yöntem önermişlerdir. Lima vd. (2017), rüzgar gücünün 72 saat sonrasını doğru bir şekilde tahmin edilmesini sağlamak için bir meteorolojik-istatistik modeli önermişlerdir. Wang vd. (2018), kısa vadede rüzgar gücünü tahmin etmek için ARMA modelini kullanmışlar ve başarılı sonuçlar elde etmişlerdir. Robles-Rodriguez ve Dochain (2018), zaman serisi ayrışması ve doğrusal olmama durumunu kapsayan iki katlı bir mekanizma kullanan 48

saat ileriye dönükrüzgar gücünün doğru tahmin edilmesi için ARMAX tabanlı bir istatistiksel yöntem önermişlerdir. Pearre ve Swan (2018), tahmin hatalarını kataloglamak ve düzeltmek için istatistiksel yöntemler önermişler ve 1–6 saat ileriye dönük tahminlerde iyi performans elde etmişlerdir.

Makine öğrenme yöntemlerini kullanarak kısa vadeli rüzgar enerjisi tahminleriyle ilgili olarak, Sideratos ve Hatziargyriou (2007) rüzgar hızının büyüklüğüne ve rüzgar hızına dayalı verilerin girişini alarak bir rüzgar santrali güç çıkışının, 48 saatlik bir ufukla doğru tahmin edilmesi için sinir ağları ve bulanık mantığın bir kombinasyonunu önermişlerdir. Rahmani vd. (2013), rüzgar enerjisi tahmini için karınca kolonisi ve parçacık sürüsü optimizasyon algoritmalarının bir melezini önermişlerdir. Najeebullah vd. (2015), özellik seçimi ve regresyon için makine öğrenimi tekniklerinin bir kombinasyonunu kullanan Makine Öğrenimine Dayalı Kısa Vadeli Rüzgar Enerjisi Tahmin sistemi önermişlerdir. Zhang vd. (2015), rüzgar hızı tahmini için doğrusal regresyon, çok katmanlı algılayıcı ve destek vektör makinesi algoritmalarını kullanmışlardır. Peng vd. (2017), rüzgar enerjisi tahmini için ayrışmaya ve AdaBoost-ekstrem öğrenme makinesine dayanan hibrit bir model önermişlerdir. Lahouar ve Slama (2017), rüzgar gücünü tahmin etmek için sadece rüzgar hızını kullanmak dışında çeşitli hava faktörlerini kullanarak Rastgele Orman Algoritmasını kullanmışlardır. Li vd. (2018) ve Sun vd. (2018), rüzgar enerjisi tahmini için veri madenciliği tabanlı yöntemler önermişlerdir. Wang vd. (2018), sayısal hava tahminlerini ve rüzgar verilerini daha iyi ele almak için derin öğrenme mimarisi ve k-meansgelen kümeleme algoritması önermişlerdir. Zheng vd. (2018), mikroşebekelerde rüzgar enerjisi tahmini için genetik algoritmayı, parçacık sürüoptimizasyon algoritmasını ve uyarlanabilir nöro-bulanık çıkarım sistemlerini birleştiren hibrit bir yaklaşım önermişlerdir. Yu vd. (2019), Qin vd. (2019) ve Shi vd. (2018), rüzgar enerjisini tahmin etmek için uzun kısa süreli bellek tabanlı derin öğrenme mimarilerini kullanmışlardır.

İstatistiksel yöntemler kullanarak uzun vadeli rüzgar enerjisi tahminleriyle ilgili olarak, Eldali vd. (2016), ARIMA modelini ERCOT verilerinden rüzgar gücünü daha iyi tahmin etmek için saatlik rüzgar gücü - tahmini ve gerçek – kullanmışlardır. De Alencar vd. (2017), yapay sinir ağı modelleri, ARIMA ve hibrid modelleri kullanarak ultra kısa, kısa, orta ve uzun vadeli rüzgar enerjisi tahminleri için farklı modeller önermişlerdir. Ekström vd. (2018), vektör otoregresif tabanlı bir metodoloji kullanılarak ölçüm verileri

olmadan birden fazla rüzgar santralının rüzgar enerjisi üretiminin istatistiksel modellenmesi için bir yöntem önermişlerdir. Dokuz vd. (2018), rüzgar gücünün doğru hesaplanması için ve bir yıllık rüzgar hızını daha iyi tahmin etmek için ARIMA ve kümeleme tabanlı bir yöntem önermişlerdir.

Makine öğrenme yöntemlerini kullanarak uzun vadeli rüzgar enerjisi tahminleriyle ilgili olarak ise, Barbounis vd. (2006), birbirine yakın farklı 4 lokasyonun meteorolojik verilerine göre üç gün ilerisi için bir rüzgar santralının rüzgar gücünü tahmin etmek amacıyla yerel tekrarlayan sinir ağlarını kullanmışlardır. Khan vd. (2014), rüzgar gücünün 1 saat ila 1 yıl ilerisindeki değerlerini tahmin etmek için Kartezyen Genetik Programlama ve yapay sinir ağlarına dayanan bir teknik önermişlerdir. Wang vd. (2015), üç farklı saha için orta vadeli rüzgar enerjisini tahmin etmek için bir Destek Vektör Regresyonu, mevsimsel endeks ayarı, Elman tekrarlayan sinir ağı hibrit modelini önermişlerdir. Dumitru ve Gligor (2017), günlük ortalama rüzgar enerjisi tahmini için ileri beslemeli yapay sinir ağlarının kullanımını araştırmışlardır. Yan ve Ouyang (2019), bir rüzgar santralının 3 aylık ilerisi için rüzgar enerjisi üretimini tahmin etmek amacıyla hem fiziksel hem de veri madenciliği tabanlı teknikler kullanan iki aşamalı hibrit bir rüzgar enerjisi tahmin modeli önermişlerdir. Maroufpoor vd. (2019), meteorolojik değişkenler kullanarak rüzgar hızı tahmini için altı farklı makine sezgisel yapay zeka algoritmasının kullanımını araştırmışlardır.

Sharma vd. (2011), çalışmalarında, veri seti olarak ABD Ulusal Meteoroloji Dairesinden alınan verileri kullanarak, destek vektör makinesi ve linear regresyon performanslarını kıyaslamışlar, yedi ayrı öznitelik kullanılarak oluşturulan destek vektör makinesi tabanlı modelin, mevcut tahmin tabanlı modellere göre %27 daha doğru sonuç verdiğini göstermişlerdir. Shi vd.(2012), yaptıkları çalışmalarında, güneş enerjisi panellerinden üretilecek güç tahmininin sistem güvenilirliği ve teşvik amaçlı kullanılabilmesine değinmişler, panellerden elde edilecek güç tahmini için destek vektör makinesi kullanarak; açık, bulutlu, sisli ve yağmurlu havaları öznitelik olarak vermişlerdir. Çalışmalarından elde ettikleri sonuçlarda, ertesi gün için güç tahmininin başarılı bir şekilde Çin'de bir PV istasyonunda denenerek gerçekleştiğini göstermişlerdir. Yousif ve Kazem (2016), güneş enerji tahmini için destek vektör makinesi ve MLP kullanmışlar, veri setinde güneş ışınımı ve ortam sıcaklığı değerlerini giriş verisi, PV güç çıktısı değerini ise çıkış verisi olarak vermişlerdir. Destek vektör

makinesi kullanarak 0.9844, MLP ile ise 0.9701 R^2 değerlerine sahip bir model kurulduğu gösterilip diğer çalışmalara kıyasla başarılı olduğunu belirtmişlerdir. Zeng ve Qiao (2013), kısa dönem güneş enerji tahmini gerçekleştirmişler ve güç tahmini için destek vektör makinesi tabanlı bir model sunmuşlardır. Destek vektör makinesinin istatistiksel AR modeli ve RBFNN'ye kıyasla daha iyi performans sergilediği gözlemlenmiştir. Yang vd. (2014), yağış olasılığı, güneş ışınlamı ve sıcaklık verileri kullanılarak güneş enerji panellerinin bir sonraki gün için güç tahmini gerçekleştirmişlerdir. Veri eğitimi için destek vektör regresyon, ertesi günkü güneş enerji potansiyel tahmini için bulanık mantık yapısı kullanılmıştır. Çalışmada önerdikleri yeni yöntemi uygulayarak, elde edilen sonuçlar sunmuşlardır. Sonuç olarak önerilen hibrit yöntemin, destek vektör makinesi ve geleneksel sinir ağlarına kıyasla daha başarılı performans sergilediğini belirtmişlerdir. Hossain vd. (2012), makine öğrenmesi algoritmaları kullanarak 6 saat sonra elde edilecek güneş enerji potansiyelinin tahmini gerçekleştirmişlerdir. 10 katlı çaprazlama kullanılarak gerçekleştirilen deneyde en iyi korelasyon katsayısını MLP gösterirken, DVM ve LMS'in yakın performanslar sergilediği gözlemlenmiştir. Wang vd. (2017), gelecek gün için PV panellerden üretilecek güneş enerjisi miktarını ve güç tahminini yapmayı amaçlamışlardır. Makine öğrenmesi algoritmalarından destek vektör makinesi ve k-En Yakın Komşu (kNN) algoritması kullanarak, performans kıyaslaması işlemi gerçekleştirmişlerdir. Elde ettikleri sonuçlarda, küçük ölçekli verilerde destek vektör makinesinin daha başarılı olduğu yüksek ölçekte ise k-En Yakın Komşu algoritmasının daha başarılı sonuç verdiği ifade edilmiştir. Tang vd. (2017), tarafından yapılan çalışmada, geleceğe dair güneş enerji potansiyel tahmini için LASSO algoritması tabanlı algoritma kullanarak, iki farklı veri seti sınanmıştır. Kullanılan algoritmanın az veri ile çalışırken diğer mevcut yöntemlere kıyasla daha iyi performans sergilediği gösterilmiştir. Zhang ve Wang (2015), yaptıkları çalışmada geleceğe dair güç tahmini için, k-En Yakın Komşu algoritması ve Çekirdek Yoğunluk Tahmini (Kernel Density Estimator) yöntemini kullanmışlardır. Çalışmada ilk olarak kNN algoritması, veri setindeki aynı hava koşullarına sahip günleri keşfetmek için kullanılmaktadır. Ardından Çekirdek Yoğunluk Tahmini ile olasılık yoğunluğu tahmin edilmektedir. Önerilen yaklaşımda elde edilen sonuçlar diğer çalışmalardan elde edilen veriler ile teyit edilmiştir.

2.2 Hibrit Yenilenebilir Güç Sistemleri İle İlgili Yapılan Çalışmalar

Hibrit yenilenebilir güç sistemleri ile ilgili olarak yapılan literatür araştırmasında bu sistemlerin farklı yönlerden araştırıldığı görülmektedir. Bunlar arasında güç yönetimi ve boyut optimizasyonu metodolojisi en önemlileri olarak göze çarpmaktadır. Şebekeye bağlı ve şebekeden bağımsız yenilenebilir tabanlı enerji sistemlerinde, farklı bileşenler birbirleriyle hibrit bir sistem şeklinde birleştirilir. Hibrit bir sistemde, güvenilir ve uygun maliyetli bir enerji sistemine sahip olmak için her bir bileşenin güç yönetimi ve boyutu en uygun şekilde belirlenmelidir. Güneş/batarya, rüzgar/batarya, güneş/rüzgar/batarya, güneş/hidrojen, rüzgar/hidrojen, güneş/rüzgar/hidrojen, güneş/rüzgar/batarya/hidrojen, güneş/dizel, güneş/dizel/batarya, rüzgar/dizel ve güneş/rüzgar/dizel gibi kaynakların birlikte kullanıldığı farklı hibrit güç sistemlerinin oluşturulması mümkündür. Aşağıda bu şekilde oluşturulan hibrit sistemlerle ilgili olarak yapılan bazı çalışmalar özetlenmiştir.

Maleki vd. (2017), tarafından yapılan çalışmada, Doğu İran'daki güneş enerjisi çiftlikleri için olası lokasyonları, çoklu değerlendirme kriterlerine göre belirlemek için Coğrafi Bilgi Sistemi (CBS) ve Yapay Arı Sürüsü Optimizasyonu yöntemini kullanan birleşik bir yaklaşım kullanılmıştır. Çalışmada oluşturulan model, PV sistemlerinin yerini, sosyo-ekonomik, teknik ve çevresel perspektiflerden optimize etmektedir. Ayrıca, çalışmada tek başına bir PV sisteminin optimum boyutlandırılması için, güç tedarik kaybı olasılığı (LPSP) değerini en üst düzeye çıkararak ve teknik kısıtlamalara tabi olarak yaşam döngüsü maliyetini en aza indirerek yük talebinin sürekli olarak karşılanması önerilmektedir.

Hatata vd. (2018), tarafından yapılan çalışmada, Klonal Seçim Algoritması (CLONALG) kullanarak Güneş/Rüzgar/Batarya hibrit güç sisteminin optimum büyüklüğünü elde etmek için yeni bir teknik önerilmektedir. Önerilen yöntemin amacı, küçük dalgalanma oranına sahip ve minimum maliyetli bir hibrit güç sistemi boyutunun belirlenmesidir. Çalışmadan elde edilen sonuçlar, önerilen yöntemin hibridizasyon işlemi için etkili olduğunu ve sistemin istenilen hedeflerine ulaşabileceğini kanıtlamıştır.

Ahmadi ve Abdi (2016), fotovoltaik panel, rüzgar türbini ve bataryadan oluşan bağımsız bir hibrit güç sisteminin optimum boyutlandırılması için, Hibrid Big Bang – Big Crunch (HBB-BC) algoritmasına dayanan yöntemin sunulduğu bir çalışma yürütmüşlerdir. Çalışmada yapılan optimizasyon işlemi, sistemin toplam maliyetinin şimdiki değerini en aza indirip yük talebini sürekli karşılamak esasına dayanmaktadır. Simülasyon sonuçları, yüksek doğrulukta HBB-BC algoritmasının en uygun çözümü bulabileceğini ve Parçacık Sürüsü Optimizasyonu (PSO) ve Kesikli Uyum Arama algoritmalarına kıyasla en iyi performansa sahip olduğunu göstermiştir.

Zhang vd. (2018), yaptıkları çalışmada, güneş ve rüzgar enerjisi ile çalışan hibrit ters ozmos desalinasyon tesisi oluşturmak amacıyla üç otonom şema, yani güneş/rüzgar/batarya/su arıtma sistemi, güneş/su arıtma sistemi ve rüzgar/batarya/su arıtma sistemi olasılıklarını göz önünde bulundurarak sistem tasarımı gerçekleştirmişlerdir. Yaşam döngüsü maliyetini en aza indiren optimizasyonun işlevi, ters osmoz desalinasyon sistemini güçlendirmek için farklı yenilenebilir enerji sistemi yapılandırmasının fizibilitesini ölçmek için kullanılmıştır. Çalışmada güç tedarik kaybı olasılığı, hibrit sistemlerin güvenilirliğini ölçmek için kullanılmış, tavlama ve kaotik aramalara dayanan yeni bir hibrit arama algoritması sunulmuştur. Çalışmadan elde edilen sonuçlar, karma kaotik arama/simüle edilmiş tavlama algoritması/veya hibrit arama algoritmasının, tek bir algoritmadan, yani kaotik arama ve simüle edilmiş tavlamadan daha faydalı sonuçlar verdiğini göstermektedir.

Sanchez vd. (2014), tarafından yapılan çalışmada, Meksika'nın güneydoğu bölgesinde bulunan izole bir konut yükünün güç ihtiyacını karşılamak için kurulması düşünülen bir rüzgar-fotovoltaik yakıt hücresi sisteminin optimum büyüklüğünün hesaplanmasında Parçacık Sürüsü Algoritması kullanılmış, enerji arzında güvenilirlik ve maliyet arasındaki bağılılığı karşılamak için en iyi sistem yapılandırması bulunmuştur. Optimal konfigürasyonun, bir yıl boyunca konut tipi değişken yük talebini sağlayan 17 fotovoltaik modül, 4 kW rüzgar türbini ve 3 kW yakıt hücresi biriminden oluştuğu belirlenmiştir.

Maleki ve Rosen (2017), kuzeydoğu İran'daki konut uygulamaları için şebekeye bağlı hibrit rüzgar/hidrojen kombine ısı ve güç sistemleri için ekonomik bir model ve optimizasyon prosedürü geliştirilmişlerdir. Çalışmada oluşturulan modelde, enerji

retim maliyeti, yerel Őebekeyle elektrik ticareti, rzgar/hidrojen enerji sisteminden elektrik enerjisi retimi, yakıt hcresinden termal geri kazanım gibi eŐitli faktrler gz nnde bulundurularak optimizasyonda, konut uygulamaları iin sistemin toplam maliyetini en aza indirmek hedeflenmiŐ, bu amaca ulaŐmak iin, paracak srs optimizasyonuna dayanan etkin bir optimizasyon yntemi nerilmiŐtir. alıŐmanın sonularına gre, hibrit sistemin konut yk iin en uygun maliyetli bir sistem olduĐu gsterilmiŐtir.

Fathy (2016) yaptıĐı alıŐmada belirli bir uzak alan ykn karŐılamak iin fotovoltaik modller, rzgar trbinleri ve yakıt hcrelerinden oluŐan hibrit bir sistemin optimum boyutlandırmasını belirlemek iin maden patlatma algoritmasını (MBA) uygulamıŐtır. alıŐmada, hibridizasyon iŐlemi, gneŐ radyasyonu, evre sıcaklıĐı ve rzgar hızı iin llen gerek verilere dayanarak gerekleŐtirilmiŐ, optimum boyutlandırma iŐlemi, meta-sezgisel optimizasyon tekniĐi, paracak srs optimizasyonu, guguk kuŐu arama optimizasyonu ve yapay arı kolonisi algoritmalarını kullanarak minimum yıllık maliyete gre yapılmıŐtır. Elde edilen sonular, hibrit fotovoltaik panel/rzgar trbini/yakıt hcresi sistemini diĐer algoritmalarından daha byk boyutlandırma alanında MBA kullanımını teŐvik etmektedir.

Yahiaoui vd. (2017), tarafından yapıŐan alıŐmada, en son sr zeka algoritmalarından biri olan, yani gri kurtlardan esinlenen Gray Wolf Optimizer'ın (GWO) uygulanması sunulmuŐtur. GWO algoritması, doĐadaki gri kurtların liderlik hiyerarŐisini ve avlanma mekanizmasını taklit etmekte olup nerilen strateji Cezayir'in gneyindeki "Djanet" adlı izole kırsal kyde hibrit enerji retim sisteminin optimum tasarım iin uygulanmıŐtır. nerilen yaklaŐımı test etmek iin bir fotovoltaik panel, dizel jeneratr, batarya ve ykten oluŐan bir g sistemi dikkate alınmıŐ, elde edilen sonular Partikl Srs Optimizasyonu (PSO) algoritması ile karŐılaŐtırılmıŐtır. Optimum boyutlandırmaya sahip nerilen sistemin, bir PV panel iin 75W kapasiteli 33 PV panelden oluŐtuĐu, PV panellerinden retilen gcn, yk talebi iin yaklaŐık % 70 oranında g saĐladıĐı grlmŐtr.

Wu vd. (2018), tarafından yapılan alıŐmada, ime suyu tedariĐi amalı baĐımsız bir blgenin elektrik yk talebini karŐılamak iin ters ozmosdesalinasyon sistemi tabanlı dizel ve fotovoltaik enerji santralinin boyutu optimize edilmiŐtir. Batarya boyutu,

fotovoltaik sistemin alanı ve önerilen hibrit sistem içindeki dizel jeneratörün yakıt tüketimi, sistemin yaşam döngüsü maliyetini en aza indirecek şekilde optimize edilmiştir. Çalışmada, bu amaçla bir güç yönetimi stratejisi tasarlanmış ve tabu aramaya dayalı etkili bir meta-sezgisel teknik kullanılmıştır. Çalışmadan elde edilen sonuçlardan, fotovoltaik/dizel/batarya/ters ozmos sisteminin, incelenen bölge için tek bir dizel sisteme veya tek bir fotovoltaik sisteme göre ekonomik ve çevresel açıdan avantajlı olduğu görülmüştür.

Ramli vd. (2018), tarafından yapılan çalışmada, Suudi Arabistan'ın Yanbu şehri için Çok Amaçlı Kendinden Uyarlamalı Diferansiyel Evrim (MOSaDE) algoritması kullanılarak, batarya depolama özellikli bir PV/rüzgar/dizel hibrit mikroşebeke sisteminin optimum boyutlandırılması yapılmıştır. Çok amaçlı optimizasyon yaklaşımı, elektrik enerjisi maliyetini ve yenilenebilir enerji faktörünü analiz etmek için kullanılmıştır. Çalışmadan elde edilen sonuçlar, hibrit sistemlerde optimizasyon proseslerinde kullanılan algoritmanın uygulanabileceğini doğrulamıştır.

Dash ve Bajpai (2015), bağımsız bir PV/batarya/yakıt hücresi hibrit sistemi için bir güç yönetimi kontrol stratejisi geliştirmişlerdir. Önerilen güç yönetimi stratejisi, üretilen gücü yük talebi ile eşleştirerek boş yük ihtiyacını ortadan kaldırmaktadır. Yapılan çalışmada sistem güvenilirliği ve maliyeti dikkate alınmamıştır.

Yang vd. (2008), güç tedariki kaybı olasılığı güvenilirlik göstergesini göz önünde bulundurarak, genetik algoritmaya (GA) dayalı bağımsız bir hibrid güneş/rüzgar sistemi için bir boyutlandırma metodolojisi önermişlerdir. Önerilen metodoloji, istenen bir güç tedariki kaybı olasılığı değerinde ve minimum sistem maliyetinde optimum sistem konfigürasyonunu belirlemek için kullanılmıştır. Güneş ve rüzgar enerjilerinin birlikte kullanılarak enerji talebi olan yerde bu talebi karşılamak için hibrit sistem kullanılmasının en uygun çözüm olduğu ifade edilmiştir.

Diaf vd. (2008), çeşitli çevresel koşulları göz önünde bulundurarak hibrit bir PV/rüzgar sisteminin optimum tasarımını incelemişlerdir. Hibrit sistem konfigürasyonları için enerji maliyetinin büyük ölçüde yenilenebilir enerji potansiyeline bağlı olduğu bildirilmiştir. İncelenen lokasyonlar neredeyse aynı güneş enerjisi potansiyeline sahip

olduğu için, rüzgar enerjisi potansiyelinin enerji maliyetini güçlü bir şekilde etkilediği görülmüştür.

Eteiba vd. (2018), küçük bir köy için talep edilen gücü sağlamak amacıyla bir PV/biyokütle hibrit yenilenebilir enerji sisteminin batarya desteği durumu ile fizibilitesini araştırmışlardır. Çalışmada dört farklı meta-sezgisel teknik kullanılarak en uygun boyutlandırma yapılmıştır. Ateşböceği algoritmasının (FA) diğer araştırılan algoritmalar arasında minimum hesaplama süresi ve en iyi performansı elde ettiği bulunmuştur.

Wang ve Nehrir (2008), şebekeden bağımsız uygulamalar için, yakıt hücresi/elektrolizör kombinasyonunun yedek bir sistem olarak kullanıldığı bir hibrit rüzgar/fotovoltaik panel/yakıt hücresi enerji sistemi önermişlerdir. Genel bir güç yönetimi stratejisi, farklı enerji kaynakları ve depolama birimi arasındaki güç akışlarını yönetmek için tasarlanmıştır.

Jamshidi ve Askarzadeh (2019), çalışma rezervi ve yük ve güneş enerjisi belirsizlikleri varlığında şebekeden bağımsız bir topluluğun elektrik gücünü sağlamak için fotovoltaik panel, yakıt hücresi ve dizel jeneratörden oluşan bir hibrit sistemin çok amaçlı tasarımını sunmuşlardır. Yapılan çalışmada, güç tedariki kaybı olasılığı değerini ve sistem maliyetini en aza indirmek için çok amaçlı karga arama algoritması (MOCSA) kullanılmıştır. Farklı parametrelerin (yakıt fiyatı, yakıt hücresi sistem ekipmanının maliyeti, emisyon maliyeti, vb.) boyutlandırma sonuçları üzerindeki etkisi araştırılmıştır.

Khiareddine (2018), su pompalama amaçları için kullanılan PV/rüzgar/hidrojen/batarya içeren bağımsız bir sistemin tekno-ekonomik analizini araştırmışlardır. Elde edilen sonuçlar, yenilenebilir kaynakların hibridizasyonunun sistem maliyetinin düşürülmesinde önemli rolü olduğunu ortaya koymaktadır.

Yang vd. (2008), batarya kullanan bir hibrit güneş/rüzgar sistemi konfigürasyonlarını optimize etmek için optimum bir boyutlandırma yöntemi önermişlerdir. Genetik algoritmayadaya, güç tedarik kaybı olasılığı değeri ile elde edebilecek optimum sistem yapılandırmasını hesaplamak için bir boyutlandırma yöntemi geliştirilmişlerdir.

Optimizasyon sürecine dahil edilen karar deęişkenleri olarak, PV modül, rüzgar türbini, bataryasayısı, fotovoltaiik panel eğim açısı ve rüzgar türbini kurulum yükseklięi seçilmiştir. Önerilen yöntem, bir telekomünikasyon röle istasyonu için güç saęlayan bir hibrit sistemin analizine uygulanmış ve iyi bir optimizasyon performansı bulunmuştur. Çalışmada 3-5 günlük pil depolama alanına sahip hibrit sistemin, incelenen durum için % 1 ve % 2'lik istenen LPSP için uygun olduęu bulunmuştur.

Ma ve Javed (2019), tarafından yapılan çalışmada, bir adaya enerji saęlamak için yenilenebilir enerji tabanlı hibrit enerji üretim sisteminin boyutlandırılması amacıyla bir metodoloji geliştirilmiştir. Önerilen yöntem ile yenilenebilir kaynaklarının deęişen doęunluęunun, batarya büyüklüęü, sistem güvenilirlięi, net şimdiki maliyet, fazla enerji ve geri ödeme süresi gibi farklı anahtar parametreler üzerindeki etkileri kapsamlı bir şekilde analiz edilmiştir. Çalışmada, rüzgar ve güneş enerjisi kullanım oranlarını gösteren doęunluk faktörüne göre, optimum sistem belirlenmeye çalışılmıştır.

Moghaddam vd. (2019), çiçek tozlaşma algoritması (FPA) kullanarak toplam net şimdiki maliyeti en aza indirmek amacıyla fotovoltaiik paneller, rüzgar türbini ve yakıt hücresi dahil olmak üzere oluşturulan hibrit sistemlerin optimum tasarımını ve enerji yönetimini sunmuşlardır. Çalışmada, beklenen enerji kaybı (LOEE) ve beklenen yük kaybı (LOLE) gibi teknik kısıtlar olarak kabul edilen güvenilirlik endeksleri kullanılmış, FPA performansı, öğretim-öğrenme tabanlı optimizasyon (TLBO), parçacık sürü optimizasyonu (PSO) yöntemleri ile karşılaştırılmıştır. Sonuçlar, önerilen metodolojinin TLBO ve PSO'ya kıyasla farklı güvenilirlik endekslerinde ve farklı hibrit sistemlerde hızlı yakınsama, düşük maliyet ve daha iyi güvenilirlik deęerleri ile optimal karar deęişkenlerini kolayca bulduęunu göstermiştir.

Maleki ve Pourfayaz (2017), tarafından yapılan çalışmada, minimum yıllık toplam maliyetle (TAC) yük talebini sürekli olarak karşılamak amacıyla bir PV/WT/batarya hibrit sisteminin optimum boyutlandırılması için farklı evrimsel algoritmaların performansını deęerlendirilmiştir. Çalışmada tüm bileşenler modellenmiş ve yıllık toplam maliyete dayanarak bir amaç fonksiyonu tanımlanmıştır. Optimizasyon probleminde, güç tedarik kaybı olasılıęı güvenilirlik indeksi kullanılmıştır. Hibrit sistemleri optimal bir şekilde boyutlandırmak için çeşitli algoritmalar kullanılmış, elde edilen sonuçlardan fotovoltaiik panel/rüzgar türbini/batarya hibrit sisteminin % 0, % 0,3

ve % 1 güç tedarik kaybı olasılığı değerleri için en uygun maliyetli hibrit sistem olduğu görülmüştür. Güç tedarik kaybı olasılığı değeri % 5 olarak ayarlandığında, fotovoltaik panel/batarya sisteminin en uygun maliyetli hibrit sistem olduğu görülmüştür.



BÖLÜM III

MATERYAL VE METOT

Bu bölümde tez çalışmasında incelenen lokasyonlar tanıtılmış, rüzgar ve güneş enerjisi tahminlerinde kullanılan teorik altyapı tanımlanmış, hibrit yenilenebilir enerji sistemleri için güç ünitelerinin özellikleri verilerek optimal sisteminin belirlenmesine yönelik hesaplama yöntemi sunulmuştur.

3.1 Uygulama Alanları

Bu çalışmanın amacı doğrultusunda gerek rüzgar ve güneş enerjisi tahmin aşamasında gerekse belirli yük talebinin karşılanması için hibrit yenilenebilir enerji sistemlerinin boyutlandırılması aşamalarında rüzgar ve/veya güneş enerjisi potansiyelinin belirli bir düzeyde olduğu noktalar seçilmiştir. Bu amaçla seçilen lokasyonlar, Türkiye'nin Niğde, Ankara, Çanakkale, İzmir ve İstanbul illeri olup, bu şehirlerde bulunan meteoroloji istasyonlarında saatlik olarak kaydedilen geçmişe ait güneş radyasyonu, rüzgar hızı, sıcaklık verileri tahmin ve optimum sistem boyutlandırma süreçlerinde kullanılmıştır. Veriler Meteoroloji Genel Müdürlüğü, Meteorolojik Veri İşlem Dairesi Başkanlığı'ndan alınmıştır. Şekil 3.1'de bu çalışmada incelenen lokasyonlar görülmektedir.



Şekil 3.1. İncelen lokasyonlar

3.2 Güneş ve rüzgar enerjisi tahminleri için enerji hesaplamaları

Rüzgar türbinlerinde enerji üretimi, rüzgar türbini üreticileri tarafından hazırlanan rüzgar güç eğrileri ile bir yere ait rüzgar hızı verileri kullanılarak hesaplanabilir. Hesaplama metodolojisi, dikkate alınan türbinin güç eğrisinin zaman serisi şeklinde hazırlanan rüzgar hızı verileri ile birleştirilmesi esasına dayanmaktadır. Bir rüzgar türbininden elde edilen enerji, kullanılan rüzgar türbinin güç-hız eğrisine bağlı olarak, rüzgar türbininin devreye girme hızı ve nominal hız veya devreye girme hızı ve kesme hızı arasında oluşturulan eğriye göre belirlenen n. dereceden bir cebirsel denklem ile hesaplanabilir. Rüzgar türbinlerinde çeşitli hız aralıklarında rüzgar türbini güç çıktısı denklem 3.1 ile hesaplanabilir.

$$P_i = \begin{cases} 0, & v < v_{ci} \\ (a_n \cdot v^n + a_{n-1} \cdot v^{n-1} + \dots + a_1 \cdot v + a_0), & v_{ci} \leq v < v_R \\ P_R, & v_R \leq v < v_{co} \\ 0, & v \geq v_{co} \end{cases} \quad (3.1)$$

burada, a_n , a_{n-1} , a_1 ve a_0 regrasyon sabitleri, v_{ci} rüzgar türbininin devreye girme hızı, v_R rüzgar türbinin nominal güç ürettiği rüzgar hızı, v_{co} rüzgar türbinin devreden çıktığı rüzgar hızı, P_R rüzgar türbinin nominal gücü ve $P_i(v)$ ise herhangi bir rüzgar hızında rüzgar türbini tarafından üretilen güçtür. Bir rüzgar türbininde göz önünde bulundurulmuş bir süre için enerji çıkışı denklem 3.2 ile hesaplanabilir.

$$E_{WT} = \sum_{i=1}^N P(v_i) \Delta t \quad (3.2)$$

burada N yıllar, mevsimler, aylar gibi dikkate alınan sürelerdeki saat sayısı, Δt ise zaman aralığıdır. Bir rüzgar türbini tarafından belirli bir süre boyunca üretilen toplam enerji, sistemin çalıştığı ilgili koşullar altında olası tüm rüzgar hızlarına karşılık gelen enerjinin toplanmasıyla hesaplanabilir.

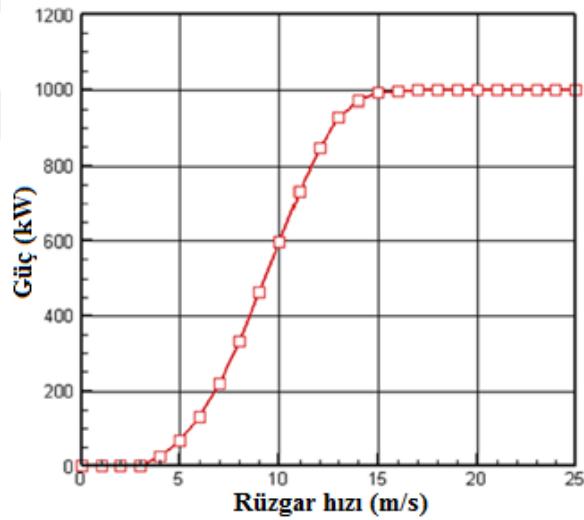
Rüzgar hızı yükseklik arttıkça artmaktadır, bu nedenle kurulması düşünülen rüzgar türbinin hub yüksekliğine karşılık gelen şartlardaki rüzgar hızının bilinmesi rüzgar türbinin üreteceği elektrik enerjisi miktarının doğru bir şekilde hesaplanması için

önemlidir. Rüzgar türbininin yüksekliğine (Hub height) karşılık gelen rüzgar hızı aşağıdaki gibi logaritmik yasa kullanılarak hesaplanır:

$$v_{hub} = v_{anem} \cdot \left(\frac{Z_{hub}}{Z_{anem}} \right)^{\alpha} \quad (3.3)$$

burada, v_{anem} ölçümün yapıldığı yükseklikte rüzgar hızı (m/s), Z_{anem} rüzgar hızı ölçümünün yapıldığı yükseklik (m), Z_{hub} rüzgar türbininin hub yüksekliği (m), α ise logaritmik yasada kullanılan üsdür.

Rüzgar güç tahmini çalışmalarında kullanılan rüzgar türbininin güç eğrisi şekil 1'de verilmiştir ve teknik özellikleri de Çizelge 1'de listelenmiştir. Bu çalışmada, rüzgar enerjisi santrallerinde yaygın olarak kullanılmaları nedeniyle 1 MW'lık bir rüzgar türbini seçilmiştir.



Şekil 3.2. 1 MW gücündeki rüzgar türbinin güç eğrisi

Çizelge 3.1. Göz önünde bulundurulmuş türbinin teknik özellikleri

Özellikleri	Rüzgar türbini
Nominal güç (kW)	1000
Kule yüksekliği (m)	50
Rotor çapı (m)	54,2
Süpürme alanı (m ²)	2300
Kanat sayısı	3
Devreye girme hızı (m/s)	3
Nominal güçteki hız (m/s)	15
Durdurma hızı (m/s)	25

Fotovoltaik panelden üretilebilecek elektrik enerjisi, panelin sıcaklık değerine bağlı olarak ifade edilen denklem 3.4 ile hesaplanabilir (HOMER Energy, 2016; Baneshi ve Hadianfard, 2016):

$$P_{PV\text{-}çıkış} = P_{PV\text{-}rated} F_{PV} \left(\frac{G_T}{G_{T,STC}} \right) [1 + \alpha_p (T_c - T_{c,STC})] \quad (3.4)$$

$$E_{PV} = \sum_{i=1}^N P_{PV\text{-}çıkış} \Delta t \quad (3.5)$$

formül 3.4' de, $P_{PV\text{-}rated}$ PV dizisi anma kapasitesi (kW), F_{PV} değer kaybı faktörü (%), G_T PV dizisine gelen radyasyon (W/m^2), $G_{T,STC}$ standart test şartlarındaki radyasyon değeri ($1 \text{ kW}/m^2$), α_p sıcaklık katsayısı ($\%/^{\circ}C$), T_c PV hücre sıcaklığı ($^{\circ}C$) ve $T_{c,STC}$ standart şartlar altında PV dizisinin hücre sıcaklığıdır ($^{\circ}C$). PV modüllerinin güç çıkışı sıcaklık arttıkça azalır. Bu nedenle bu çalışmada sıcaklık faktörü dikkate alınmıştır. Formül 3.5' de N yıllar, mevsimler, aylar gibi dikkate alınan sürelerdeki saat sayısı, Δt ise zaman aralığıdır. Bir fotovoltaik panel tarafından belirli bir süre boyunca üretilen toplam enerji, sistemin çalıştığı ilgili koşullar altında olası tüm güneş radyasyonu ve sıcaklığa karşılık gelen enerjinin toplanmasıyla hesaplanabilir.


Meteoroloji istasyonlarında güneş verisi olarak ışıınım değerleri ve sıcaklık değerleri gözlenmektedir. Bu istasyonlarda, yatay düzlem üzerine gelen güneş ışıınımı değerleri

ölçülmektedir. Güneş enerjisi santrallerinde, fotovoltaik panellerin eğimli olarak yerleştirilmesi elektrik enerjisi üretimi açısından önemlidir. Eğim değeri (β - **Eğim**, söz konusu yüzey ile yatay düzlem arasındaki açı) genellikle güneş santrallerin kurulduğu yerlerin enlem derecesi olarak alınır. Bu çalışmada güneş paneller eğimi panellerin kurulduğu yerlerdeki enlem derecesi olarak alınmıştır. Çizelge 3.2’de göz önünde bulundurulmuş lokasyonların enlem derecesini göstermektedir.

Çizelge 3.2. Seçilen lokasyonların enlem dereceleri

Lokasyon	Niğde	Çeşme	Mamak	Bozcaada	Silivri
β	37.58^0	38.33^0	39.94^0	39.82^0	41.07^0

Eğik düzlem üzerindeki güneş radyasyonunun yatay düzlem üzerindeki değerine oranı güneş enerjisi hesaplarında yaygın olarak kullanılmaktadır. Bu oran (R_{bt}) denklem 3.6’de verilmiştir (Duffie ve Beckman, 2013). Şekil 3.2 yatay ve eğik düzlem üzerine gelen güneş ışınımı görülmektedir.



Şekil 3.2. Yatay ve eğik yüzeylerde güneş ışınımı.

$$R_{bt} = \frac{G_{Tilt}}{G_{Horizontal}} = \frac{G \cdot \cos \theta}{G \cdot \cos \theta_z} = \frac{\cos \theta}{\cos \theta_z} \quad (3.6)$$

Burada, G_{Tilt} eğim açısı üzerinde güneş ışınımı, $G_{Horizontal}$ yatay yüzeyde güneş ışınımı, θ geliş açısı, θ_z ise zenith açısıdır. $\cos \theta$ ve $\cos \theta_z$ 'nin değerleri denklem 3.7 ve denklem 3.8 ile hesaplanabilir.

$$\cos \theta = \sin \delta \cdot \sin \phi \cdot \cos \beta - \sin \delta \cdot \cos \phi \cdot \sin \beta \cdot \cos \gamma + \cos \delta \cdot \cos \phi \cdot \sin \beta \cdot \cos \omega + \cos \delta \cdot \sin \phi \cdot \sin \beta \cdot \cos \gamma \cdot \cos \omega + \cos \delta \cdot \sin \beta \cdot \sin \gamma \cdot \sin \omega \quad (3.7)$$

ve

$$\cos \theta_z = \cos \phi \cdot \cos \delta \cdot \cos \omega + \sin \phi \cdot \sin \delta \quad (3.8)$$

δ , deklinasyon açlarına ve mevsimlere göre güneş ışınlarının dünyaya geliş açılarını göstermektedir. Bu açının en büyük değeri, kış ve yaz gün dönümlerinde 23.45° 'dir. Bu açının oluşumundan dolayı güneş ışınları kış gün dönümünde 23.45° güney enlemine, yaz gün dönümünde 23.45° kuzey enlemine diktir. Dünyanın kendi ve güneşin çevresinde dönüşü sırasında oluşan bu açıya deklinasyon açısı denir ($-23.45^\circ \leq \delta \leq 23.45^\circ$). γ - yüzey azimut açısı herhangi bir bölgede ve zamanda güneşe doğru varsayılan doğrunun yatay düzlemdeki izdüşümü ile güney doğrultusu arasındaki açıdır ($-180^\circ \leq \gamma \leq 180^\circ$), ω -saat açısı, zamanın açısal ölçüsüdür ve bir saat 15° boylama eşittir.

Fotovoltaik panellerde elektrik enerjisi üretimi güneş ışınımı ve sıcaklık verileri kullanılarak hesaplanabilir. Hesaplama metodolojisi, güneş ışınımı ile göz önünde bulundurulan güneş panelinin güç üretim karakteristiklerini ve zaman serisi şeklinde hazırlanan sıcaklık verilerini birleştirmeyi temel almaktadır.

3.3 Makine Öğrenmesi

Makine öğrenmesi, bilgisayarlar veya diğer cihazların harici olarak yönetilmeden öğrenme yeteneği kazanmalarını sağlamayı amaçlayan bilgisayar bilimleri alanlarından biridir (Samuel, 2010a; Alpaydın, 2010a). Makine öğrenmesi, veriden öğrenme ve veriye göre tahminler yapabilmek için algoritmalar ve metotlar geliştirilmesini amaçlamaktadır. İstatistik, optimizasyon, veri madenciliği, yapay zeka, evrimsel hesaplama ve yapay sinir ağları gibi veriden anlam çıkarmayı hedefleyen pek çok bilgisayar bilimleri alanlarının avantajlarını kullanarak doğru örüntüler keşfetmeye ve tahminler yapmaya odaklanmaktadır.

Makine öğrenmesi teknikleri yapılan işin ve kullanılan girdilerin özelliğine göre danışmanlı öğrenme ve danışmansız öğrenme olmak üzere iki ana kategoriye ayrılmaktadır. Danışmanlı öğrenmede, her bir girdi verisine karşılık olarak beklenen çıktılar mevcut iken danışmansız öğrenmede girdi verisine karşılık hangi çıktıların olması gerektiği mevcut değildir. Her iki kategoride de kullanılan makine öğrenmesi

teknikleri arasında; karar ağaçları, birliktelik kural madenciliği, yapay sinir ağları, derin öğrenme, lojik programlama, destek vektör makineleri, kümeleme, takviyeli öğrenme ve genetik algoritma sayılabilir.

Makine öğrenmesi çeşitli sebeplerden dolayı önemlidir. Girdi ve çıktı verileri arasındaki gizli ilişkilerin tam olarak ortaya konulmadığı veya matematiksel modelin çıkarılmadığı girdi/çıktı veri çiftleri için makine öğrenmesi fayda sağlamaktadır. Makinelerin (bilgisayar veya diğer cihazların) değişen çevresel şartlara ayak uydurabilme yetenekleri kazanabilmelerine yardımcı olmaktadır. Yapılan işlerle ilgili değişen bilginin mevcut sistemlere aktarılabilmesinde makine öğrenmesi teknikleri kolaylıklar sağlamaktadır. Birbiriyle etkileşim içerisindeki karmaşık sistemlerin birbirlerinden haberdar olarak büyük bir sistemi oluşturmalarını sağlamaktadır. Bu faydalarının yanında makine öğrenmesi çeşitli sebeplerden dolayı zordur. Birincisi, verinin makine öğrenmesi görevini tam olarak temsil edip etmediğinin ve veriye-dayalı olarak kurulacak olan modellerin başarısının değerlendirilmesi zordur. Büyük veri kaynaklarının analiz edilmesinde yenilikçi yöntemler kullanılması gerekmektedir. Mevcut bir görevi yerine getirecek yeni makine öğrenmesi algoritmaları geliştirilmesi gerekmektedir. Bir görev için birden fazla makine öğrenmesi tekniği kullanılabilir ancak kullanılacak olan makine öğrenmesi tekniklerinden hangisinin daha fazla fayda sağlayacağını tespiti zordur. Makine öğrenmesi çok geniş yelpazedeki uygulama alanları için fayda sağlayabilmektedir. Bunlar arasında, biyoinformatik, insan-makine etkileşimi, bilgisayar ağları, bilgi keşfi, tıbbi tanı, ekonomi, sigortacılık, doğal dil işleme, tavsiye sistemleri, robotik ve enerji sistemlerinin optimizasyonu sayılabilir (Samuel, 2010b ve Alpaydin, 2010b).

Her biri belirli problemlerde uzmanlaşmış birçok makine öğrenme yöntemi vardır. Tahmin amacıyla, sınıflandırma ve regresyon algoritmaları yaygın olarak kullanılmaktadır. Bu algoritmaların çoğu başlangıçta sınıflandırma algoritmalarıdır ve girdi veri kümesinden gerçek değerler üretmek üzere modifiye edilmişlerdir. Bu sınıflandırma alt kümesine regresyon analizi denir.

Bu tez çalışmasında makine öğrenmesi yöntemleri iki farklı amaçla kullanılmıştır. Birinci amaç, geçmiş veriler kullanılarak uzun dönem güç üretim tahminlerinin yapılması için regresyon algoritmalarının kullanılmasıdır. İkinci amaç ise, meteorolojik parametrelere dayalı olarak belirli bir lokasyonda talep edilen gücü karşılayacak optimal

sistemin önerilmesi için optimizasyon algoritmalarının kullanılmasıdır. Her iki yöntem için kullanılmış olan algoritmalar aşağıda detaylarıyla verilmiştir.

3.3.1 Regresyon Algoritmaları

Bu bölümde, LASSO regresyonu, kNN regresyonu, xGBoost regresyonu, Rastgele Orman Regresyonu ve Destek Vektör Regresyonu (SVR) gibi bu çalışmada kullanılan regresyon analizi algoritmalarını tanıtmıştır. Bu algoritmalar, regresyon problemleri için yaygın kullanımları ve literatürdeki yüksek performansları nedeniyle seçilmiştir. Bu algoritmaların teorik arka planı birbirinden farklıdır ve bu durum rüzgar ve güneş enerjisi tahmin problemlerinde hangi arka plan ve algoritmanın daha başarılı olduğu hakkında bilgi sağlayacaktır. Her algoritmaların performansını ve çalışma zamanını etkileyen birkaç algoritma parametresi vardır. Bu nedenle bu çalışmada ele alınan probleme göre her algoritma için en iyi parametreleri seçmek amacıyla çok sayıda testler yapılarak algoritmalar için en uygun parametrelerin tespiti gerçekleştirilmiştir. Farklı parametre ayarları ile algoritmalar çalıştırılmış ve en iyi elde edilen sonuçlar kullanılmıştır.

3.3.1.1 LASSO Regresyon Algoritması

LASSO (Least Absolute Shrinkage Selector Operator) regresyon algoritması lineer regresyon algoritmasının özelleşmiş bir versiyonudur (Tibshirani, 1996). LASSO algoritmasına tahminleri dengelediği için büzleştirme modeli de denilmektedir. LASSO regresyon algoritmasının temel amacı, tahmin hata oranını düşürecek ve yeterli kalitede olacak tahmin setlerini elde etmektir. LASSO regresyon algoritmasının, lineer veya ridge regresyondan en önemli farkı bazı özniteliklerin katsayılarını parametrik olarak belirleyebilmesidir. Bu sayede LASSO regresyon algoritması, bir özniteliğin etkisini azaltıp artırma becerisine sahiptir. LASSO regresyon algoritmasının verimli olmasının bir diğer önemli sebebi ise öznitelik seçimi ve düzenleştirme işlemlerini birlikte yapabilmesidir.

LASSO regresyon algoritması, denklem 3.9'e göre regresyon görevini gerçekleştirmektedir. Burada, K örnek sayısını, α_1 and β_j özniteliklerin katsayılarını ve $\hat{\alpha}$ tahmin sonucunu ifade etmektedir.

$$(\hat{\alpha}, \hat{\beta}) = \arg \min \left\{ \frac{1}{K} \sum_{i=1}^K \left(y_i - \alpha_1 - \sum_{j=1}^K x_{i,j} \beta_j \right)^2 \right\} \quad (3.9)$$

Eşitlik 3.8'teki formül Lagrange formuna göre basitleştirilerek denklem 3.9'daki gibi tekrar düzenlenebilir. denklem 3.10'da görüldüğü üzere L1 düzenleme, parametrelerin katsayılarının mutlak değerini sonuca ekleyerek parametrelerin sonuç üzerindeki etkisini düzenleyebilmektedir.

$$(\hat{\alpha}, \hat{\beta}) = \arg \min \left\{ \frac{1}{K} \|y - X \cdot \beta\|_2^2 + \lambda \|\beta\|_1 \right\} \quad (3.10)$$

Bu tez çalışmasında LASSO regresyon algoritması kullanılırken λ parametresi 0.1 olarak seçilmiştir.

3.3.1.2 kNN Regresyon Algoritması

k En Yakın Komşu (k Nearest Neighbor – kNN) algoritması oldukça yaygın olarak kullanılan ve örnek-tabanlı tembel öğrenme yaklaşımını kullanan bir sınıflandırma algoritmasıdır. kNN algoritması, test örneklerinin parametrelerinin k sınıf merkezlerine olan yakınlığıyla sınıflandırma işlemini gerçekleştirmektedir (Yao ve Ruzzo, 2006; Hu vd., 2014). Test örneklerinin parametrelerinin sınıf merkezlerine olan yakınlığı Öklid, Manhattan ve Minkowski gibi uzaklık metrikleri kullanılarak hesaplanmaktadır. kNN algoritması ilk olarak rastgele k sınıf merkezi belirlemekte ve eğitim örneklerini belirlenen sınıf merkezlerine olan uzaklıklarına göre sınıflandırmaktadır. Ardından k sınıf merkezlerinin en iyi modellenmesi için tekrarlı bir süreç başlatılmaktadır. Son olarak test örneklerinin parametreleri, son olarak modellenmiş olan k sınıf merkezlerine olan uzaklıklarına göre sınıflandırılmaktadır. kNN algoritmasının formulasyonu denklem 3.11'de verilmiştir.

$$y' = \arg \max_{(x_i, y_i) \in D_{neighbors}} \sum I(v = y_i) \quad (3.11)$$

Burada, v sınıf etiketleri, y_i i. en yakın komşunun sınıf etiketi, $I(.)$ ise içerisindeki değer doğru ise 1, yanlış ise 0 değerlerini döndüren bir fonksiyondur.

kNN regresyon algoritması, kNN sınıflandırma algoritmasının regresyon amacıyla düzenlenmiş versiyonudur. kNN regresyon algoritmasında, sabit sınıf değerleri yerine eğitim örnekleri ve bu örneklerin çıktı değerleri kullanılarak test çıktıları tahmin edilmektedir.

Bu tez çalışmasında kNN regresyon algoritması kullanılırken k değeri 4 ve uzaklık metriği olarak Minkowski uzaklığı seçilmiştir.

3.3.1.3 xGBoost Regresyon Algoritması

Aşırı Eğim Artırma (eXtreme Gradient Boost – xGBoost) algoritması eğim artırma karar ağacı algoritmasının geliştirilmiş bir versiyonudur. xGBoost algoritması artırılmış ağaçları paralel bir yaklaşımla kurmakta ve verimi artırmayı hedeflemektedir (Chen ve Guestrin, 2016). Bu yapısı sebebiyle xGBoost algoritması hızlı ve ölçeklenebilir bir algoritmadır. xGBoost algoritmasının temel hedefi daha iyi karar ağaçları kurulmasını sağlayarak amaç fonksiyonunu minimize etmektir. xGBoost algoritması regresyon amacıyla da kullanılmakta ve diğer artırımlı algoritalardan daha hızlı ve verimli olduğu için tercih edilmektedir.

xGBoost algoritmasına ait formülasyon denklem 3.12’de verilmiştir.

$$F_{obj}(\theta) = L(\theta) + \Omega(\theta) \text{ where } L(\theta) = I(\hat{y}_i, y_i) \text{ and } \Omega(\theta) = \gamma \cdot T + \frac{1}{2} \cdot \lambda \cdot \|w\|^2 \quad (3.12)$$

Eşitlikte görüldüğü üzere $F_{obj}(\theta)$ amaç fonksiyonunu, $L(\theta)$ tahmin değeri olan \hat{y}_i ile gerçek değer olan y_i arasındaki kayıp fonksiyonunu, $\Omega(\theta)$ düzenleme terimini, γ öğrenme oranını, T ağaçtaki yaprak sayısını, λ düzenleme parametresini ve w yaprakların ağırlığını ifade etmektedir.

Bu tez çalışmasında xGBoost regresyon algoritması kullanılırken öğrenme oranı 0.1 ve ağaç sayısı 500 olarak belirlenmiştir.

3.3.1.4 Rastgele Orman Regresyon Algoritması

Rastgele Orman (Random Forest – RF) algoritması girdi veri kümesinden çok sayıda karar ağacı oluşturarak performansı artırmayı amaçlayan karar ağacı algoritmalarından biridir (Breiman, 2001). Rastgele Orman algoritması veri kümesindeki girdi parametrelerini çeşitli parçalara ayırmakta ve her bir parametreden oluşan karar ağaçları oluşturmaktadır. Daha sonra her bir karar ağacının sonucu kullanılarak son karar belirlenmektedir. Bu sayede, çok fazla sayıda parametreye sahip olan karmaşık problemler daha basit ve kolaylıkla işlenebilir hale gelmektedir.

Rastgele Orman algoritmasında parametre uzayından θ_k rastgele parametreler vektörü oluşturulmakta ve her bir ağaç θ_k ve eğitim veri kümesi kullanılarak oluşturulmaktadır. Rastgele Orman algoritmasında genelleştirme hatası ve sınır fonksiyonu denklem 3.13’de verilmektedir.

$$PE^* = P_{X,Y}(mg(X < Y) < 0) \quad (3.13)$$

Denklem 3.13’de ki $mg(X, Y)$, denklem 3.14’de verilmiştir.

$$mg(X, Y) = a \cdot v_k \cdot I(h_k(X) = Y) - \max_{j \neq Y} a \cdot v_k \cdot I(h_k(X) = j) \quad (3.14)$$

Burada, X ve Y rastgele vektörleri, mg diğer çıktılara göre doğru çıktıyı verebilmek için rastgele vektörlerin oylarının ortalamasını kontrol eden sınır fonksiyonunu, $I(.)$ gösterge fonksiyonunu ve h_k sınıflandırıcıları ifade etmektedir.

Bu tez çalışmasında Rastgele Orman regresyon algoritması kullanılırken ağaç sayısı 10 ve rastgele durum 50 olarak seçilmiştir.

3.3.1.5 Destek Vektör Regresyon Algoritması

Destek Vektör Regresyon (Support Vector Regression – SVR) algoritması, Destek Vektör Makinesi (Support Vector Machines – SVM) algoritmasının regresyon versiyonudur (Drucker vd., 1997). SVM algoritması bir, iki veya çok boyutlu girdi

uzayındaki girdi veri kümesi örneklerini sınıflandırmak için bir doğru, düzlem veya hiperdüzlem oluşturmaktadır. Lineer olmayan SVR girdi hiperuzayları için bir regresyon fonksiyonu bulmaya çalışmaktadır.

SVR algoritması ε uzaklıktaki girdi parametrelerinden bir düzlem elde edebilmek için eğitim veri örneklerini kullanmaktadır. En temel formdaki SVR algoritması denklem 3.15’de verilmiştir.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i + \xi_i^* \quad \text{subjekt to} \quad \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (3.15)$$

Burada, w girdi parametrelerinin uzayını, b sapma değerini, ε hassasiyeti ve ξ_i ve ξ_i^* hata ölçeklerini ifade etmektedir.

SVR algoritmasının başarısını etkileyen çeşitli parametreler bulunmaktadır. Bu parametreler fonksiyon tipi, C , gamma ve epsilon değerleridir. Fonksiyon tipi, girdi verisinin karakteristiğine göre seçilmesi gereken ve algoritmanın başarısını etkileyen en önemli parametredir. C ve gamma değerleri, algoritmanın ürettiği modelin aşırı veya yetersiz eğitilmesini engelleyen parametrelerdir.

Bu tez çalışmasında SVR regresyon algoritması kullanılırken fonksiyon tipi olarak Radyal Tabanlı Fonksiyon kullanılmış ve C ve gamma değerleri sırasıyla 3000 ve 0.1 olarak seçilmiştir.

3.3.2 Regresyon Algoritmalarıyla Güç Üretim Tahmini Yöntemi

Bu tez çalışmasında, saatlik rüzgar hızı, güneş radyasyonu ve sıcaklık değerleri ile 4 yıllık eğitim verisi üzerinde regresyon algoritmaları çalıştırılmış ve rüzgar güç üretim tahmini ve güneş güç üretim tahmini modelleri geliştirilmiştir. Rüzgar güç tahmini modeli günlük ortalama rüzgar hızı ve günlük rüzgar hızı standart sapmasına, güneş güç tahmini modeli ise günlük ortalama güneş radyasyonu ve günlük ortalama sıcaklık parametrelerine göre 1 yıllık güç üretim tahmini yapmaktadır. Rüzgar ve Güneş güç üretim tahmini yöntemleri Algoritma 1 ve 2’de verilmiştir.

Algoritma 1. Rüzgar Güç Tahmini Yöntemi

Girdiler:

D: 5 yıllık saatlik rüzgar hızı veri kümesi

egitimOrani: Regresyon algoritmalarının eğitim veri kümesi oranı

turbinOzellikleri: Rüzgar türbini özellikleri

Çıktı:

Ruzgar_Guc: Tahmin edilen rüzgar gücü

Algoritma:

1. *saatlikGuc*=*saatlik-guc-hesapla* (*D*, *turbinOzellikleri*)
 2. [*gunlukRH*, *gunlukSS*] = *verisetini-onisle* (*D*)
 3. *gunlukGuc* =*günlük-toplam-gucu-hesapla* (*saatlikGuc*)
 4. [*gunlukRHEgitim*, *GunlukSSEgitim*, *gunlukRHTest*, *gunlukSSTest*, *gunlukGucEgitim*, *gunlukGucTest*] = *eğitim-test-ayir*(*egitimOrani*)
 5. *model* = *regresyon-algoritmasini-calistir* (*gunlukRHEgitim*, *GunlukSSEgitim*, *gunlukGucEgitim*)
 6. *tahminiGuc* =*gucu-tahmin-et* (*model*, *gunlukRHTest*, *gunlukSSTest*)
 7. *metrikler* = *algoritma-performansi-hesapla* (*tahminiGuc*, *gunlukGucTest*)
 8. *return tahminiGuc*
-

Algoritma 2. Güneş Güç Tahmini Yöntemi

Girdiler:

D: 5 yıllık saatlik güneş ışıınımı ve sıcaklık veri kümesi

egitimOrani: Regresyon algoritmalarının eğitim veri kümesi oranı

Çıktı:

Gunes_Guc: Tahmin edilen güneş gücü

Algoritma:

1. *saatlikGuc*=*saatlik-guc-hesapla* (*D*)
 2. [*gunlukRad*, *gunlukSic*] = *verisetini-onisle* (*D*)
 3. *gunlukGuc* =*günlük-toplam-gucu-hesapla* (*saatlikGuc*)
 4. [*gunlukRadEgitim*, *GunlukSicEgitim*, *gunlukRadTest*, *gunlukSicTest*, *gunlukGucEgitim*, *gunlukGucTest*] = *eğitim-test-ayir* (*egitimOrani*)
 5. *model* = *regresyon-algoritmasini-calistir* (*gunlukRadEgitim*, *GunlukSicEgitim*, *gunlukGucEgitim*)
 6. *tahminiGuc* =*gucu-tahmin-et* (*model*, *gunlukRadTest*, *gunlukSicTest*)
 7. *metrikler* = *algoritma-performansi-hesapla* (*tahminiGuc*, *gunlukGucTest*)
 8. *return tahminiGuc*
-

Algoritma 1 ve 2’de görüldüğü üzere, birinci adımda rüzgar ve güneş veri kümeleri girdi olarak alınmaktadır. İkinci adımda, bu veri kümeleri üzerinde ön işlem yapılarak saatlik veriler günlük ortalamalara dönüştürülmektedir. Üçüncü adımda, saatlik girdi verilerini kullanarak günlük toplam güç hesaplaması yapılmaktadır. Dördüncü adımda, regresyon algoritmalarının eğitilmesi için veri kümesi eğitim ve test veri kümeleri olarak iki gruba ayrılmaktadır. *egitimOrani* parametresi bu tez çalışması için 0.8 olarak seçilmiştir. Bu sayede veri kümesinin 4 yıllık kısmı eğitim veri kümesi olarak, son bir yıllık kısmı da test veri kümesi olarak ayrılmıştır. Beşinci adımda, regresyon algoritmaları eğitim veri kümelerini kullanarak modeller üretmektedir. Altıncı adımda, regresyon algoritmalarının modelleri kullanılarak üretilen rüzgar ve güneş güç değerleri tahmin edilmektedir. Yedinci adımda, algoritmaların ürettiği tahmini güç değerleri ve gerçekteki üretilen güç değerleri karşılaştırılarak algoritmaların performansı hesaplanmaktadır. Son olarak sekizinci adımda, tahmini güç değerleri algoritmaların çıktısı olarak sunulmaktadır.

3.3.3. Optimizasyon Algoritmaları

Bu bölümde, bu tez çalışmasının optimal sistem tasarımı kısmında kullanılmış olan Genetik Algoritma (Genetic Algorithm – GA) ve Yapay Arı Kolonisi Algoritması (Artificial Bee Colony Algorithm – ABC) ve bu tez çalışmasında önerilmiş olan ızgara arama (Grid Search) tabanlı deterministik optimum sistem tasarımı algoritması tanıtılmıştır. İlk olarak bu tez çalışmasında önerilmiş olan ve deterministik olarak tüm ihtimalleri değerlendiren ve en uygun hibrit sistem tasarımını çıktı olarak veren algoritma anlatılmış, daha sonra GA ve ABC optimizasyon algoritmaları ve bu algoritmalar yardımıyla hibrit sistem tasarımı anlatılmıştır.

3.3.3.1. Önerilen Deterministik Algoritma

Bu çalışmada deterministik yaklaşım için ızgara arama (Grid Search) yöntemi kullanılmıştır. Önerilen algoritma, arama uzayındaki her bir çözümü teker teker değerlendirerek, seçilen çözümün talebi karşılayıp karşılamadığı incelenmiş ve bir diziye kaydedilmiştir. Daha sonra, üretilmiş olan dizi en iyi çözümler en yukarıda kalacak şekilde Kabarcık Sıralama Algoritması kullanılarak sıralanmış ve en iyi çözümler en yukarıda listelenmiştir.

İlk deneyde PV panel ve batarya sayısı parametre olarak kullanılırken, ikinci deneyde ilk deneye ek olarak rüzgar türbin seçimi de parametrelere eklenmiştir.

Çalışmada kullanılan deterministik yaklaşımın adımları Algoritma 3’de sunulmuştur.

Algoritma 3. Önerilen Deterministik algoritmanın adımları

1. Arama uzayının parametrelerinin ayarlanması.
 2. Her bir parametre değeri karşılanacak şekilde döngülerin oluşturulması.
 3. Saatlik üretim maliyeti, Güç Tedariki Kaybı Olasılığı (LPSP) ve Excessive değerlerinin her döngüde hesaplanması ve sonuçların bir listeye eklenmesi.
 4. Listenin saatlik üretim maliyetine göre Kabarcık Sıralama Algoritması (Bubble Sort) ile sıralanması.
 5. En optimum sonucun elde edilmesi.
-

Çalışmada kullanılan arama uzayı parametreleri ve çözüm aralıkları aşağıda listelenmiştir:

- $0 < \text{PV Panel Sayısı} \leq 100$
- $0 < \text{Batarya Sayısı} \leq 100$
- $0 < \text{Rüzgar Türbin Seçimi} \leq 50$

İlk deneyde algoritma 10.000 tur çalışırken, ikinci deneyde 500.000 iterasyon çalışmaktadır.

3.3.3.2. Genetik Algoritma

Genetik algoritma evrimden ilham alınarak keşfedilen, hesaplama model ailesinin bir üyesidir. Spesifik bir problemin çözümü için, genetik bilimindeki kromozom yapısını kullanır ve bu yapılara rekombinasyon işlemi uygular (Whitley, 1994). Genetik algoritmanın işlem adımları Algoritma 4’te verilmiştir (Karaboğa, 2018a).

Algoritma 4. Genetik algoritma adımları

1. Çözümlerin bir başlangıç popülasyonunu oluştur
 2. Popülasyondaki her çözümün uygunluk değerini hesapla
 3. Durdurma kriteri sağlanıyorsa araştırmayı durdur. Yoksa, aşağıdaki adımları gerçekleştir.
 - 3.1. Tabii seleksiyon işlemini uygula
 - 3.2. Çaprazlama işlemini uygula
 - 3.3. Mutasyon işlemini uygula
 4. Adım 2'ye git.
-

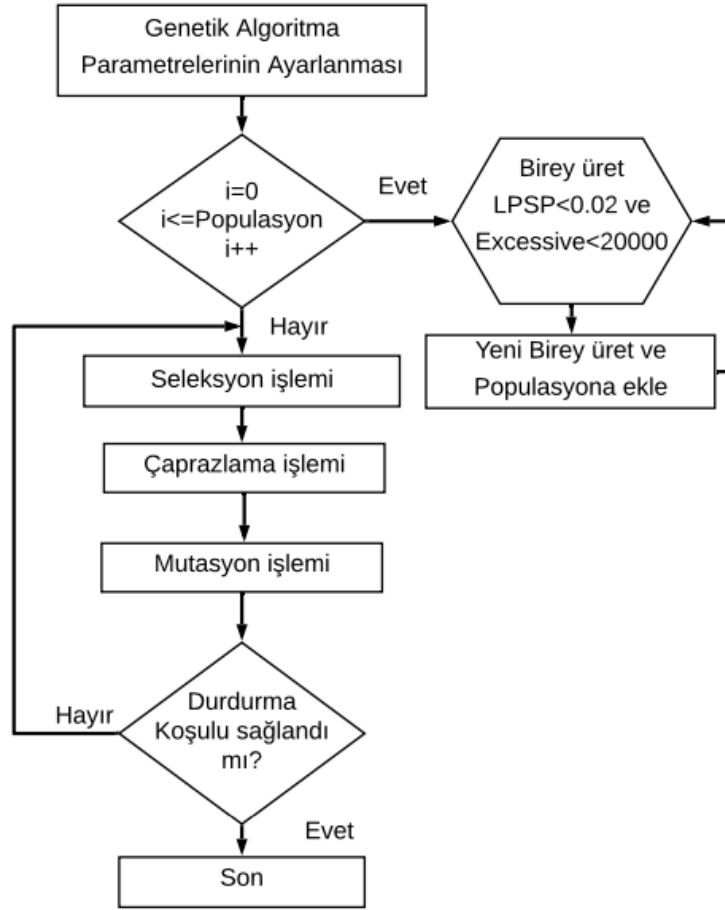
Seleksiyon operatörü, güçlü bireylerin hayatta kalması ve güçsüz bireylerin elenmesi anlamına gelmektedir (Filipović, 2003).

Çaprazlama operatörü, popülasyonun potansiyelini araştırmak üzere bir önceki popülasyondan daha iyi özellikli yeni kromozomlar oluşturmak için kullanılmaktadır. Genellikle çaprazlama oranına eşit bir olasılıkla belirlenen kromozomlar üzerinde uygulanmaktadır (Jang, 1997).

Mutasyon operatörü, popülasyondaki bireylerin mutasyon oranına bağlı olarak genlerinde değişiklik gerçekleştirilmesidir. Yapay zeki sistemlerde bu operatör, tekrardan elde edilemeyecek iyi bir çözümün korunumunu ve popülasyondaki çeşitliliği sağlar (Goldberg, 1989).

Bu tez çalışmasında genetik algoritma, verilen değişken yük talebine göre 2 farklı deneyde kullanılmıştır. İlk deneyde PV paneller ve bataryalar ile Niğde ve Bozcaada bölgelerinde kurulacak optimum sistemin bulunması amaçlanmıştır. Burada her kromozom PV panel ve batarya sayısını içeren 2 gene sahiptir. İkinci deneyde ise PV panel, Batarya ve Rüzgar Türbini ile Niğde ve Bozcaada bölgelerinde kurulacak optimum sistemin bulunması amaçlanmıştır. Her kromozom PV panel sayısı, batarya sayısı ve rüzgar türbin seçimi olarak 3 gene sahip olacak şekilde tasarlanmıştır.

Ayrıca çalışmada çaprazlama oranı 0,8 mutasyon oranı 0,01 popülasyon büyüklüğü 15, LPSP değeri 0,02 ve Excessive değeri 20000 olarak belirlenmiştir. Çalışmada kullanılan genetik algoritmanın akış diyagramı şekil 3.3'de verilmiştir.



Şekil 3.3. Çalışmada kullanılan genetik algoritmanın akış diyagramı

Akış diyagramı incelendiğinde ilk olarak, genetik algoritmaya ait mutasyon oranı, çaprazlama oranı, popülasyon büyüklüğü ve durdurma kriteri gibi parametreler belirlenmektedir. Daha sonra her bir birey “LPSP” ve “Excessive” değişkenlerini karşılayacak şekilde üretilir ve başlangıç popülasyonuna eklenir. Ardından seleksiyon işlemi için Rulet Tekerleği yöntemi kullanılarak bireylerin kalitesine göre, genlerin rastlantısal olarak gelecek jenerasyona aktarılması sağlanmaktadır. Sonrasında çaprazlama oranına bağlı olarak çaprazlanacak bireyler seçilir ve çaprazlanacak bireylerde oluşan yeni çocukların LPSP ve Excessive değişkenlerini karşılayıp karşılamadığı kontrol edilir. Eğer karşılamıyor ise ebeveyn çocuk ile değiştirilmez. Ardından mutasyon oranına bağlı olarak popülasyondaki bireylerin genleri değiştirilir. Çaprazlama da olduğu gibi burada da oluşan yeni bireyin LPSP ve Excessive değişkenlerini karşılayıp karşılamadığı kontrol edilir. Eğer değerler karşılanıyor ise mutasyon kabul edilir. Son olarak durdurma koşulunun sağlanıp sağlanmadığına bakılır ve eğer koşul sağlanmışsa program çalışmayı durdurur.

3.3.3.3 Yapay Arı Koloni Algoritması

Yapay arı koloni algoritması, bal arılarının yiyecek ararken kullandıkları zeki davranışlardan esinlenerek Karaboğa tarafından keşfedilen sezgisel bir optimizasyon algoritmasıdır (Karaboğa, 2018b). Yapay arı koloni algoritmasının temel adımları Algoritma 5’te verilmiştir.

Algoritma 5. Yapay arı koloni algoritması adımları

1. Başlangıç yiyecek kaynağı bölgelerinin üretilmesi.
 2. Görevli arıların yiyecek kaynağı bölgelerine gönderilmesi
 3. Olasılıksal seleksiyonda kullanılacak olasılık değerlerinin görevli arılardan gelen bilgiye göre hesaplanması
 4. Gözcü arıların olasılık değerlerine göre yiyecek kaynağı bölgesi seçmeleri
 5. Bırakılacak kaynakların bırakılışı ve kaşif arı üretimi
 6. Çevrim sayısı maksimum çevrim sayısı olana kadar adım 2’ ye git
-

Başlangıç yiyecek kaynak bölgeleri üretilirken denklem 3.16 kullanılmaktadır.

$$x_{ij} = x_j^{\min} + rand(0,1)(x_j^{\max} - x_j^{\min}) \quad (3.16)$$

Formülde $i = 1 \dots N$, N yiyecek sayısı, $j = 1 \dots D$, D optimize edilecek parametre sayısı, olmakla birlikte x_j^{\min} ve x_j^{\max} j . parametrenin alt ve üst sınırını belirtir.

Görevli arılar yeni yiyecek kaynakları ararken mevcut çözümlerin komşularına bakar. Daha sonra mevcut çözüm ile bulunan yeni çözümler kıyaslanır. Komşu çözüm daha iyi ise hafızaya alınır daha kötü ise geliştirilememeye sayacı bir arttırılır. Komşu kaynakların keşfi denklem 3.17’ye göre gerçekleştirilmektedir.

$$x_{ij} = x_j + \Theta_{ij}(x_{ij} - x_{kj}) \quad (3.17)$$

Burada v_{ij} , x_{ij} komşuluğundaki yeni bir çözümdür, $\Theta_{ij}[1,-1]$ aralığında seçilen rastgele bir değer, j 1 ile optimize edilecek parametre sayısı arasında seçilen rastgele bir tam sayı ve x_{jk} ise 1 ile yiyecek sayısı aralığında seçilen rassal bir değişkendir.

Bu bağlamda gözcü arıların yiyecek kaynaklarını seçme ihtimali ise denklem 3.18’de verilmektedir.

$$p_i = \frac{fitness_i}{\sum_{i=1}^N fitness_i} \quad (3.18)$$

Burada p_i , her bir çözüm için kaynak seçim olasılığı $fitness_i$ ise i . çözümün kalite değerini belirtmektedir (Çavuş ve Tuncer, 2017).

Bu tez çalışmasında yapay arı koloni algoritması verilen değişken yük talebine göre 2 farklı deneyde kullanılmıştır. İlk deneyde PV paneller ve bataryalar ile Niğde ve Bozcaada bölgelerinde kurulacak optimum sistemin bulunması amaçlanmıştır. Burada optimize edilecek parametreler kurulacak sistemdeki batarya ve panel sayısını temsil etmektedir. İkinci deneyde ise, PV panel sayısı, batarya sayısı ve rüzgar türbin seçimi ile Niğde ve Bozcaada bölgelerinde kurulacak optimum sistemin bulunması amaçlanmıştır. Bu deneyde optimizasyonu gerçekleştirilecek parametreler ise PV panel sayısı, batarya sayısı ve rüzgar türbin seçimidir.

Deneylerde gözcü arı ve kaynak sayısı 15, geliştirilememe limiti 20, LPSP değeri 0,02 ve Excessive değeri 20000 olarak belirlenmiştir. Probleme uyarlanan yapay arı kolonisi algoritmasının akış diyagramı şekil 3.4’de verilmiştir.

Şekil 3.4 incelendiğinde ilk olarak, ABC’ye ait kaynak sayısı, gözcü arı sayısı, geliştirilememe limiti ve durdurma kriteri gibi parametreler belirlenmektedir. Ardından kaynaklar LPSP ve Excessive şartlarını sağlayacak bir şekilde oluşturulmaktadır. Daha sonra görevli arılar için komşu kaynaklar belirlenip, gözcü arıların seçtiği kaynakların nektar miktarları hesaplanmaktadır.

Sonrasında en iyi kaynağın pozisyonu hafızaya alınarak, jenerasyondaki en kaliteli pozisyonun korunumu sağlanır. Geliştirilememe limiti dolan kaynaklardan her jenerasyondan 1 kaşif arı çıkacak şekilde bırakma işlemi yapılır. Son olarak durdurma kriterine bakılır eğer durdurma koşulları sağlanıyorsa algoritmanın çalışması durdurulur. Sağlanmıyorsa bir sonraki jenerasyon için komşu kaynakların belirleneceği

adıma dönülür ve döngü devam eder. Ayrıca her yeni kaynak üretiminde LPSP ve Excessive koşullarının sağlanıp sağlanmadığı algoritma sürecinde kontrol edilmektedir. Örneğin kaşif arı üretilirken bu koşulun sağlandığı yeni kaynak üretilmektedir.



Şekil 3.4. Çalışmada kullanılan ABC algoritmasının akış diyagramı

BÖLÜM IV

RÜZGAR VE GÜNEŞ ENERJİSİ TAHMİNİ DENEYSEL SONUÇLARI


Bu bölümde Bölüm 3.3.1 ve 3.3.2’de sunulmuş olan rüzgar ve güneş enerjisi tahmini için kullanılan algoritmalarından elde edilen sonuçlar sunulmuştur. İlk olarak rüzgar ve güneş verilerinin değerlendirilmesi yapılmış daha sonra rüzgar enerjisi ve güneş enerjisi tahmini sonuçları verilmiştir.

4.1 Rüzgar ve Güneş Verileri

Bu tez çalışmasında rüzgar ve güneş verisi olarak Türkiye’den seçilen 5 farklı lokasyondaki meteorolojik veriler kullanılmıştır. Bu bölümde öncelikle rüzgar enerjisi tahmini için kullanılan rüzgar hızı ve rüzgar hızının dağılımının analizi yapılmıştır. Daha sonra güneş enerjisi tahmini için kullanılan güneş radyasyonu ve sıcaklık verilerinin analizi yapılmıştır.

4.1.1 Rüzgar Verilerinin Analizi

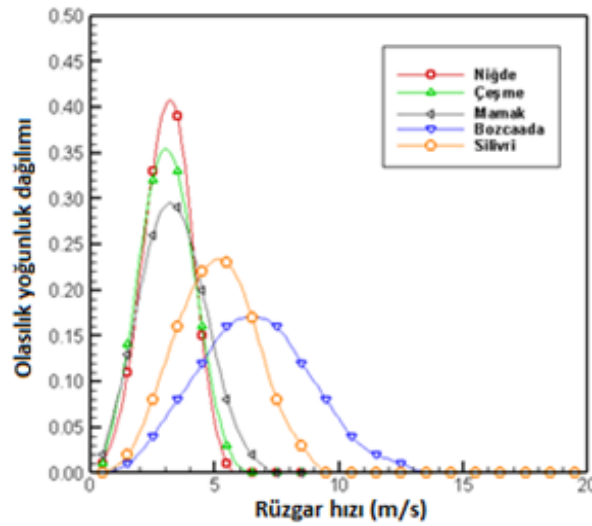
Şekil 4.1’de bu tez çalışmasında kullanılan 5 lokasyondaki rüzgar hızı karakteristikleri sunulmuştur. Bu tez çalışmasında kullanılan 5 yıllık veri kümesindeki saatlik rüzgar hızı verilerinin günlük ortalamaları şekilde gösterilmektedir. Şekilde görüldüğü üzere, rüzgar hızı tüm yıl boyunca en fazla olan ve rüzgar enerjisi konusunda en verimli olan lokasyon Bozcaada’dır. Ayrıca, Silivri de yüksek rüzgar hızı değerlerine sahip bir diğer lokasyon olarak görülmektedir. Çeşme, Mamak ve Niğde lokasyonlarında rüzgar hızı değerleri kış aylarında yükselen ve yaz aylarında düşen mevsimsel değişimler içermektedir.



Şekil 4.1. Seçilen 5 lokasyondaki günlük ortalama rüzgar hızı değerleri

Rüzgar enerjisi analizi ve yatırımlarının değerlendirilmesinde, rüzgar hızı değerlerinin davranışını belirleyen parametrelerin bulunması gerekmektedir. Bunun için en temel ve pratik metotlardan biri dağılım fonksiyonlarının kullanılmasıdır. Olasılık yoğunluk fonksiyonları rüzgar hızı değerlerinin farklı seviyelerdeki frekansını göstermektedir.

Bu tez çalışmasında, rüzgar hızı dağılımlarının analizi için Weibull dağılımı kullanılmıştır. Weibull parametreleri olan k ve c ortalama rüzgar hızı ve standart sapması olarak belirlenmiştir (Gökçek vd., 2007). Şekil 4.2’de rüzgar hızının seçilen lokasyonlarda 50m yükseklikteki Weibull dağılımlarını göstermektedir. Şekil 4.2’de görüldüğü üzere, en yüksek olasılık değeri Niğde için 0,41 iken bu değer Silivri için 0,23, Bozcaada için 0,17’dir. Ayrıca, çizelge 4.1’de seçilen lokasyonların 50m yükseklikteki Weibull dağılım parametrelerini göstermektedir.



Şekil 4.2. Seçilen lokasyonlarda rüzgar hızı frekans dağılımı


Çizelge 4.1. Seçilen lokasyonlarda Weibull dağılım parametreleri

Lokasyon	k	c (m/s)
Niğde	3,69	3,45
Çeşme	3,17	3,44
Bozcaada	3,20	7,28
Mamak	2,78	3,77
Silivri	3,44	5,60

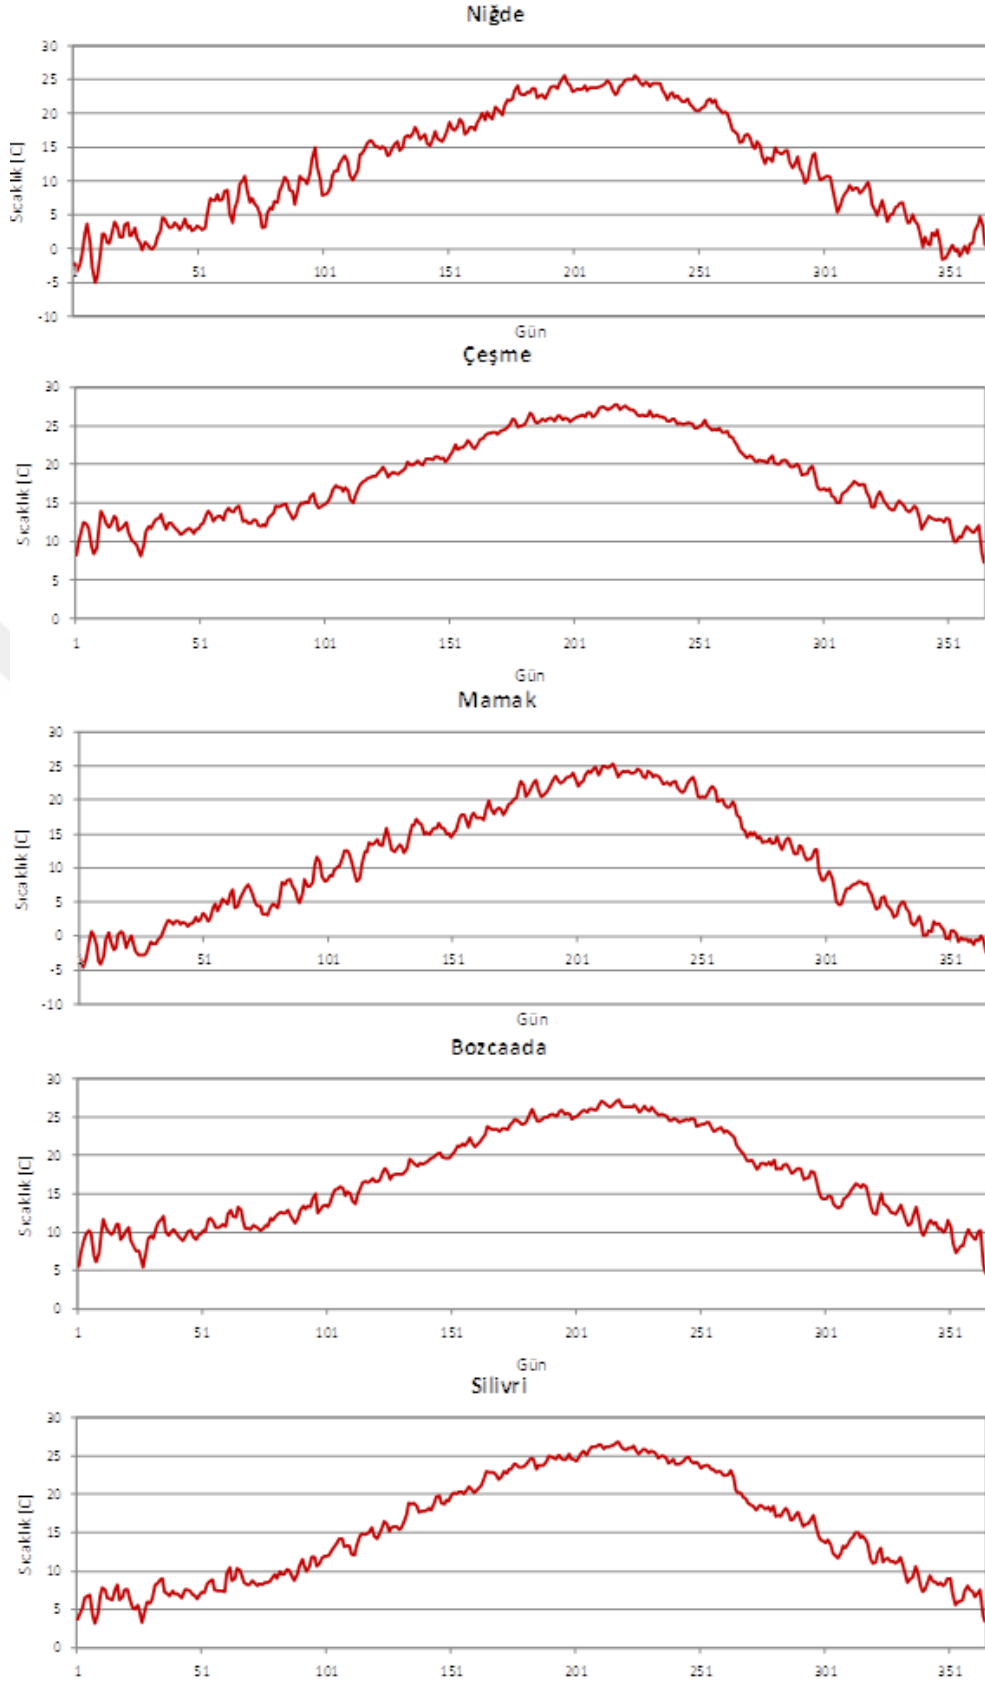
Mevcut arařtırmada dikkate alınan rüzgar türbininin güç eğrisi Őekil 1'de verilmiřtir ve teknik özellikleri de çizelge 1'de listelenmiřtir. Bu çalıřmada, rüzgar enerjisi santrallerinde yaygın olarak kullanılmaları nedeniyle 1 MW'lık bir rüzgar türbini seçilmiřtir.

4.1.2. Güneř Verilerinin Analizi

Őekil 4.3 ve 4.4'te güneř radyasyonu ve ortam sıcaklıęı verilerinin seçilen 5 lokasyondaki deęerleri günlük ortalamalar halinde ve 5 yılın ortalaması olacak Őekilde gösterilmektedir. Nięde için yıllık ortalama sıcaklık deęeri 11.87 °C, Bozcaada için ise 17.13 °C'dir. Nięde için yıllık ortalama güneř radyasyonu deęeri 0.2588 kW/m² iken Çeřme için 0.2783 kW/m² olarak ölçölmüřtür. Őekil 4.3'te göröldüęü üzere, 0.2815 kW/m² yıllık en yüksek ortalama deęerlere sahip olduęu için, güneř radyasyonunda en iyi lokasyon Mamak'tır. Őekil 4.4'te göröldüęü üzere, sıcaklık deęerleri tüm lokasyonlar için yaz aylarında artış göstermekte ve kiř aylarında düřmektedir. Nięde ve Mamak negatif sıcaklık deęerleri görölen iki lokasyondur. Dięer lokasyonlarda sıcaklık deęerleri tüm yıl boyunca pozitif olarak gözlemlenmektedir.



Şekil 4.3. Seçilen 5 lokasyondaki günlük ortalama güneş radyasyonu değerleri



Şekil 4.4. Seçilen 5 lokasyondaki günlük ortalama ortam sıcaklığı değerleri

4.2 Rüzgar ve Güneş Enerjisi Tahmini Deneysel Sonuçları

Bu bölümde rüzgar ve güneş enerjisi tahmini için kullanılan regresyon algoritmalarının sonuçları sunulmuştur. İlk olarak rüzgar enerjisi tahmini deneysel sonuçları verilmiş, ardından güneş enerjisi tahmini deneysel sonuçları anlatılmıştır.

Deneysel sonuçlarda algoritmalar kıyaslanırken R^2 , RMSE ve MAE ölçütleri kullanılmıştır. Performans metriklerinde y_i değeri gerçek değerleri, \hat{y}_i algoritmalar tarafından tahmin edilen değeri ve \bar{y} gerçek değer ortalamasını göstermektedir. R^2 , RMSE ve MAE ölçütleri sırasıyla formül 4.1, 4.2, 4.3' de verilmiştir.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^{365} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{365} (y_i - \bar{y})^2} \right) \quad (4.1)$$

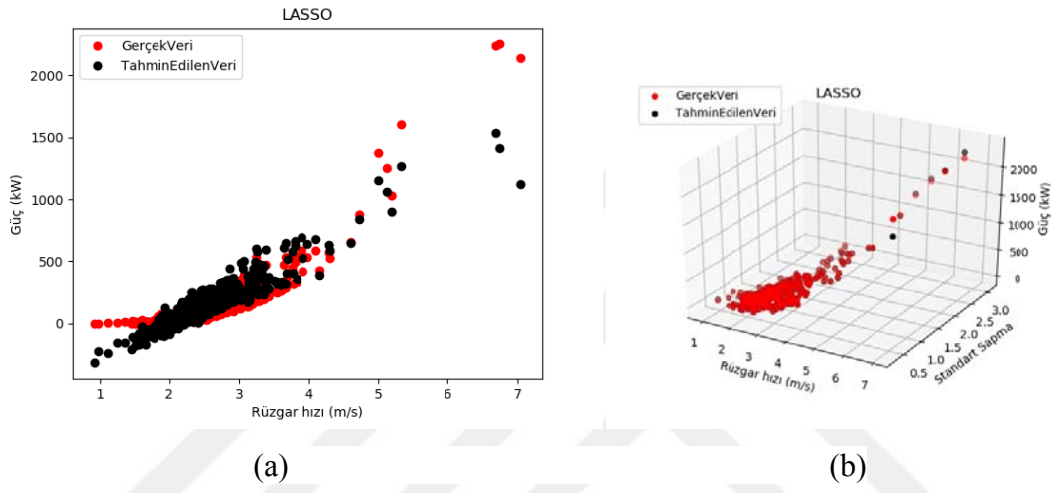
$$RSME = \sqrt{\frac{\sum_{i=1}^{365} (\hat{y}_i - y_i)^2}{365}} \quad (4.2)$$

$$MAE = \frac{\sum_{i=1}^{365} |\hat{y}_i - y_i|}{365} \quad (4.3)$$

4.2.1 Rüzgar Enerjisi Tahmini Deneysel Sonuçları

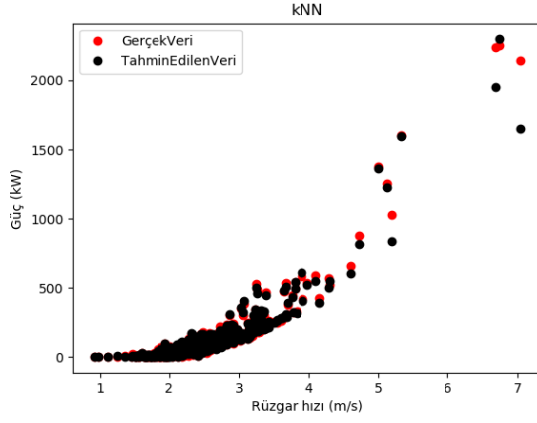
Bu bölümde, regresyon algoritmaları kullanılarak günlük ortalama rüzgar hızı ve standart sapması kullanılarak üretilen rüzgar gücü tahmini yapılmıştır. Veri kümesinin ilk dört yıllık kısmı eğitim için kullanılmış, son bir yılı ise test için ayrılmıştır. Her bir algoritma için Niğde bölgesindeki rüzgar enerjisi tahmini sonuçları aşağıda sunulmuştur. Ayrıca 5 bölgedeki algoritmaların tahminleriyle gerçek güç üretim değerlerin karşılaştırması yapılmıştır.

Şekil 4.5'te LASSO regresyonunun sonuçları gösterilmektedir. LASSO'nun düşük rüzgar hızı değerleri için negatif rüzgar güç tahmini yaptığı görülmektedir. Bu davranışın temel nedeni, LASSO'nun doğrusal regresyon olup, modeli doğrusal bir düzleme yerleştirmeye çalışmasıdır. Şekil 4.5 (b)'de görüldüğü üzere standart sapma da tahmin edilen rüzgar gücünü etkilemektedir. Düşük standart sapmalar, LASSO tarafından daha doğru tahmin edilirken, yüksek standart sapmalar başarılı tahmin edilememiştir.

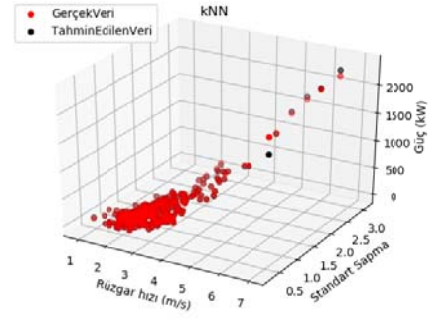


Şekil 4.5. (a) Tahmin gücü ve (b) LASSO regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi

Şekil 4.6, kNN regresyonunun sonuçlarını göstermektedir. Şekil 4.6 (a)'da kNN algoritması, güç değerlerini pozitif olarak tahmin etmektedir. Ayrıca, rüzgar gücü tahmin performansı, LASSO regresyonundan daha iyidir. Fakat rüzgar hızı arttıkça kNN algoritmasının başarımlarının düştüğü gözlemlenmiştir. Ayrıca, şekil 4.6 (b)'de görülebileceği gibi, standart sapma artışında da performans düşüşü görülmektedir. Bununla birlikte, kNN algoritmasının genel performansı, R^2 değeri yüksek olduğu için iyidir.



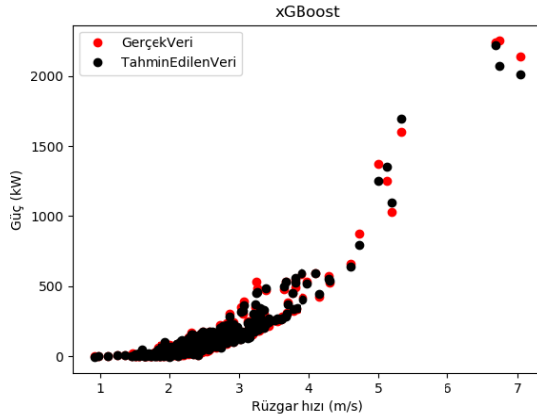
(a)



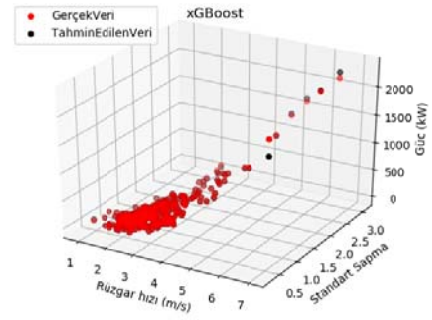
(b)

Şekil 4.6. (a) Tahmin gücü ve (b) kNN regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi

Şekil 4.7, xGBoost regresyonunun sonuçlarını sunar. Şekil 4.7 (a)' da görülebileceği gibi, kNN algoritmasına benzer şekilde, xGBoost algoritması da yüksek rüzgar hızı değerleri için %100 doğru güç değerlerini tahmin edememiştir, ancak kNN algoritmasından daha iyi doğruluğa sahiptir. Ayrıca şekil 4.7 (b) 'de görülebileceği gibi, standart sapma değerlerinin artması algoritmanın doğru tahmin performansını düşürse de başarılı sonuçlar elde edilmiştir.



(a)

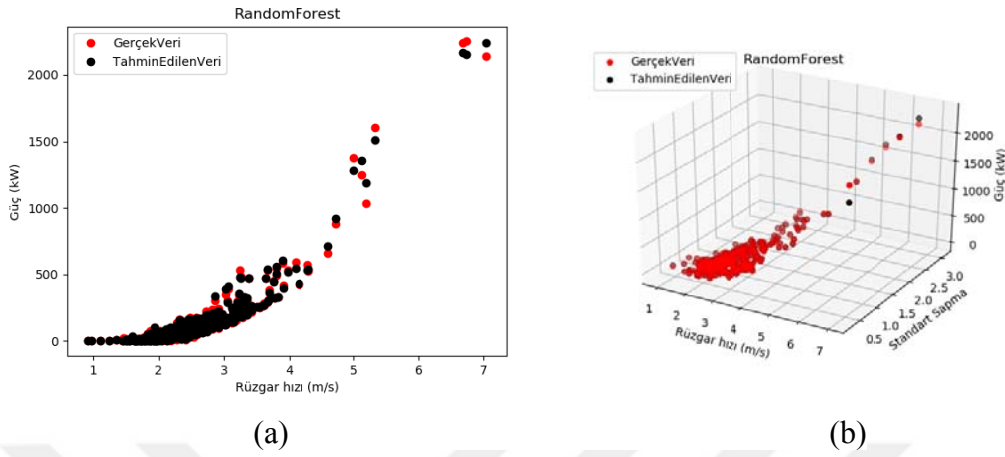


(b)

Şekil 4.7. (a) Tahmin gücü ve (b) xGBoost regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi

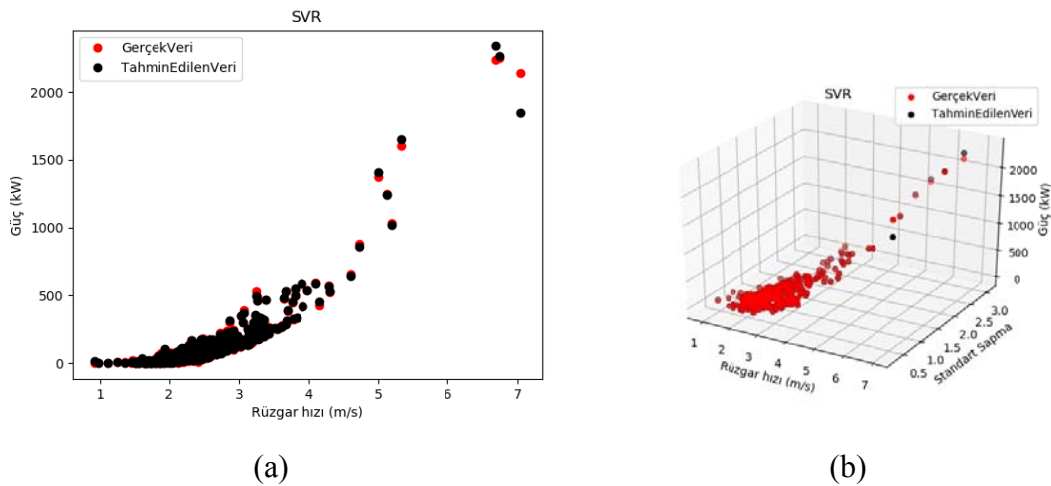
Şekil 4.8, Rastgele Orman regresyonunun sonuçlarını sunmaktadır. Şekil 4.8 (a)' da görüldüğü üzere, RF' da negatif güç tahmininde bulunmamıştır ve yüksek rüzgar hızı

değerlerinde SVR' a kıyasla daha başarılı performans göstermiştir. Şekil 4.8 (b)'de ise 3 boyutlu sonuçlar verilmiştir.



Şekil 4.8. (a) Tahmin gücü ve (b) RF regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi

Şekil 4.9, SVR sonuçlarını göstermektedir. Şekil 4.9 (a)'da görüldüğü üzere SVR, diğer algoritmalara kıyasla daha doğru rüzgar gücü tahmininde bulunmuştur. Ayrıca, şekil 4.9 (b) SVR'nin standart sapma değişimini uyarlayabildiğini ve rüzgar gücünü başarıyla öngörebildiğini göstermektedir.



Şekil 4.9. (a) Tahmin gücü ve (b) SVR regresyonu kullanılarak rüzgar hızı ve standart sapma etkisinin 3B görselleştirilmesi

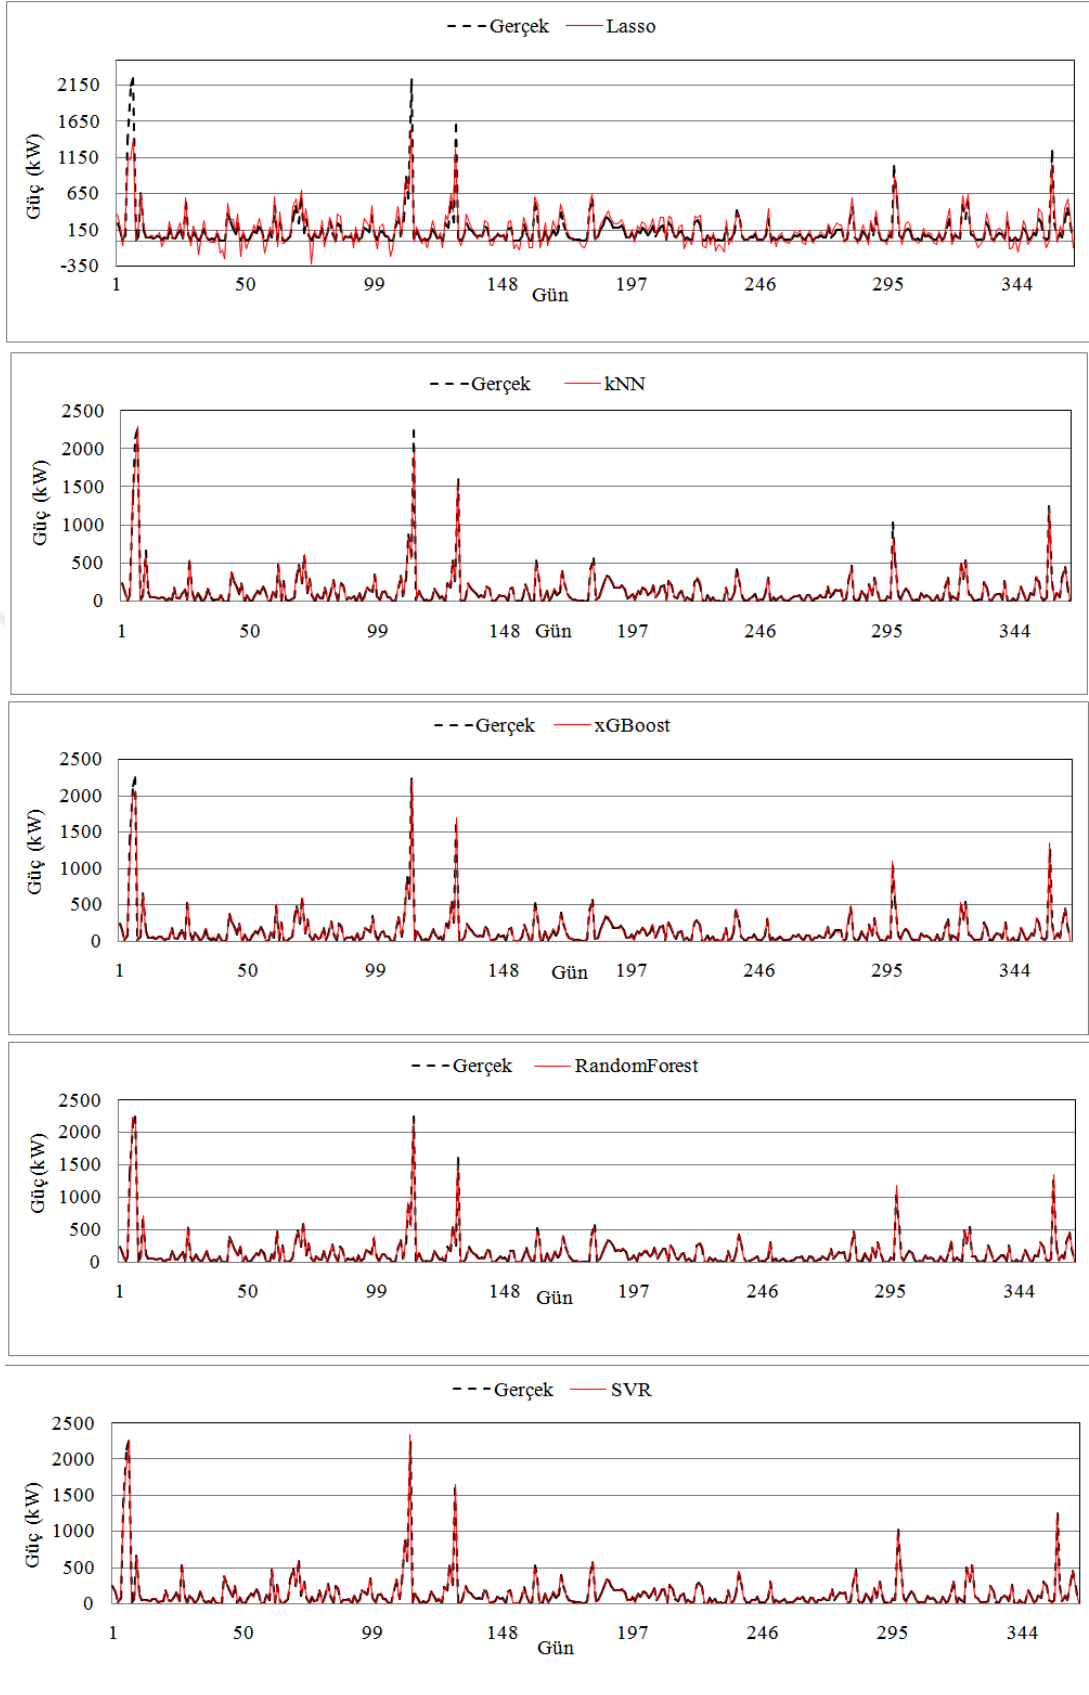
Çizelge 4.2, rüzgar enerjisi tahmin problemi için makine öğrenme algoritmalarının 5 lokasyondaki tahmin doğruluğunu göstermektedir. Beş aday algoritma arasında,

LASSO regresyon, modeli doğrusal bir düzleme sığdırmaya çalıştığından en kötü performansı sergileyen algoritmadır. kNN ve xGBoost regresyon algoritmaları, LASSO regresyonundan daha iyidir, ancak farklı sınırlamaları vardır. SVR ve RF algoritmalarının ise daha başarılı olduğu açıkça görülebilir. Çizelge incelendiğinde SVR algoritması R^2 ve RMSE değerlerine göre diğer algoritmalara kıyasla daha iyi performansa sahip olduğu açıkça görülmektedir. Çizelgedeki 5 lokasyondan elde edilen sonuçlar incelendiği zaman, algoritmaların tüm lokasyonlar için yüksek doğrulukta ve başarılı sonuçlar üretebildikleri görülmektedir.


Çizelge 4.2. Günlük rüzgar hızı ve standart sapma için algoritmaların 5 lokasyondaki tahmin doğruluğu

Metrik/Algoritma		LASSO	kNN	xGBoost	RF	SVR
Niğde	R^2	0,8619	0,9852	0,9939	0,995	0,992
	RMSE	116,61	53,82	34,40	30,224	38,52
	MAE	88,85	7,197	6,528	5,430	7,048
Çeşme	R^2	0,7600	0,9916	0,9974	0,9946	0,9989
	RMSE	107,86	20,12	11,22	16,24	7,12
	MAE	86,91	4,33	4,34	4,48	3,62
Bozcaada	R^2	0,8358	0,9603	0,9889	0,9915	0,9664
	RMSE	369,68	96,14	103,95	84,33	167,30
	MAE	283,95	12,24	12,91	12,01	8,51
Mamak	R^2	0,8208	0,9890	0,9956	0,9925	0,9959
	RMSE	182,11	45,05	28,39	27,39	15,55
	MAE	98,12	5,66	6,02	6,37	4,67
Silivri	R^2	0,8799	0,9950	0,9987	0,9966	0,9997
	RMSE	223,29	45,58	23,36	37,69	10,82
	MAE	174,56	10,38	7,21	7,78	5,69

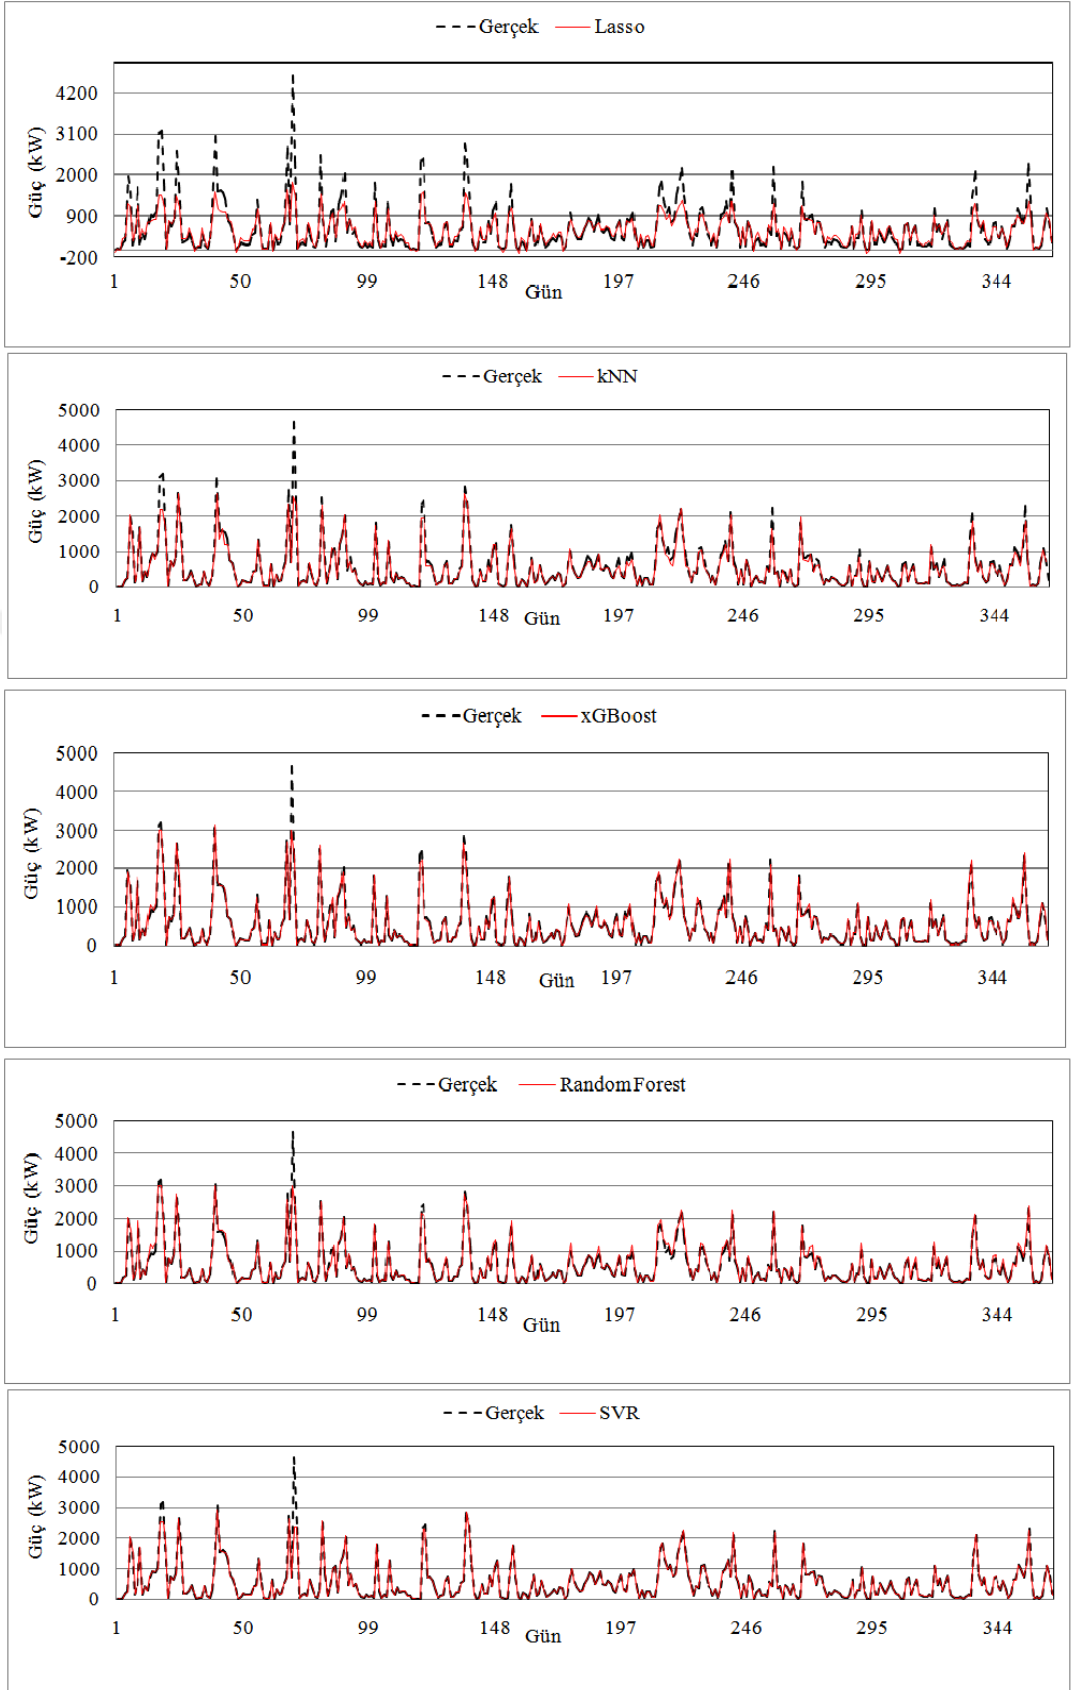
Şekiller 4.10-4.14'te regresyon algoritmalarının 5 bölge için gerçek rüzgar gücü üretim değerlerini ve algoritmaların günlük tahmin sonuçlarını göstermektedir. Şekiller incelendiği zaman, çizelge 4.2 ile uyumlu bir şekilde LASSO algoritmasının en kötü tahmin değerlerini ürettiği, SVR ve RF algoritmalarının ise en başarılı tahmin değerlerini ürettiği görülmektedir. Ayrıca kNN ve xGBoost algoritmaları da yüksek başarıya ulaşabilen algoritmalarıdır.



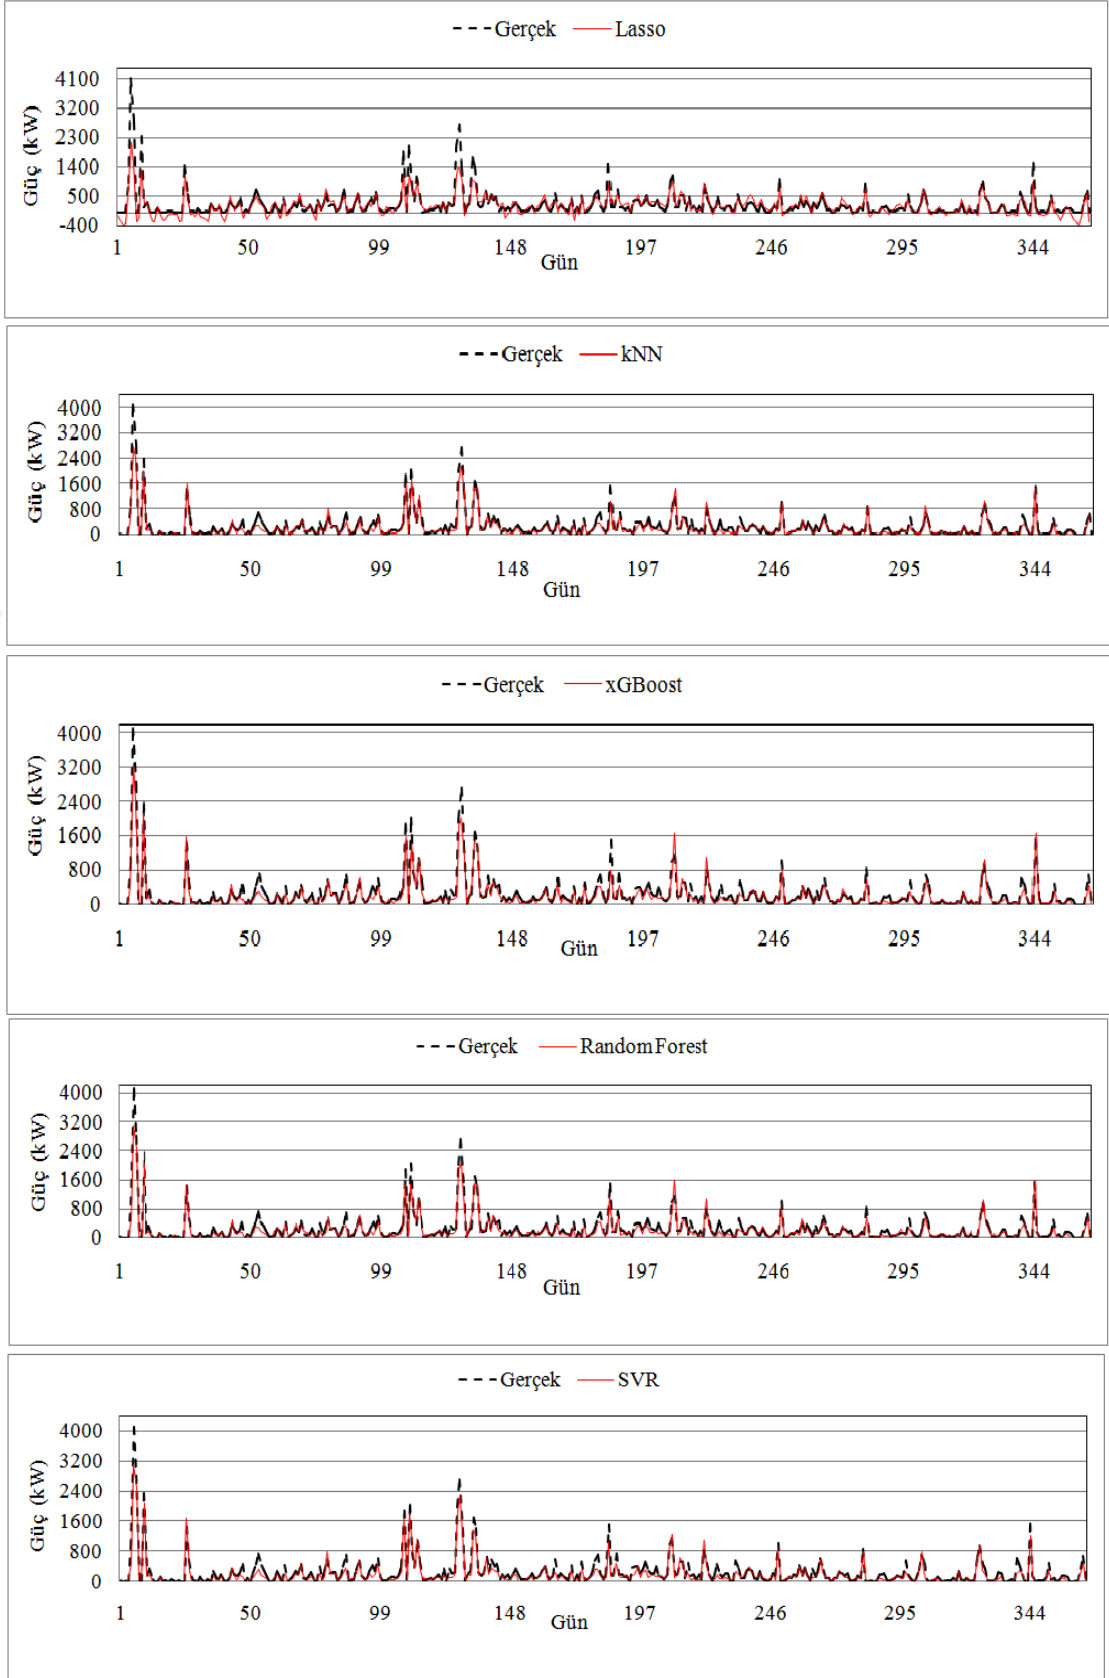
Şekil 4.10. Niğde bölgesi için günlük gerçek rüzgargücü değerleri ve algoritmaların tahmini




Şekil 4.11. Çeşme bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini



Şekil 4.12. Silivri bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini



Şekil 4.13. Mamak bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini




Şekil 4.14. Bozcaada bölgesi için günlük gerçek rüzgar gücü değerleri ve algoritmaların tahmini

4.2.2 Güneş Enerjisi Tahmini Deneysel Sonuçları

Bu bölümde, regresyon algoritmaları kullanılarak günlük ortalama güneş radyasyonu ve ortam sıcaklığı verileri kullanılarak üretilecek olan güneş gücü tahmini yapılmıştır. Veri kümesinin ilk dört yıllık kısmı eğitim için kullanılmış, son bir yılı ise test için ayrılmıştır. Her bir algoritma için Niğde bölgesindeki güneş enerjisi tahmini sonuçları aşağıda sunulmuştur. Ayrıca 5 bölgedeki algoritmaların tahminleriyle gerçek güç üretim değerlerin karşılaştırması yapılmıştır.

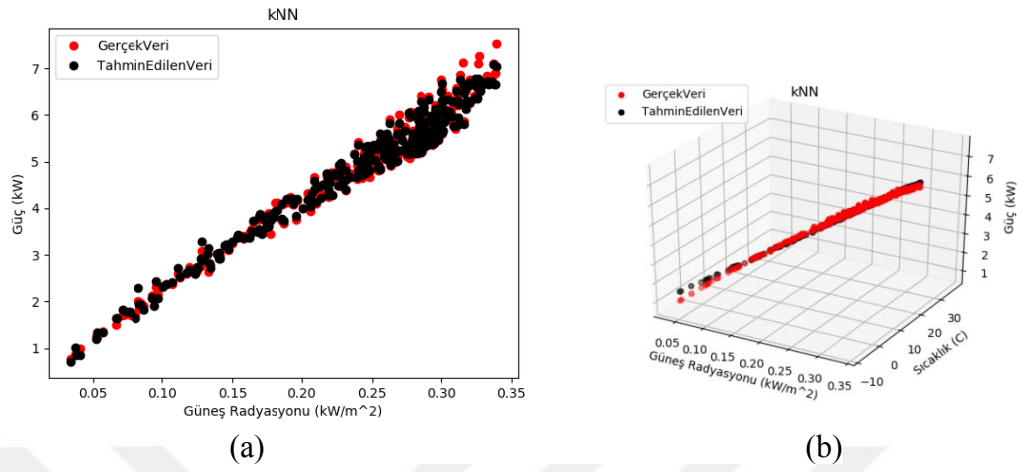
Şekil 4.15'te LASSO regresyonunun güneş enerjisi tahmini sonuçları gösterilmektedir. Burada görülen eğilimin temel nedeni, LASSO'nun bir tür doğrusal regresyon olmasıdır ve modeli doğrusal bir düzleme yerleştirmeye çalışmasıdır. Şekil 4.15 (b)'de görülebildiği gibi, ortam sıcaklığı tahmin edilen gücü etkilemektedir. Küçük değerli sıcaklık aralıklarında, LASSO tarafından büyük sıcaklık değerinden daha doğru tahmin edildiği görülmektedir.



Şekil 4.15. (a) Tahmini güneş gücü ve (b) LASSO regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi

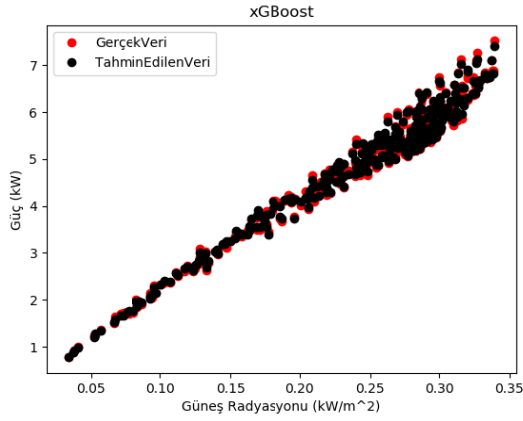
Şekil 4.16' da kNN regresyonu ile gerçekleştirilen güneş enerjisi güç tahmini ve gerçek değerler göstermektedir. Şekil 4.16 (a)'da görülebileceği gibi kNN algoritması güneş enerjisi değerlerini doğrusal olarak tahmin edebilir. Ayrıca, sonuçlar kNN algoritmasının tahmin performansının iyi olduğunu göstermektedir. Daha düşük ve daha yüksek güneş radyasyonu değerleri için, kNN algoritmasının doğruluğu azalmaktadır. Ayrıca, şekil 4.16 (b)'de görüldüğü üzere, ortam sıcaklığındaki artış da

algoritmanın doğruluğunu etkilemektedir. Bununla birlikte, kNN algoritmasının genel performansı hakkında, R^2 değeri yüksek olduğu için iyi denebilir.

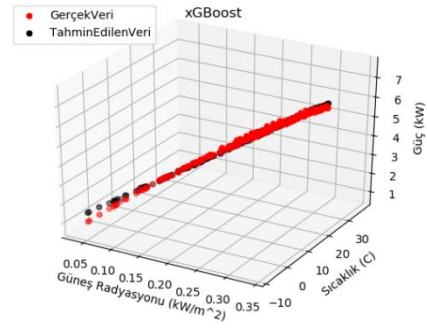


Şekil 4.16. (a) Tahmini güneş gücü ve (b) kNN regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi

Şekil 4.17, xGBoost regresyon algoritmasının sonuçlarını göstermektedir. Şekil 4.17 (a)'da görülebileceği gibi, kNN algoritmasına benzer şekilde, xGBoost algoritması da daha yüksek güneş ışınımı için doğru güç değerlerini tahmin edememiştir. Ancak başarımlar olarak kNN algoritmasından daha iyi doğruluğa sahiptir. Şekil 4.17 (b)'de görülebileceği gibi, ortam sıcaklığının çok yüksek olduğu durumlarda bile xGBoost doğru tahmini gerçekleştirebilmektedir.



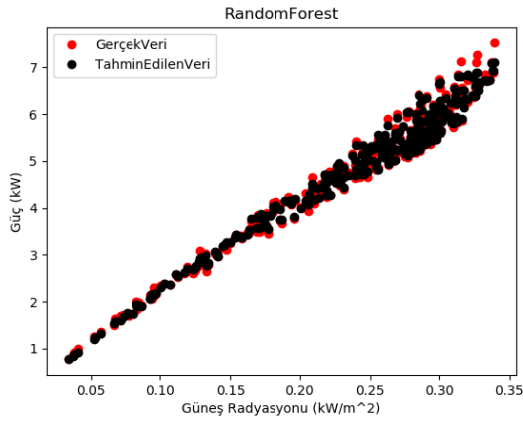
(a)



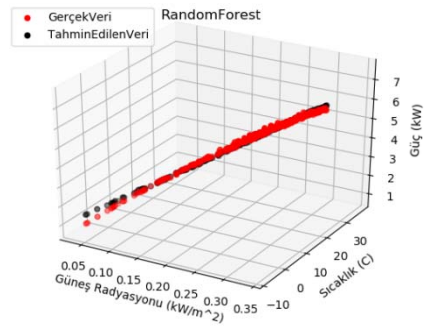
(b)

Şekil 4.17. (a) Tahmini güneş gücü ve (b) xGBoost regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi

Şekil 4.18'de, Rastgele Orman regresyonunun sonuçları sunulmaktadır. Şekil 4.18 (a)'da görülebileceği gibi, RF' da başarılı bir şekilde güç tahmini gerçekleştirebilir ve güneş radyasyonu değerlerinin yüksek olduğu durumlarda SVR'dan daha iyi performans sergilemektedir. Ancak 0.3-0.35 arasındaki güneş radyasyonu değerlerindeki artışla başa çıkamaz. Ayrıca, şekil 4.18 (b)'de görülebileceği gibi RF, ortam sıcaklığındaki değişime uyum sağlayarak sonuçları doğru bir şekilde tahmin edebilmektedir.



(a)

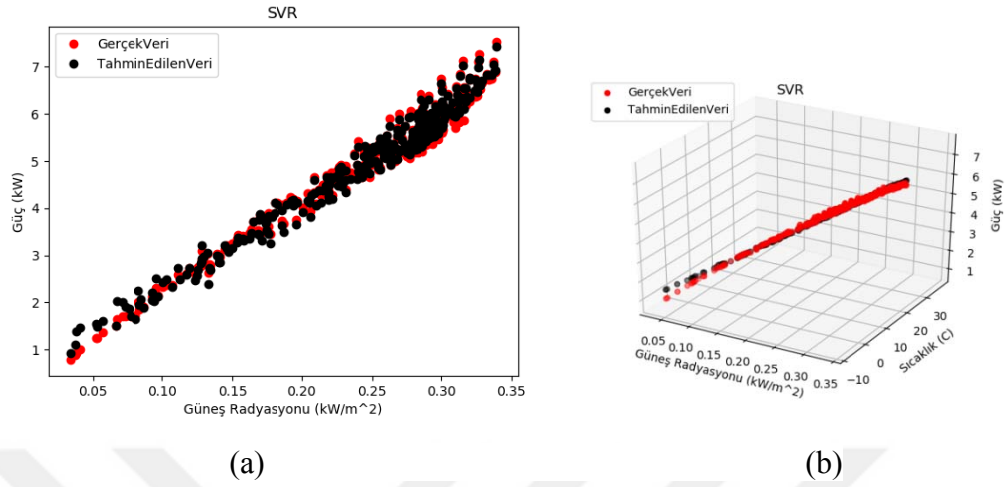


(b)

Şekil 4.18. (a) Tahmini güneş gücü ve (b) RF regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi

Şekil 4.19, SVR sonuçlarını göstermektedir. Şekil 4.19 (a)'da görülebildiği gibi SVR, diğer algoritmalara göre güç değerlerini daha doğru tahmin edebilir. Ayrıca, şekil 4.19

(b)'de SVR'nin ortam sıcaklığının değişimini uyarlayabildiğini ve güneş radyasyonu ve ortam sıcaklığına dayalı gücü başarıyla öngörebildiğini göstermektedir.




Şekil 4.19. (a) Tahmini güneş gücü ve (b) SVR regresyonu kullanılarak güneş radyasyonu ve ortam sıcaklığının etkisinin 3B görselleştirilmesi

Çizelge 4.3, günlük ortalama güneş radyasyonu ve ortam sıcaklığı için algoritmaların 5 lokasyondaki tahmin doğruluğunu vermektedir. Beş aday algoritma arasında, LASSO regresyonu, modeli doğrusal bir düzleme sığdırmaya çalıştığından en başarısız algoritmadır. kNN ve RF regresyon algoritmaları, LASSO regresyonundan daha iyidir, ancak kendilerine özgü farklı parametreleri vardır. SVR ve xGBoost algoritmaları ise daha başarılı olarak görülebilir, çünkü ürettikleri modeller yüksek oranda ortam değişimine daha iyi uyum göstermektedirler. Bu iki algoritma arasında SVR, R^2 , RMSE ve MAE değerlerine göre daha iyi hassasiyete sahiptir. Ancak, xGBoost algoritması ile arasındaki fark azdır.


Çizelge 4.3. Günlük ortalama güneş radyasyonu ve ortam sıcaklığı için algoritmaların 5 lokasyondaki tahmin doğruluğu

Metrik/Algoritma		LASSO	kNN	xGBoost	RF	SVR
Niğde	R ²	0,9523	0,9954	0,9983	0,9973	0,9987
	RMSE	0,2895	0,0898	0,0542	0,0689	0,0348
	MAE	0,2069	0,0428	0,0380	0,0371	0,0309
Çeşme	R ²	0,9858	0,9784	0,9796	0,9789	0,9648
	RMSE	0,16	0,20	0,19	0,19	0,25
	MAE	0,11	0,13	0,11	0,12	0,23
Bozcaada	R ²	0,9861	0,9824	0,9828	0,9820	0,9724
	RMSE	0,1673	0,19	0,19	0,1899	0,24
	MAE	0,11	0,12	0,11	0,1086	0,21
Mamak	R ²	0,9827	0,9513	0,9549	0,9571	0,9213
	RMSE	0,18	0,31	0,29	0,29	0,39
	MAE	0,11	0,23	0,21	0,22	0,34
Silivri	R ²	0,9845	0,9854	0,9863	0,9864	0,9787
	RMSE	0,19	0,18	0,18	0,18	0,22
	MAE	0,12	0,12	0,11	0,11	0,18


Şekiller 4.20-4.24'te regresyon algoritmalarının 5 bölge için gerçek güneş gücü üretim değerlerini ve algoritmaların günlük tahmin sonuçlarını göstermektedir. Şekillerde görüldüğü üzere, LASSO regresyon algoritması en başarısız tahminlere sahiptir. Bununla birlikte diğer algoritmaların tahmin sonuçları başarılı olarak görülebilir.




Şekil 4.20. Niğde bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini



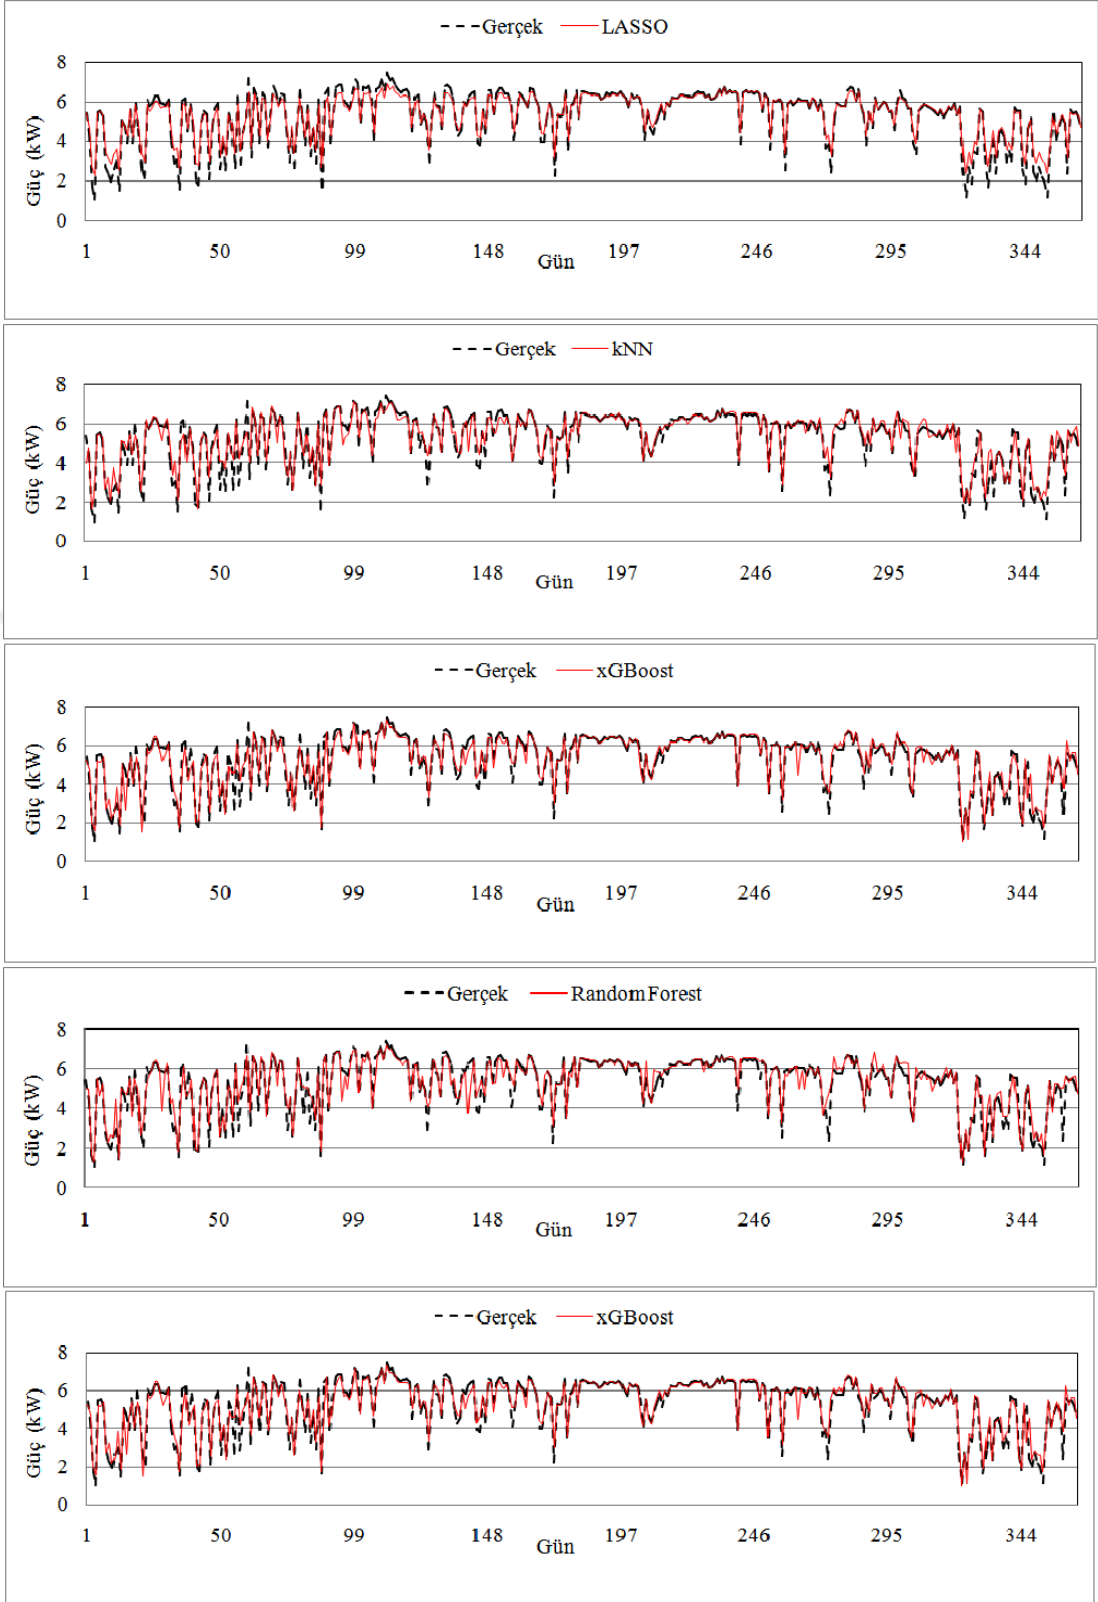
Şekil 4.21. Çeşme bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini



Şekil 4.22. Silivri bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini



Şekil 4.23. Mamak bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini



Şekil 4.24. Bozcaada bölgesi için günlük gerçek güneş gücü değerleri ve algoritmaların tahmini

BÖLÜM V

OPTİMUM HİBRİT SİSTEM BOYUTLANDIRMASI DENEYSEL SONUÇLARI

Bu bölümde öncelikle oluşturulan hibrit sistemin bileşenlerinin teknik özellikleri, yük talebinin karakteristiği ve güneş enerjisi/batarya ve güneş enerjisi/rüzgar enerjisi/batarya hibrit sistemlerin modelleri açıklanmıştır. Daha sonra, Bölüm 3.3.3'te önerilen deterministik algoritma ve yapay zeka algoritmalarından elde edilen optimum hibrit yenilenebilir enerji sistemi boyutlandırmasının sonuçları sunulmuştur. İlk olarak güneş enerjisi ve batarya hibrit sisteminin boyutlandırması için kullanılan algoritmalarından elde edilen sonuçlar, daha sonra güneş enerjisi, rüzgar enerjisi ve batarya hibrit sisteminin boyutlandırması için elde edilen sonuçlar verilmiştir.

5.1 Oluşturulan Hibrit Sistemin Özellikleri

Hibrit yenilenebilir enerji sistemlerinde kurulması gereken optimum sistemin keşfedilmesi, enerji kaynaklarına, teknik sistemin performansına, iklim koşullarına ve yük profiline bağlı karmaşık bir süreçtir (Zahraee vd., 2016). Literatürde hibrit yenilenebilir enerji sistemlerinin modellenmesi, konfigürasyonu, planlaması ve optimizasyonu üzerine farklı bölgeler ve kıstaslar için çalışmalar yapılmıştır (Al-falahi vd., 2017). Bu çalışmaların çoğu, birbirleri ile verimli bir şekilde çalıştıkları için güneş ve rüzgar enerjisinin hibrit kullanımını içermektedir (Fathima ve Palanisamy, 2015).

Hibrit yenilenebilir enerji sistemlerinin optimal tasarımı bazı sınırlamaları ve kriterleri barındırır. Bu kriterler ekonomik ve teknik olmak üzere iki genel gruba ayrılır (Ghofrani ve Hosseini, 2016). Ekonomik kriterlerin amacı, sistemin maliyetini en aza indirmektir. Teknik sınırlamalar ise güvenilirliği, verimliliği en üst düzeye çıkarmayı ve çevre üzerindeki olumsuz etkiyi azaltmayı amaçlamaktadır. Hibrit yenilenebilir enerji sistemleri, yüksek yatırım maliyetleri ve düşük bakım ve işletme maliyetleri ile karakterize edilir. Bundan dolayı, kurulacak hibrit sistemin gerekli gücü yeterli altyapıyla sağlayacak optimum bir sistem olması gerekmektedir.

Bu bölümün devam eden kısımlarında güneş enerjisi, rüzgar enerjisi ve batarya için seçilen bileşenlerin teknik özellikleri verilmiştir. Daha sonra yük talebi modellenmiş ve güneş/batarya ve güneş/rüzgar/batarya hibrit modellerin teknik özellikleri sunulmuştur.

5.1.1 Güneş Enerjisi Sistemi Teknik Özellikleri


Bu tez çalışmasında kullanılmak üzere seçilen güneş panelinin teknik özellikleri çizelge 5.1'de verilmiştir (HOMER Energy, 2016; Halabi vd., 2017).

Çizelge 5.1. Seçilen güneş panelinin teknik ve ekonomik özellikleri

Özellikleri	PV paneli
Panel Maliyeti [\$]	2000
Değiştirme Maliyeti [\$]	2000
İşletme ve Bakım Maliyeti [\$/yıl]	10
Ömür [yıl]	25
Çalışma Sıcaklığı [°C]	47
Sıcaklığın güç üzerindeki etkisi [%/°C]	-0,5
Zemin Yansımaları [%]	20

5.1.2 Rüzgar Enerjisi Sistemi Teknik Özellikleri

Bu tez çalışmasında, seçilen rüzgar türbininin güç eğrisi şekil 5.1'de verilmiştir ve teknik özellikleri de çizelge 5.2'de listelenmiştir. Bu çalışmada, yük talebi ile ilgili kapasitesi nedeniyle 2.5 kW'lık bir rüzgar türbini seçilmiştir.



Şekil 5.1. 2.5 kW rüzgar türbini için güç eğrisi.

Çizelge 5.2. Seçilen rüzgar türbininin teknik ve ekonomik özellikleri (HOMER Energy, 2016).

Özellikleri	Rüzgar türbini
Anma gücü (kW)	2,5
Kule yüksekliği (m)	18
Rotor çapı (m)	5
Süpürme alanı (m ²)	19,6
Kanat sayısı	3
Kesme rüzgar hızı (V _{ci}) (m/s)	3,0
Kesme rüzgar hızı (V _{co}) (m/s)	25,0
Maliyeti [\$/kW]	2000
İşletme bakım maliyeti [\$/yıl]	100

5.1.3 Batarya Sistemi Teknik Özellikleri

Enerji yönetim sistemi, rüzgarın ve güneş ışınlarının öngörülemez doğası nedeniyle, özellikle PV’lerde yenilenebilir enerji jeneratörleri için yaygın olarak kullanılmaktadır. PV tarafından üretilen ekstra elektrik bataryaya depolanırken, elektrik eksikliği durumunda gerekli yük talebini karşılanır. Çizelge 5.3’de bu tez çalışmasında kullanılan bataryanın (Standart 1 kWA Lead Acid) teknik özellikleri verilmiştir. Akünün şarj ve deşarj durumunda gücü Eşitlik 5.1’de verilmiştir (Maleki ve Pourfayaz, 2015):

$$P_{Batt}(t) = P_{Batt}(t-1) \cdot (1 - \sigma) + \left[(N_{PV} \cdot P_{PV}(t)) \cdot \eta_{Inv} - \frac{P_{Load}(t)}{\eta_{Inv}} \right] \cdot \eta_{Batt} \quad (5.1)$$

Yenilenebilir kaynaklardan üretilen güç, güç talebinden daha azsa, deşarj başlar. Deşarj durumundaki pilin güç denklemi Eşitlik 5.2’de verilmiştir (Maleki ve Pourfayaz, 2015):

$$P_{Batt}(t) = P_{Batt}(t-1) \cdot (1 - \sigma) - \left[\frac{P_{Load}(t)}{\eta_{Inv}} - (N_{PV} \cdot P_{PV}(t)) \cdot \eta_{CON} \right] / \eta_{Batt} \quad (5.2)$$

Formüllerde kullanılan kısaltmalar aşağıda verilmiştir.

$P_{Batt}(t)$ - t zamanında pil şarjı,

$P_{Batt}(t-1)$ - t-1 zamanındaki şarj miktarını temsil eder,
 $\sigma = 0.0002$ - pilin kendi kendine deşarj oranı,
 η_{CON} - dönüştürücü verimliliği,
 η_{REC} - doğrultucu verimliliği,
 η_{Inv} - inverter verimliliği,
 η_{Batt} - pil sisteminin şarj verimliliği

Çizelge 5.3. Seçilen bataryanın teknik ve ekonomik özellikleri (HOMER Energy, 2016).

Özellikleri	Batarya
Nominal Gerilim [V]	12
Nominal kapasite [kWh]	1,45
Maksimum kapasite [Ah]	83,4
Gidiş Dönüş Verimliliği [%] η_{Batt}	85
Maksimum şarj akımı [Ah]	16,7
Minimum şarj durumu [%]	40
Maliyeti [\$/birim]	110
Değiştirme Maliyeti [\$]	100
İşletme ve bakım maliyeti [\$/yıl]	10
Ömür [yıl]	10

5.1.4 Konvertör (Dönüştürücü) Teknik Özellikleri

Adından da anlaşılacağı gibi, dönüştürücü, ters akım olarak bilinen bir işlemle doğru akımı (DC) alternatif akıma (AC) dönüştüren bir aygıttır. Dönüştürücü ayrıca düzeltme olarak bilinen bir işlemle AC'yi DC'ye dönüştürür. Güç sistemi için gerekli olan dönüştürücünün boyutu pik yük gereksinimine göre belirlenir. Bu çalışmada pik yük gereksinimi 3.672 [kWh]'dir. Konvertör, toplam pik yük gereksinimi karşılayacak kadar büyük olmalıdır. Konvertör boyutu toplam pik yük gereksiniminden % 25 -% 30 daha büyük olacak şekilde seçilir (Khatri, 2016):

$$P_{con} = P_{LoadPeak} \cdot SF = 3.672 \cdot 1.3 = 4.8 [kWh] \quad (5.3)$$

$P_{loadPeak}$ - talep pik noktası

SF-güvenlik faktörü,


Bu çalışmada konverter boyutu 5 kW olarak seçilmiştir. Çizelge 5.4'te seçilen dönüştürücünün teknik özellikleri verilmiştir (HOMER Energy, 2016).

Çizelge 5.4. Seçilen dönüştürücünün teknik özellikleri

Özellikleri	Dönüştürücü
Dönüştürücü Maliyeti [\$]	700
Değiştirme Maliyeti [\$]	630
İşletme Bakım Maliyeti [\$/yıl]	10
Ömür [Yıl]	15
Verim [%]	95

5.1.5. Yük Talebi

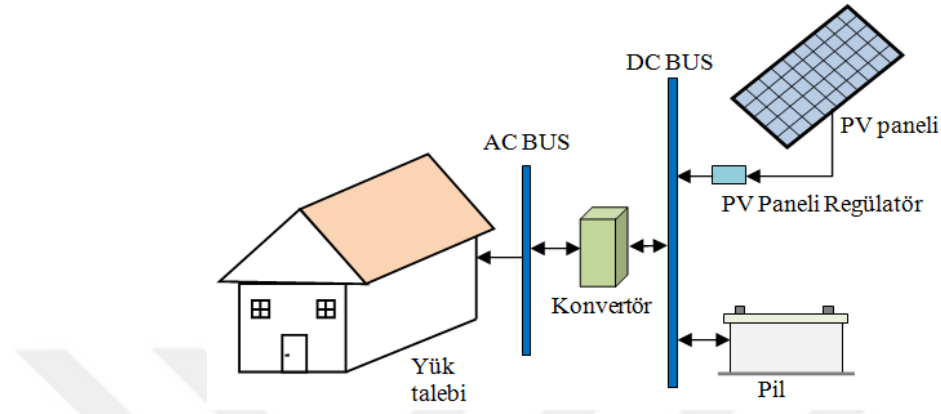
Şekil 5.2'de gün içerisinde tipik bir ev için talep edilen saatlik yük değerleri verilmektedir. Çalışmada bu değerler her iki lokasyon için de eşit alınarak işlemler gerçekleştirilmiştir.



Şekil 5.2. Bir ev için saatlik yük talebi

5.1.5 Güneş/Batarya Modeli

Temel güneş/batarya hibrit sistemin tasarımı şekil 5.3'te gösterilmiştir. Bu modelde fotovoltaik paneller, bataryalar, konvertör ve regülatör bulunmaktadır.



Şekil 5.3. Güneş/batarya hibrit sisteminin tasarımı

Bu sistemde, birim elektrik enerjisi üretim maliyetinin hesaplanması prosedürü aşağıda açıklanmıştır. Güneş paneli maliyeti aşağıda verilen denklem ile hesaplanabilir (Nafeh, 2011).

$$C_p = I_p P_p \text{ [\$]} \quad (5.5)$$

Burada I_p güneş panelinin spesifik maliyetini (\$/kW), P_p panel kurulu gücünü (kW) ifade etmektedir. Benzer şekilde, batarya (C_{bat}) ve dönüştürücü (C_{con}) maliyetleri de hesaplanabilir. Böylece göz önünde bulundurulmuş sistemin toplam maliyeti (Worighi vd., 2019).

$$C_{T, sis} = C_p + C_{con} + C_{bat} \text{ [\$]} \quad (5.6)$$

Diğer taraftan, bu çalışmada sistem ömrü toplam 25 yıl seçilmiş olup proje boyunca bazı sistem elemanların değiştirilmesi gerekmektedir. Dönüştürücü ömrü 15 yıl olup proje süresince 1 kez değiştirilmesi gerekmektedir. Dolayısıyla tek ödeme şimdiki değer faktörü kullanılarak değiştirilen dönüştürücünün maliyeti aşağıdaki gibi hesaplanabilir (Gökçek ve Kale, 2018).

$$C_{con/rep} = P_{con} \left(\frac{1}{(1+i)^{15}} \right) \quad (5.7)$$

Burada P_{con} konverter maliyetini, i ise faiz oranını göstermektedir. Batarya sisteminde ömrü 10 yıl olup proje süresi boyunca 10 uncu ve 20 inci yıllarda değiştirilmesi gerekmektedir. Tek ödeme şimdiki değer faktörünü kullanarak değiştirilen batarya sisteminin şimdiki değeri aşağıdaki denklemle hesaplanabilir (Gökçek ve Kale, 2018).

$$C_{bat/rep} = P_{bat} \left(\frac{1}{(1+i)^{10}} + \frac{1}{(1+i)^{20}} \right) \quad (5.8)$$

İşletme bakım maliyetler, değiştirme maliyetleri de hesaba katıldığında sistemin toplam maliyeti aşağıda verilen denklem 5.9 ile hesaplanabilir (Worighi vd., 2019).

$$C_{T, sis} = C_P + C_{con} + C_{bat} + C_{p,o\&m} + C_{c,o\&m} + C_{b,o\&m} + C_{con/rep} + C_{bat/rep} \quad [\text{\$}] \quad (5.9)$$

İlk sermaye maliyetini yıllık sermaye maliyeti değerine dönüştürmek için, denklem 5.10'de verilen yatırım ikame faktörü (CRF) değeri kullanılır (Gökçek ve Kale, 2018).

$$CRF = \frac{i(1+i)^n}{(1+i)^n - 1} \quad (5.10)$$

Burada, i faiz oranı %8 olarak alınmıştır, n projenin yıl olarak ömrü olup göz önünde bulundurulan elektrik üretim sisteminin ömrü boyunca farklı zamanlarda yapılan masraflarda düşünüldüğünde ve yıllık elektrik enerji üretiminin sabit olduğu düşünüldüğünde, enerji üretim maliyeti denklem 5.11 ile hesaplanabilir. Bu hesaplama metoduna, Bir Değere Getirilmiş Maliyet (LCOE) metodu adı verilir (Gökçek ve Kale, 2018).

$$LCOE = \frac{(C_P + C_{con} + C_{bat} + C_{con/rep} + C_{bat/rep})CRF + C_{p,o\&m} + C_{c,o\&m} + C_{b,o\&m}}{AEP} \quad [\text{\$/kWh}] \quad (5.11)$$

Burada AEP (kWh) sistem tarafından üretilen yıllık elektrik enerji miktarıdır. Bu metotla paranın zaman değeri dikkate alınarak eşdeğer bir enerji üretim maliyeti elde edilir.

Bu çalışmada, optimal sistem boyutlandırılması işlemi bir değere getirilmiş maliyet değerinin minimum değerine göre yapılmıştır. Optimizasyon probleminde güç tedarik kaybı olasılığı (LPSP) güvenilirlik indeksi kullanılmıştır. Hibrit enerji sistemlerinde, çoğunlukla güvenilir bir sisteme sahip olmak için güç tedarik kaybı olasılığı kavramı dikkate alınır. Bu değer, 0 ile 1 arasında bir sayı ile tanımlanır. 1 değeri yükün asla karşılanamayacağını, 0 değeri yükün her zaman karşılanacağı anlamına gelir. Herhangi bir T periyodu için güç tedariki kaybı olasılığı, fotovoltaik paneller, rüzgar türbinleri gibi enerji üreten birimlerin ve bataryada depolanan enerjinin yük talebini karşılayamadığı durumda ortaya çıkan ve güç tedariki kaybı (LPS) olarak isimlendirilen değer ile yük talebi toplamının oranıdır. Belirli bir süre için güç tedarik kaybı olasılığı değeri aşağıda verilen denklem 5.12 ile tanımlanır (Al-Sharafi vd., 2017).

$$LPSP = \frac{\sum_{t=1}^T LPS(t)}{\sum_{t=1}^T E_{yük}(t)} \quad (5.12)$$


burada, LPS değeri denklem (5.13) kullanılarak hesaplanır (Al-Sharafi vd., 2017).

$$LPS(t) = E_{yük}(t) - E_{gen}(t) \quad (5.13)$$

Burada $E_{gen}(t)$ herhangi bir zamanda hibrit sistemde bulunan güç üretim birimlerinde üretilen elektrik enerjisi miktarıdır.

5.1.6 Güneş/Rüzgar/Batarya Modeli

Temel güneş/rüzgar/batarya hibrit sistemin tasarımı şekil 5.4'de gösterilmiştir. Bu modelde fotovoltaik paneller, rüzgar türbinleri, bataryalar, konvertör ve regülatör bulunmaktadır. Önceki kesimde anlatılan güneş/batarya sisteminden farklı olarak bu sistemde rüzgar türbini bulunmaktadır.



Şekil 5.4. Güneş/rüzgar/batarya hibrit sistemin tasarımı

Bu sistemde birim elektrik enerjisi üretim maliyeti ise rüzgar türbini göz önünde bulundurularak aşağıdaki denklemle hesaplanabilir (Gökçek ve Kale, 2018).

$$LCOE = \frac{C_{toplam} CRF + C_{p,o\&m} + C_{c,o\&m} + C_{b,o\&m} + C_{WT,o\&m}}{AEP} \text{ [$/kWh]} \quad (5.14)$$

Burada C_{toplam} denklem 5.15 ile verilmiştir (Worighi vd., 2019).

$$C_{toplam} = C_P + C_{con} + C_{bat} + C_{WT} + C_{con/rep} + C_{bat/rep} \quad (5.15)$$

Burada, C_{WT} rüzgar türbini maliyeti, $C_{WT,o\&m}$ ise rüzgar türbini yıllık işletme bakım maliyetidir.


Diğer yatırımlarda olduğu gibi enerji üretim santrallerinin kurulmasından önce de ekonomik değerlendirmelerin yapılması fizibilite çalışmalarının önemli bir parçasını oluşturur. Bir enerji yatırımı yapılmadan önce, kullanılacak enerji kaynağına bağlı olarak teknik analiz yapılırken paralelinde de yatırım ve enerji maliyetinin belirlenmesi gereklidir. Bazı enerji üretim santrallerinin ilk yatırım maliyeti fazla olsa bile, ömür boyu maliyet değerlendirilmesi yapıldığında bu yatırımın ucuz olduğu görülebilmektedir. Sistemlerin ömür boyu maliyetlerinin hesaplanmasında Bugünkü Net Maliyet (BNM) yöntemi kullanılabilir. Bir sistemin Bugünkü Net Maliyeti (BNM), sistemin kullanım ömrü boyunca yapılan tüm para akışlarının bugünkü değeridir.

Yapılan harcamalar, sermaye maliyetlerini, deęiřtirme maliyetlerini, iřletme ve bakım maliyetlerini, yakıt maliyetlerini, emisyon cezalarını ve řebekeden elektrik satın alma maliyetlerini ierir. Sistemden elde edilen gelirler ise, sistemin hurda deęerini ve řebekeye elektrik satıř deęerini ierir.


5.2 Gneř Enerjisi ve Batarya Hibrit Sistem Boyutlandırması

5.2.1 Nięde lokasyonu iin gneř enerjisi ve batarya hibrit sistem boyutlandırması


Verilen yk talebine ve tekno-ekonomik gstergeler ile nerilen Deterministik Algoritma, Genetik Algoritma ve Yapay Arı Kolonisi (ABC) algoritması sonularına gre, Nięde ili iin oluřturulan optimal gneř/batarya g retim sistemi, 19 adet panel ve 24 birim bataryadan oluřmakta olup, řekil 5.5, řekil 5.6 ve řekil 5.7’de, fotovoltaiik paneller tarafından retilen g, batarya g (řarj durumu) ve talep fazlası elektrik retimi (artık elektrik) deęerleri verilmiřtir. Nięde ili iin fotovoltaiik panellerde bir yıl boyunca retilen elektrik enerjisi miktarı **35939 kWh** olup, elektrik enerjisi retimi yıl boyunca deęiřiklik gstermektedir. Optimizasyon algoritmaları tarafından bulunan optimum sistem **0,0122 G Tedariki Kaybı** olasılıęı deęerine sahip olup, bir deęere getirilmiř elektrik enerjisi retim maliyeti **0,1514 \$/kWh** olarak hesaplanmıřtır.



řekil 5.5. Nięde’de fotovoltaiik paneller tarafından bir yıl boyunca retilen g

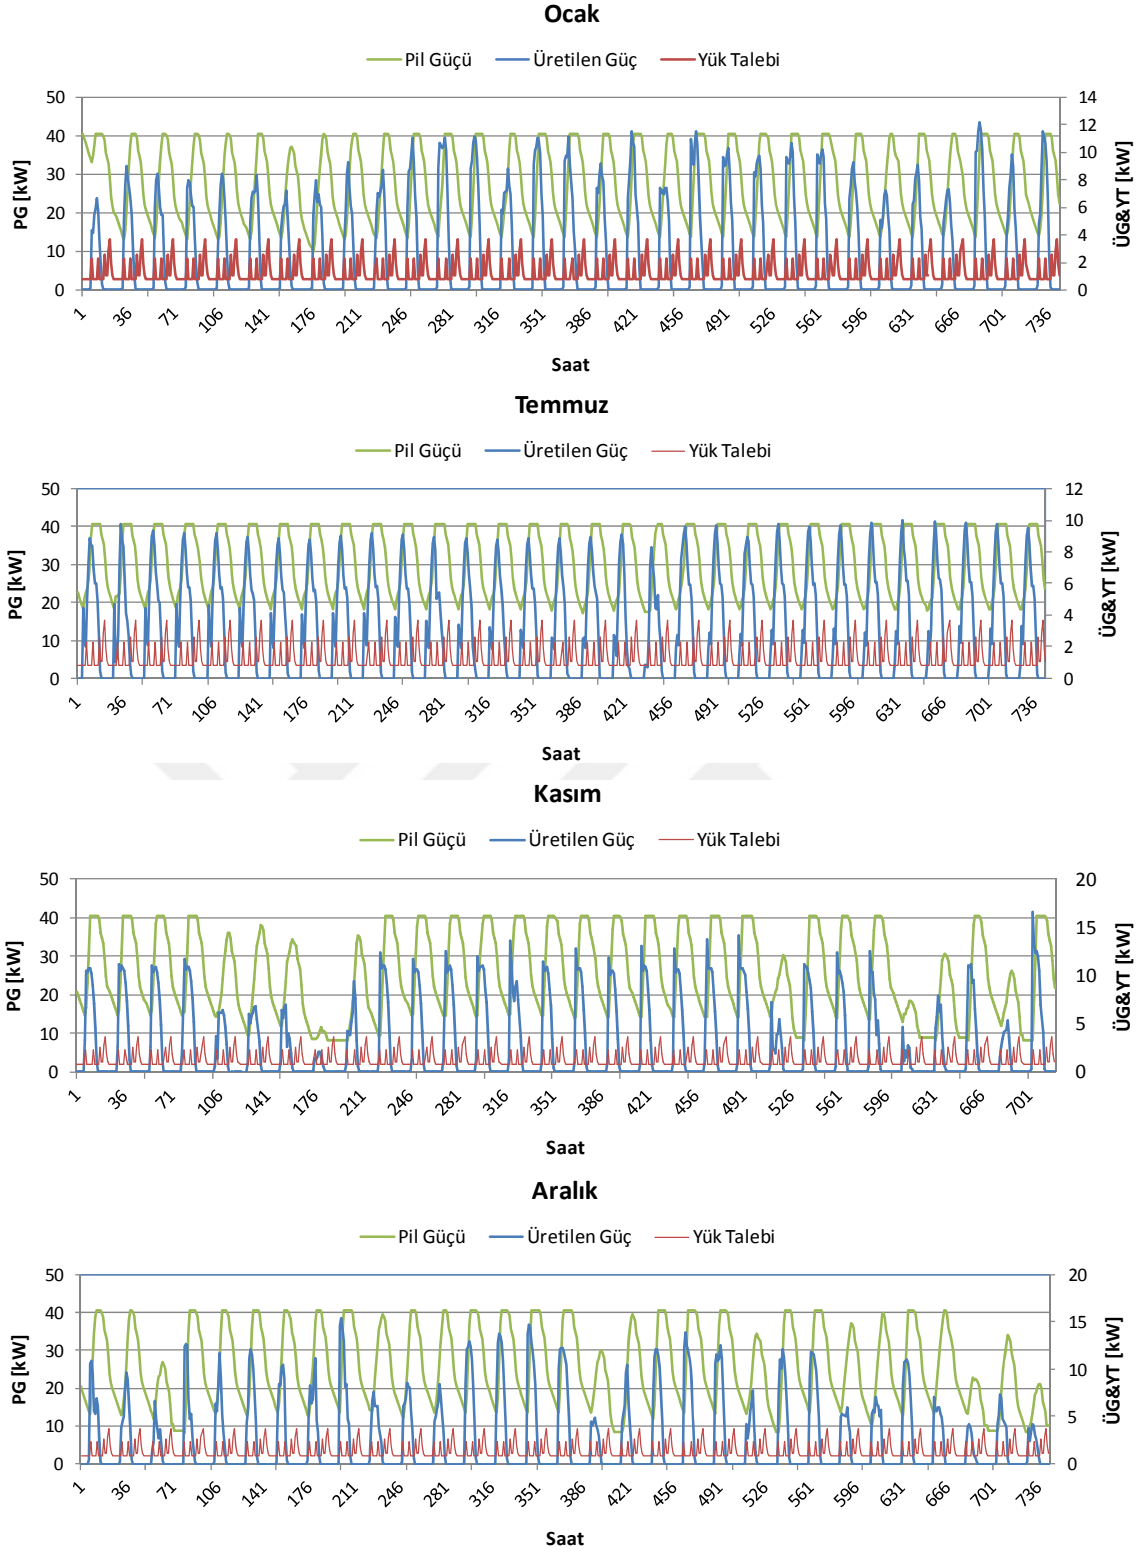


Şekil 5.6. Niğde için kullanılan bataryaların saatlik şarj durumu



Şekil 5.7. Niğde için talep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi


Şekil 5.8’de Niğde lokasyonunda elde edilen optimal sisteme ait üretilen güç, batarya gücü ve yük talebi verileri ocak, temmuz, kasım, aralık gibi karakteristik aylar için sunulmuştur. Ocak ayında fotovoltaik panellerde üretilen elektrik enerjisi miktarı 2611 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1243 kWh olarak hesaplanmıştır. Güneş radyasyonunun fazla olduğu temmuz ayında ise, fotovoltaik panellerde üretilen elektrik enerjisi miktarı 3387 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1906 kWh olarak hesaplanmıştır.



Şekil 5.8. Niğde için farklı aylarda üretilen güç, batarya ve yük talebi değerleri


Şekil 5.9 Niğde lokasyonu için, fotovoltaik paneller tarafından üretilen toplam aylık güç değerini ve toplam yük talebini göstermektedir. Elde edilen optimal sistem için, Niğde

lokasyonunda aralık ayı elektrik enerjisi üretim miktarı 2500 kWh iken, ekim ayında bu değer 3500 kWh olmuştur.



Şekil 5.9. Niğde'de üretilen elektrik ve yük talebinin toplam aylık değerleri


Şekil 5.10 Niğde lokasyonu için, oluşturulan optimal sistemde kullanılan bataryaların ortalama aylık şarj durumu görülmektedir. Şekilden de görüldüğü gibi, haziran, temmuz ve ağustos aylarında pil gücünün daha az kullanıldığı, pil gücü kullanımının kasım ve aralık aylarında arttığı görülmektedir.



Şekil 5.10. Niğde için kullanılan bataryaların ortalama aylık şarj durumu


Şekil 5.11, Niğde lokasyonu için oluşturulan optimal PV/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları görülmektedir. Bu değer aylık bazda değerlendirildiğinde, şekil 5.11'den görüldüğü gibi talep fazlası elektrik enerjisi üretiminin 1177 kWh ile 2042 kWh arasında değiştiği söylenebilir. Talep fazlası

elektrik enerjisi üretimi, güneş radyasyonu değerinin fazla olduğu temmuz ayında maksimum iken aralık ayında minimum olmuştur.



Şekil 5.11. Niğde'de aylık talep fazlası elektrik enerjisi üretimi


Şekil 5.12, Niğde lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını aylık bazda göstermektedir. Karşılanamayan elektrik enerjisi miktarı 0 kWh ile 18 kWh arasında değişmektedir. Şekil 5.12'den yük talebine göre karşılanamayan elektrik enerjisi miktarının maksimum değerinin kasım ayında olduğu görülmektedir.



Şekil 5.12. Niğde'de karşılanamayan toplam aylık güç değerleri


Şekil 5.13 Niğde lokasyonu için fotovoltaik paneller tarafından üretilen toplam güç değerlerini mevsimsel bazda göstermektedir. Bu şekilden görüldüğü, güneş radyasyonu değerinin fazla olduğu ilkbahar ve yaz mevsimlerinde enerji üretimi değerleri daha

yüksektir. Yaz mevsimi için PV panellerden üretilen elektrik enerjisi miktarı 9403 kWh iken, kış mevsimi için bu değer 8342 kWh olmuştur.




Şekil 5.13. Niğde'de üretilen toplam güç ve yük talebinin mevsimsel değişimi

Niğde lokasyonunda farklı mevsimler için elde edilen optimal sistemde kullanılan bataryaların şarj durumu şekil 5.14'de verilmiştir. Sonbahar ve kış mevsimlerinde elektrik enerjisi üretimi miktarı azaldığı için bataryaların doluluk oranı düşmektedir.




Şekil 5.14. Niğde lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu

Şekil 5.15'te Niğde lokasyonu için oluşturulan optimal PV/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları mevsimsel bazda görülmektedir. Şekil 5.15'den görüldüğü gibi talep fazlası elektrik enerjisi üretiminin 4185 kWh ile 5118 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi üretimi, güneş radyasyonu değerinin fazla olduğu yaz mevsiminde maksimum iken kış mevsiminde minimum olmuştur.



Şekil 5.15. Niğde'de mevsimseltalep fazlası elektrik enerjisi üretimi

Şekil 5.16, Niğde lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını mevsimsel bazda göstermektedir. Yaz mevsiminde karşılanmayan güç mevcut değildir, ancak sonbahar mevsiminde karşılanmayan güç değeri maksimumdur.




Şekil 5.16. Niğde'de karşılanamayan toplam gücün mevsimsel değerleri


5.2.2 Bozcaada lokasyonu için güneş enerjisi ve batarya hibrit sistem boyutlandırması

Verilen yük talebine ve tekno-ekonomik göstergeler ile önerilen deterministik algoritma, genetik algoritma ve yapay arı kolonisi algoritması sonuçlarına göre, Bozcaada için oluşturulan optimal güneş/batarya güç üretim sistemi, 17 adet panel ve 64 birim bataryadan oluşmakta olup, şekil 5.17, şekil 5.18 ve şekil 5.19'da, PV paneller tarafından üretilen güç, pil gücü (SOC şarj durumu) ve fazla elektrik üretimi değerleri verilmiştir. Bozcaada için fotovoltaik panellerde bir yıl boyunca üretilen elektrik enerjisi miktarı 35466 kWh olup, elektrik enerjisi üretiminin son bahar mevsiminde azaldığı


görülmektedir. Optimizasyon algoritmaları tarafından bulunan optimum sistem 0,0199 Güç Tedariki Kaybı Olasılığı değerine sahip olup, bir değere getirilmiş elektrik enerjisi üretim maliyeti 0,1898 \$/kWh olarak hesaplanmıştır.



Şekil 5.17. Bozcaada'da fotovoltaik paneller tarafından bir yıl boyunca üretilen güç

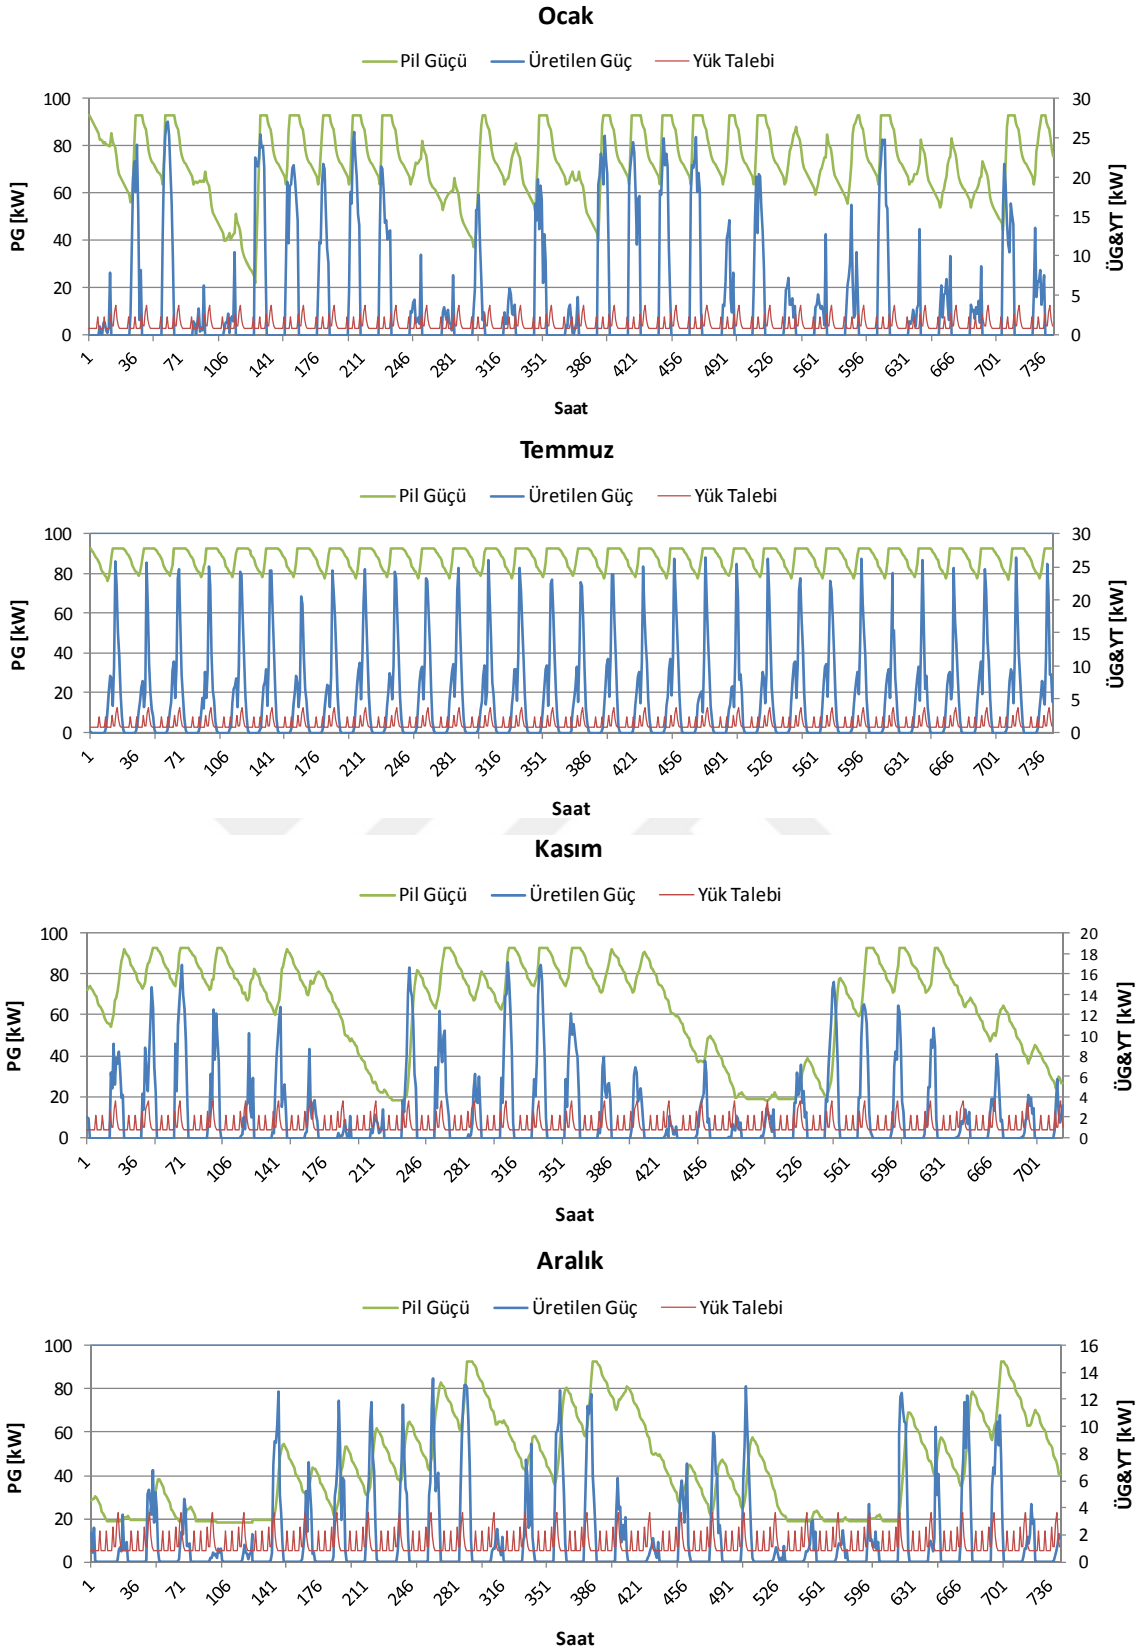


Şekil 5.18. Bozcaada lokasyonu için kullanılan bataryaların saatlik şarj durumu




Şekil 5.19. Talep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi

Şekil 5.20’de Bozcaada lokasyonlarında üretilen güç, batarya gücü ve yük talebi verileri ocak, temmuz, kasım, aralık gibi karakteristik aylar için sunulmuştur. Ocak ayında fotovoltaik panellerde üretilen elektrik enerjisi miktarı 2998 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1505 kWh olarak hesaplanmıştır. Güneş radyasyonunun fazla olduğu temmuz ayında ise, fotovoltaik panellerde üretilen elektrik enerjisi miktarı 3806 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 2265 kWh olarak hesaplanmıştır.




Şekil 5.20. Bozcaada için farklı aylarda üretilen güç, batarya ve yük talebi değerleri

Şekil 5.21 Bozcaada lokasyonu için, fotovoltaik paneller tarafından üretilen toplam aylık güç değerini ve toplam yük talebini göstermektedir. Elde edilen optimal sistem için, Bozcaada lokasyonunda aralık ayı elektrik enerjisi üretim miktarı 1150 kWh iken, ağustos ayında bu değer 4054 kWh olmuştur.



Şekil 5.21. Bozcaada'da üretilen elektrik ve yük talebinin toplam aylık değerleri


Şekil 5.22 Bozcaada lokasyonu için, oluşturulan optimal sistemde kullanılan bataryaların ortalama aylık şarj durumu görülmektedir. Şekilden de görüldüğü gibi, haziran, temmuz ve ağustos aylarında pil gücünün daha az kullanıldığı, pil gücü kullanımının kasım ve aralık aylarında arttığı görülmektedir.



Şekil 5.22. Bozcaada lokasyonu için kullanılan bataryaların ortalama aylık şarj durumu


Şekil 5.23'da Bozcaada lokasyonu için oluşturulan optimal PV/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları görülmektedir. Bu değer aylık bazda değerlendirildiğinde, şekil 5.23'den görüldüğü gibi talep fazlası elektrik enerjisi

üretiminin 65 kWh ile 2440 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi üretimi, güneş radyasyonu değerinin fazla olduğu ağustos ayında maksimum iken aralık ayında minimum olmuştur.



Şekil 5.23. Bozcaada’da aylık talep fazlası elektrik enerjisi üretimi


Şekil 5.24, Bozcaada lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını aylık bazda göstermektedir. Karşılanamayan elektrik enerjisi miktarı 0 kWh ile 93 kWh arasında değişmektedir. Şekil 5.24’ten yük talebine göre karşılanamayan elektrik enerjisi miktarının maksimum değerinin aralık ayında olduğu görülmektedir.



Şekil 5.24. Bozcaada’da karşılanamayan toplam aylık güç değerleri


Şekil 5.25 Bozcaada lokasyonu için fotovoltaik paneller tarafından üretilen toplam güç değerlerini mevsimsel bazda göstermektedir. Bu şekilden görüldüğü, güneş radyasyonu değerinin fazla olduğu ilkbahar ve yaz mevsimlerinde enerji üretimi değerleri daha

yüksektir. Yaz mevsimi için fotovoltaik panellerden üretilen elektrik enerjisi miktarı 11103 kWh iken, sonbahar mevsimi için bu değer 5182 kWh olmuştur.




Şekil 5.25. Bozcaada'da üretilen elektrik ve yük talebinin toplam mevsimsel değerleri

Bozcaada lokasyonunda farklı mevsimler için elde edilen optimal sistemde kullanılan bataryaların şarj durumu şekil 5.26'da verilmiştir. Sonbahar ve kış mevsimlerinde elektrik enerjisi üretimi miktarı azaldığı için bataryaların doluluk oranı düşmektedir.




Şekil 5.26.Bozcaada lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu

Şekil 5.27'de Bozcaada lokasyonu için oluşturulan optimal PV/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları mevsimsel bazda görülmektedir. Şekil 5.23'ten görüldüğü gibi talep fazlası elektrik enerjisi üretiminin 1756 kWh ile 6544 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi üretimi, güneş radyasyonu değerinin fazla olduğu yaz mevsiminde maksimum iken sonbahar mevsiminde minimum olmuştur.




Şekil 5.27. Bozcaada'da mevsimsel talep fazlası elektrik enerjisi üretimi

Şekil 5.28' de farklı mevsimlerde karşılanmayan gücün toplam değerlerini göstermektedir. Sonbahar mevsiminde fotovoltaik panellerden güç üretimi küçüktür ve karşılanmamış güç mevcuttur, diğer mevsimler için ise karşılanamayan yük bulunmamaktadır.



Şekil 5.28. Bozcaada'da karşılanmayan gücün toplam mevsimsel değerleri

Şekil 5.29'te, optimizasyon algoritmaları tarafından bulunan optimal sisteme ait toplam sistem maliyetinin şimdiki değeri gösterilmektedir. Şekil 5.29 incelendiğinde, Bozcaada'nın BNM (Bugünkü Net Maliyet) değerinin Niğde'ye kıyasla 1289 dolar daha yüksek olduğu görülmektedir. Çizelge 5.4'te göz önünde bulundurulmuş lokasyonlar için elde edilen optimal PV/batarya sistemlerine ait simülasyon sonuçları görülmektedir.



Şekil 5.29. Niğde ve Bozcaada için PV/batarya sisteminin BNM değerleri

Çizelge 5.5. PV/batarya sisteminin kullanılan algoritmalara göre optimal sonuçları

PV Panel (PV)/Batarya		
Lokasyon	Niğde	Bozcaada
PV Sayısı	19	17
Batarya Sayısı	24	64
LPSP [%]	1,22	1,99
LCOE [\$ / kWh]	0,1514	0,1898
BNM [\$]	5442,45	6731,42
Toplan Maliyet [\$]	61270	75780

Çizelge 5.5'teki sonuçlar incelendiğinde, Niğde'ye kurulacak optimum hibrit sistemin 19 PV panel ve 24 batarya kullanılarak gerçekleştirilebileceği ve saatlik enerji maliyetinin yaklaşık 0,15 \$ olduğu görülmektedir, Bozcaada'da ise optimum sistem 64 batarya ve 17 PV panel ile sağlanırken, saatlik enerji maliyetinin yaklaşık 0,19 \$ olduğu görülmektedir, Sonuç olarak fotovoltaik panel ve bataryalar ile Niğde bölgesine kurulacak bir hibrit sistemin Bozcaada'ya kıyasla daha uygun maliyetle çalıştığı ve daha düşük LPSP değerine sahip olduğu söylenebilir.

Çizelge 5.6'de, Niğde ve Bozcaada lokasyonları için optimizasyon algoritmaları tarafından modellenen Toplam Güç Üretimi (TGÜ), Toplam Yük Talebi (TYT), Talep Fazlası Elektrik Enerjisi Üretimi (TFEEÜ), Karşılanamayan Elektrik Enerjisi Miktarı (KEEM) verilerini göstermektedir.


Çizelge 5.6. PV/batarya sisteminin elektrik enerjisi değerleri

PV Panel (PV)/Batarya					
No	Lokasyon	TGÜ (kWh/yıl)	TYT (kWh/ yıl)	TFEEÜ (kWh/yıl)	KEEM (kWh/yıl)
1	Niğde	35939,71	11255,87	18917,15	18,33
2	Bozcaada	35466,27	11255,87	18605,68	116,05


5.3 Güneş Enerjisi, Rüzgar Enerjisi ve Batarya Hibrit Sistem Boyutlandırması

5.3.1 Niğde lokasyonu için güneş enerjisi, rüzgar enerjisi ve batarya hibrit sistem boyutlandırması


Verilen yük talebine ve tekno-ekonomik göstergeler ile önerilen deterministik algoritma, genetik algoritma ve yapay arı kolonisi algoritması sonuçlarına göre, Niğde ili için oluşturulan optimal Güneş/rüzgar/batarya hibrit güç üretim sistemi, 18 adet panel, 1 adet rüzgar türbini ve 23 birim bataryadan oluşmakta olup, şekil 5.30, şekil 5.31 ve şekil 5.32'de, PV paneller tarafından üretilen güç, rüzgar türbini tarafından güç, pil gücü (SOC şarj durumu) ve fazla elektrik üretimi değerleri verilmiştir. Niğde ili için fotovoltaik panellerde bir yıl boyunca üretilen elektrik enerjisi miktarı 34048 kWh, rüzgar türbini için ise 1221 kWh olup rüzgar türbininden elektrik enerjisi üretimi rüzgar hızlarının yüksek olduğu kış mevsiminde fazla olmaktadır. Optimizasyon algoritmaları tarafından bulunan optimum sistem 0,0154 Güç Tedariki Kaybı Olasılığı değerine sahip olup, bir değere getirilmiş elektrik enerjisi üretim maliyeti 0,1599 \$/kWh olarak hesaplanmıştır.




Şekil 5.30. Niğde'de fotovoltaik paneller tarafından bir yıl boyunca üretilen güç



Şekil 5.31. Niğde'de rüzgar türbini tarafından bir yıl boyunca üretilen güç

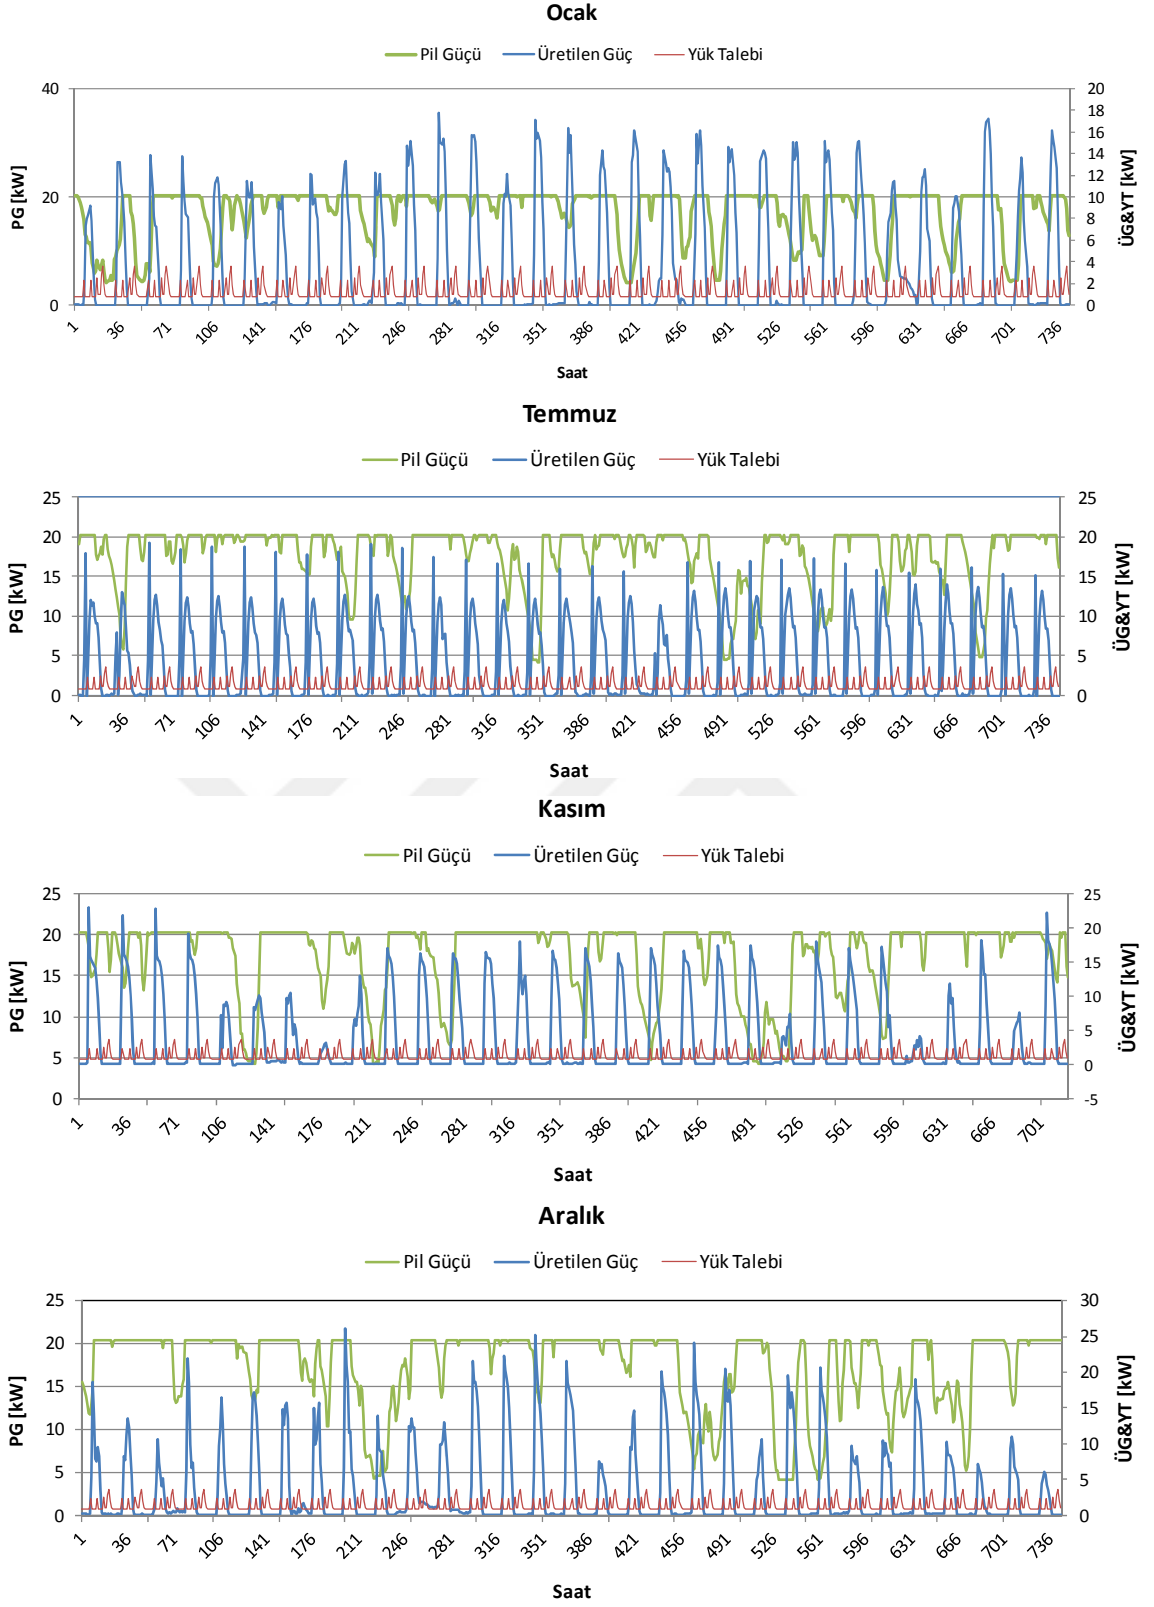


Şekil 5.32. Niğde lokasyonu için kullanılan bataryaların saatlik şarj durumu




Şekil 5.33. Niğde’de talep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi

Şekil 5.34’de Niğde lokasyonunda üretilen güç, pil gücü ve yük talebi verileri ocak, temmuz, kasım, aralık gibi karakteristik aylar için sunulmuştur. Ocak ayında fotovoltaik paneller ve rüzgar türbini tarafından üretilen elektrik enerjisi miktarı 2620 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1262 kWh olarak hesaplanmıştır. Güneş radyasyonu ve rüzgar hızlarının fazla olduğu temmuz ayında ise, fotovoltaik panellerde üretilen elektrik enerjisi miktarı 3321 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1811 kWh olarak hesaplanmıştır.




Şekil 5.34. Niğde için farklı aylarda üretilen güç, batarya ve yük talebi değerleri

Şekil 5.35 Niğde lokasyonu için, fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam aylık güç değerini ve toplam yük talebini göstermektedir. Elde edilen optimal sistem için, Niğde lokasyonunda aralık ayı elektrik enerjisi üretim miktarı 2500 kWh iken, ekim ayında bu değer 3400 kWh olmuştur.




Şekil 5.35. Niğde'de üretilen elektrik ve yük talebinin toplam aylık değerleri

Şekil 5.36'de, fotovoltaik paneller ve rüzgar türbini tarafından üretilen güç miktarını gösterilmektedir. Fotovoltaik paneller ve rüzgar türbini arasında üretilen güç değerleri karşılaştırıldığında, önerilen bu sistemde toplam üretilen elektrik enerjisinin miktarının % 93'ünden fazlasının fotovoltaik paneller tarafından üretildiği görülmektedir.




Şekil 5.36. Niğde'de PV panel ve rüzgar türbini tarafından üretilen toplam aylık güç değerleri

Şekil 5.37’de Niğde lokasyonu için, oluşturulan optimal sistemde kullanılan bataryaların ortalama aylık şarj durumu görülmektedir. Şekilden de görüldüğü gibi, haziran ve temmuz aylarında pil gücünün daha az kullanıldığı, pil gücü kullanımının kasım ve aralık aylarında arttığı görülmektedir.




Şekil 5.37. Niğde lokasyonu için kullanılan bataryaların ortalama aylık şarj durumu

Şekil 5.38’de Niğde lokasyonu için oluşturulan optimal PV/rüzgar türbini/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları görülmektedir. Bu değer aylık bazda değerlendirildiğinde, şekil 5.38’den görüldüğü gibi talep fazlası elektrik enerjisi üretiminin 1210 kWh ile 1925 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi üretimi, güneş radyasyonu değerinin fazla olduğu haziran ve ekim aylarında maksimum iken aralık ayında minimum olmuştur.




Şekil 5.38. Niğde’de aylık toplam aşırı güç değerleri

Şekil 5.39, Niğde lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını aylık bazda göstermektedir. Karşılanamayan elektrik enerjisi miktarı 0 kWh ile 19 kWh arasında değişmektedir. Şekil 5.39'dan yük talebine göre karşılanamayan elektrik enerjisi miktarının maksimum değerinin kasım ayında olduğu görülmektedir.



Şekil 5.39. Niğde'de karşılanmamış toplam aylık güç değerleri


Şekil 5.40, Niğde lokasyonu için fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam güç değerlerini mevsimsel bazda göstermektedir. Yaz mevsimi için fotovoltaik paneller ve rüzgar türbini tarafından üretilen elektrik enerjisi miktarı 9351 kWh iken, kış mevsimi için bu değer 8363 kWh olmuştur.



Şekil 5.40. Niğde'de üretilen toplam güç ve yük talebinin mevsimsel değişimi


Şekil 5.41'de, fotovoltaik paneller ve rüzgar türbini tarafından üretilen güç miktarları mevsimsel olarak gösterilmektedir. Yaz mevsiminde elektrik enerjisi üretim miktarı fotovoltaik panellerden 9103 kWh ve rüzgar türbinlerinden 248 kWh iken, kış

mevsiminde bu değerler 7903 kWh fotovoltaik, 459 kWh rüzgar türbininden elde edilen güç olmuştur.




Şekil 5.41. Niğde'de fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam mevsimsel güç değerleri

Niğde lokasyonunda farklı mevsimler için elde edilen optimal sistemde kullanılan bataryaların şarj durumu şekil 5.42'de verilmiştir. Sonbahar ve kış mevsimlerinde elektrik enerjisi üretimi miktarı azaldığı için bataryaların doluluk oranı düşmektedir.




Şekil 5.42. Niğde lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu

Şekil 5.43'te Niğde lokasyonu için oluşturulan optimal PV/rüzgar türbini/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları mevsimsel bazda görülmektedir. Şekil 5.43'ten görüldüğü gibi, talep fazlası elektrik enerjisi üretiminin 4265 kWh ile 5000 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi üretimi, güneş radyasyonu değerinin ve rüzgar hızı değerlerinin fazla olduğu yaz mevsiminde maksimum iken kış mevsiminde minimum olmuştur.



Şekil 5.43. Niğde'de mevsimsel talep fazlası elektrik enerjisi üretimi

Şekil 5.44, Niğde lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını mevsimsel bazda göstermektedir. Yaz mevsiminde karşılanmayan güç mevcut değildir, ancak sonbahar mevsiminde karşılanmayan güç değeri 28 kWh olmuştur.




Şekil 5.44. Niğde'de karşılanmayan gücün toplam mevsimsel değerleri


5.3.2 Bozcaada lokasyonu için güneş enerjisi, rüzgar enerjisi ve batarya hibrit sistem boyutlandırması

Verilen yük talebine ve tekno-ekonomik göstergeler ile önerilen deterministik algoritma, genetik algoritma ve yapay arı kolonisi algoritması sonuçlarına göre, Bozcaada için oluşturulan optimal güneş/rüzgar/batarya hibrit güç üretim sistemi, 2 adet panel, 3 adet rüzgar türbini ve 14 birim bataryadan oluşmakta olup, şekil 5.45, şekil 5.46, şekil 5.47 ve şekil 5.48'de, fotovoltaik paneller tarafından üretilen güç, rüzgar türbini tarafından güç, batarya gücü ve fazla elektrik üretimi değerleri verilmiştir.


Bozcaada için fotovoltaik panellerde bir yıl boyunca üretilen elektrik enerjisi miktarı 4173 kWh, rüzgar türbini için ise 28615 kWh olup rüzgar türbinlerinden üretilen elektrik enerjisi rüzgar hızlarının azaldığı yaz mevsiminde daha az olurken kış ve sonbahar mevsiminde artmaktadır. Optimizasyon algoritmaları tarafından bulunan optimum sistem 0,0195 Güç Tedariki Kaybı Olasılığı değerine sahip olup, bir değere getirilmiş elektrik enerjisi üretim maliyeti 0,0872 \$/kWh olarak hesaplanmıştır.




Şekil 5.45. Bozcaada'da PV paneli tarafından bir yıl boyunca üretilen güç



Şekil 5.46. Bozcaada'da rüzgar türbini tarafından bir yıl boyunca üretilen güç



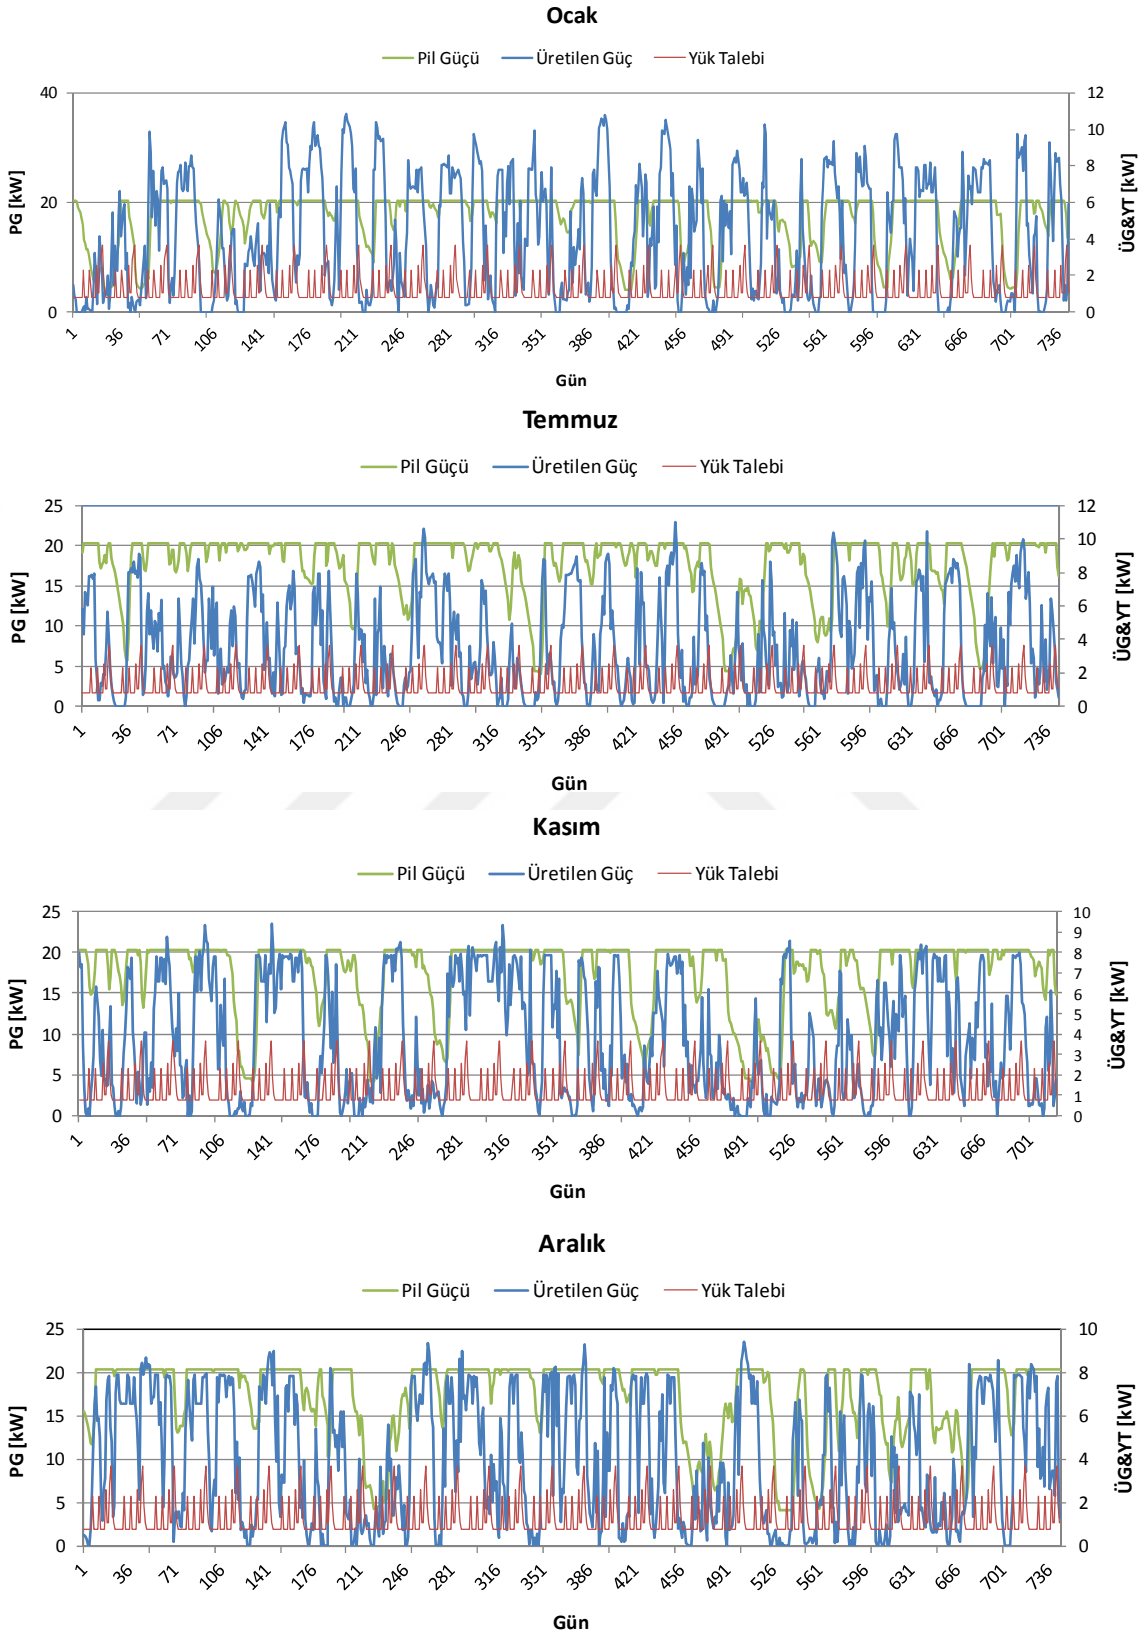
Şekil 5.47. Bozcaada lokasyonu için kullanılan bataryaların saatlik şarj durumu



Şekil 5.48. Bozcaada lokasyonu için talep fazlası üretilen elektrik enerjisi miktarının saatlik değişimi


Şekil 5.49’de Bozcaada lokasyonunda üretilen güç, batarya gücü ve yük talebi verileri ocak, temmuz, kasım, aralık gibi karakteristik aylar için sunulmuştur. Ocak ayında fotovoltaik paneller ve rüzgar türbini tarafından üretilen elektrik enerjisi miktarı 3132 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1706 kWh olarak hesaplanmıştır. Güneş radyasyonu ve rüzgar hızlarının fazla olduğu temmuz ayında ise, fotovoltaik panellerden ve rüzgar türbini tarafından üretilen elektrik enerjisi miktarı

2608 kWh olup, bu ay için fazla elektrik enerjisi üretim değeri 1283 kWh olarak hesaplanmıştır.




Şekil 5.49. Bozcaada için farklı aylarda üretilen güç, batarya ve yük talebi değerleri

Şekil 5.50 Bozcaada lokasyonu için, fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam aylık güç değerini ve toplam yük talebini göstermektedir. Elde edilen optimal sistem için, Bozcaada lokasyonunda haziran ayı elektrik enerjisi üretim miktarı 2063 kWh iken, şubat ayında bu değer 3273 kWh olmuştur.




Şekil 5.50. Bozcaada'da üretilen elektrik ve yük talebinin toplam aylık değerleri

Şekil 5.51'de, fotovoltaik paneller ve rüzgar türbini tarafından üretilen güç miktarını gösterilmektedir. Fotovoltaik paneller ve rüzgar türbini arasında üretilen güç değerleri karşılaştırıldığında, önerilen bu sistemde toplam üretilen elektrik enerjisinin miktarının % 80'den fazlasının rüzgar türbinleri tarafından üretildiği görülmektedir.




Şekil 5.51. Bozcaada'da fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam aylık güç değerleri

Şekil 5.52’de Bozcaada lokasyonu için, oluşturulan optimal sistemde kullanılan bataryaların ortalama aylık şarj durumu görülmektedir. Şekilden de görüldüğü gibi, Mayıs ve Haziran aylarında pil gücünün daha fazla kullanıldığı, batarya gücü kullanımının şubat ve ekim aylarında arttığı görülmektedir.




Şekil 5.52. Bozcaada lokasyonu için kullanılan bataryaların ortalama aylık şarj durumu

Şekil 5.53’de Bozcaada lokasyonu için oluşturulan optimal PV/rüzgar türbini/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları görülmektedir. Bu değer aylık bazda değerlendirildiğinde, şekil 5.53’ten görüldüğü gibi talep fazlası elektrik enerjisi üretiminin 825 kWh ile 1900 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi üretimi, rüzgar hızı değerinin fazla olduğu ocak ve şubat aylarında en fazla iken haziran ayında minimum olmuştur.




Şekil 5.53. Bozcaada'da aylık toplam aşırı güç değerleri

Şekil 5.54, Bozcaada lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını aylık bazda göstermektedir. Karşılanamayan elektrik enerjisi miktarı 0 kWh ile 25 kWh arasında değişmektedir. Şekil 5.54'ten yük talebine göre karşılanamayan elektrik enerjisi miktarının maksimum değerinin mayıs ayında olduğu görülmektedir.



Şekil 5.54. Bozcaada'da karşılanmamış toplam aylık güç değerleri


Şekil 5.55, Bozcaada lokasyonu için fotovoltaik paneller ve rüzgar türbini tarafından üretilen toplam güç değerlerini mevsimsel bazda göstermektedir. Yaz mevsimi için fotovoltaik paneller ve rüzgar türbini tarafından üretilen elektrik enerjisi miktarı 6845 kWh iken, ilkbahar mevsimi için bu değer 9657 kWh olmuştur.



Şekil 5.55. Bozcaada'da üretilen toplam güç ve yük talebinin mevsimsel değişimi


Şekil 5.56'de, fotovoltaik paneller ve rüzgar türbini tarafından üretilen güç miktarları mevsimsel olarak gösterilmektedir. Yaz mevsiminde elektrik enerjisi üretim miktarı fotovoltaik panellerden 1162 kWh ve rüzgar türbinlerinden 5683 kW iken, kış

mevsiminde bu değerler 634 kWh fotovoltaik, 8178 kWh rüzgar türbininden elde edilen güç olmuştur.



Şekil 5.56. Bozcaada'da PV panel ve rüzgar türbini tarafından üretilen toplam mevsimsel güç değerleri


Bozcaada lokasyonunda farklı mevsimler için elde edilen optimal sistemde kullanılan bataryaların şarj durumu şekil 5.57'de verilmiştir. Şekilde gösterildiği gibi, batarya gücünün maksimum kullanımı yaz sezonunda gerçekleşirken, diğer mevsimlerde pil gücü minimum düzeyde kullanılmaktadır.



Şekil 5.57. Bozcaada lokasyonu için kullanılan bataryaların ortalama mevsimsel şarj durumu


Şekil 5.58'de Bozcaada lokasyonu için oluşturulan optimal PV/rüzgar türbini/batarya sisteminde talep dışında üretilen fazla elektrik enerjisi miktarları mevsimsel bazda görülmektedir. Şekil 5.58'den görüldüğü gibi talep fazlası elektrik enerjisi üretiminin 3085 kWh ile 5420 kWh arasında değiştiği söylenebilir. Talep fazlası elektrik enerjisi

üretimi, rüzgar hızı değerlerinin fazla olduğu kış mevsiminde maksimum iken yaz mevsiminde minimum olmuştur.



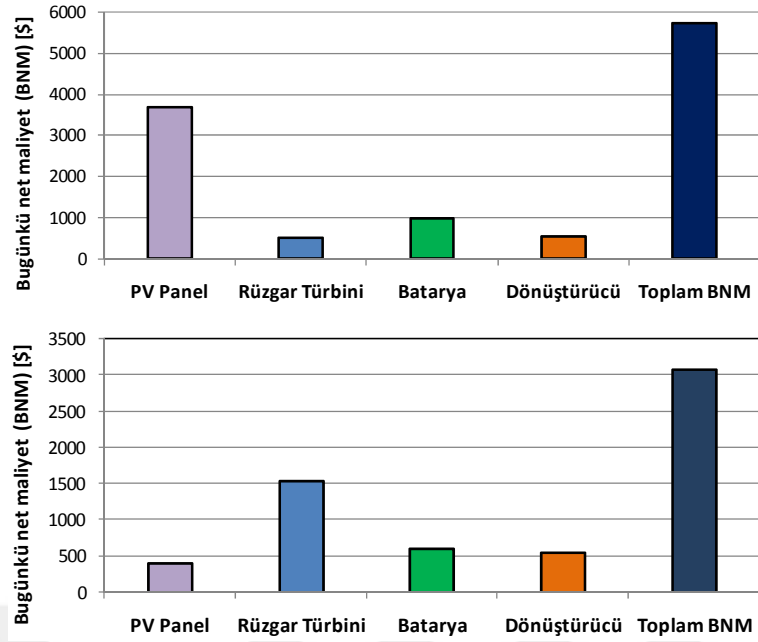
Şekil 5.58. Bozcaada'da mevsimsel talep fazlası elektrik enerjisi üretimi

Şekil 5.59, Bozcaada lokasyonu için belirlenen optimal tasarım için karşılanamayan elektrik enerjisi miktarını mevsimsel bazda göstermektedir. Yaz sezonunda fotovoltaik panellerden güç üretimi küçüktür ve karşılanmamış güç mevcuttur, diğer mevsimlerde bu değer daha düşük olmaktadır.



Şekil 5.59. Bozcaada'da karşılanamayan gücün toplam mevsimsel değerleri

Şekil 5.60'te, optimizasyon algoritmaları tarafından bulunan optimal sisteme ait toplam sistem maliyetinin şimdiki değeri gösterilmektedir. Şekil 5.60 incelendiğinde, Niğde lokasyonu için önerilen sistemin BNM değerinin Bozcaada'ya kıyasla 2356.54\$ daha düşük olduğu görülmektedir.



Şekil 5.60. Niğde ve Bozcaada için PV/rüzgar türbini/batarya sisteminin BNM değerleri

Çizelge 5.7’de göz önünde bulundurulmuş lokasyonlar için elde edilen optimal PV/batarya sistemlerine ait simülasyon sonuçları görülmektedir.

Çizelge 5.7. PV/rüzgar türbini/batarya sisteminin kullanılan algoritmalarla göre optimal sonuçları

PV Panel (PV)/Rüzgar Türbini (RT)/Batarya		
Lokasyon	Niğde	Bozcaada
PV Sayısı	18	2
RT Sayısı	1	3
Batarya Sayısı	23	14
LPSP [%]	1,54	1,952
LCOE [\$ / kWh]	0,1599	0,0872
BNM [\$]	5706,47	3077,18
Toplan Maliyet [\$]	64242	34642,18

Çizelge 5.7’deki sonuçlar incelendiğinde, Niğde’ye kurulacak optimum hibrit sistemin 18 PV panel, 1 Rüzgar Türbini ve 23 batarya kullanılarak gerçekleştirilebileceği ve saatlik enerji maliyetinin yaklaşık 0,16 \$ olduğu görülmektedir. Bozcaada’da ise optimum sistem 2 PV panel, 3 Rüzgar Türbini ve 14 batarya ile sağlanırken, saatlik

enerji maliyetinin yaklaşık 0,087 \$ olduğu görülmektedir. Sonuç olarak maliyetler ve sistem bileşenleri dikkate alındığında Bozcaada bölgesine kurulacak bir hibrit sistemin Niğde bölgesine kıyasla daha uygun maliyete çalıştığı görülmektedir.

Çizelge 5.8’de, Niğde ve Bozcaada bölgeleri için optimizasyon algoritmaları tarafından modellenen Toplam Güç Üretimi (TGÜ), Toplam Yük Talebi (TYT), Talep Fazlası Elektrik Enerjisi Üretimi (TFEEÜ), Karşılanamayan Elektrik Enerjisi Miktarı (KEEM)verilerini göstermektedir.

Çizelge 5.8. PV/rüzgar türbini/batarya sisteminin elektrik enerjisi değerleri

PV Panel (PV)/Rüzgar Türbini (RT)/Batarya					
No	Lokasyon	TGÜ (kWh/yıl)	TYT (kWh/ yıl)	TFEEÜ (kWh/yıl)	KEEM (kWh/yıl)
1	Niğde	35490	11255,87	18424,58	43,86
2	Bozcaada	32787	11255,87	16755,68	104,73

Çizelge 5.9’de bu çalışmada optimum sistem tasarımında kullanılan algoritmaların işlem zaman performans kıyaslaması verilmiştir. Sonuçlar incelendiğinde, önerilen deterministik algoritmanın diğer optimizasyon algoritmalarına göre çok daha uzun sürede çalıştığı görülmektedir.

Çizelge 5.9. Algoritmaların işlem zamanı performans kıyaslaması

Lokasyon	Algoritma	Pv/Batarya	Pv/Batarya/Rüzgar
Niğde	ABC	1,08dk	2dk
	GA	9,53dk	23,83dk
	Deterministik	10dk	493dk
Bozcaada	ABC	24saniye	20,88dk
	GA	4,83dk	16,46dk
	Deterministik	10dk	504dk

Bu durumun sebebi, deterministik algoritmanın ızgara tabanlı bir arama yöntemi uygulaması ve üzerine sıralama algoritması kullanmasıdır. GA ve ABC algoritmaları arasında ABC algoritması işlem zamanı performansı olarak GA’dan daha iyi çalıştığı

görülmektedir. Sadece Bozcaada lokasyonunda ve güneş/rüzgar/batarya sistemi için ABC algoritmasının daha geç sonuç üretebildiği gözlemlenmiştir. Bu durumun muhtemel sebebi ise Bozcaada lokasyonunun rüzgar açısından daha iyi bir potansiyele sahip olması ve bu nedenle ABC algoritmasının tüm kombinasyonlar arasından seçimler yapmaya çalışmasıdır.

Çizelge 5.10'da pv/batarya ile kurulan sistemde keşfedilen en optimum 10 konfigürasyon verilmiştir. Çizelge 5.10'daki sonuçlar incelendiği zaman, Niğde lokasyonunda bulunan en iyi sonucun 19 fotovoltaik panel ve 24 batarya ile kurulduğu ve bir değere getirilmiş elektrik enerjisi üretim maliyeti değerinin 0,1514 \$/kWh olduğu görülmektedir. Bu kombinasyonu, yakın değerlere sahip diğer kombinasyonlar takip etmektedir. Diğer kombinasyonların da bir değere getirilmiş elektrik enerjisi üretim maliyeti değerleri en iyi sonuca oldukça yakın olarak gözlemlenmektedir. Bozcaada lokasyonu için ise, 17 fotovoltaik panel ve 64 bataryadan oluşan sistemin bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,1898 \$/kWh değeri ile en iyi sonuca sahip olduğu görülmektedir. Bozcaada için en iyi on kombinasyonda fotovoltaik panel sayısı değişmezken batarya sayısında küçük değişiklikler gözlemlenmektedir.

Çizelge 5.10. Pv/Batarya ile kurulan sistemde keşfedilen en optimum 10 konfigürasyon

En iyi 10 sonuç	Niğde			Bozcaada		
	Panel Sayısı	Batarya Sayısı	LCOE	Panel Sayısı	Batarya Sayısı	LCOE
1	19	24	0,151433	17	64	0.189797
2	19	25	0,152614	17	65	0.190994
3	19	26	0,153794	17	66	0.192191
4	18	24	0,153845	17	67	0.193387
5	19	27	0,154975	17	68	0.194584
6	18	25	0,155092	17	69	0.195780
7	19	28	0,156156	17	70	0.196977
8	18	26	0,156338	17	71	0.198174
9	17	24	0,156542	17	72	0.199370
10	19	29	0,157337	17	73	0.200567

Çizelge 5.11’da pv/rüzgar türbini/batarya ile kurulan sistemde keşfedilen en optimum 10 konfigürasyon listelenmiştir. Çizelge 5.11’deki sonuçlar incelendiği zaman, Niğde lokasyonunda en iyi sonucun 18 fotovoltaik panel, 1 rüzgar türbini ve 23 batarya ile oluştuğu görülmektedir. Bu kombinasyonun bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,1599 \$/kWh olarak hesaplanmıştır. Diğer sonuçlarda da benzer şekilde rüzgar türbini sabit kalırken, fotovoltaik panel sayısı ve batarya sayısında küçük değişiklikler gözlemlenmektedir. Bozcaada lokasyonu için ise en iyi sonucun 2 fotovoltaik panel, 3 rüzgar türbini ve 14 batarya ile oluşturulduğu görülmektedir. Bu kombinasyonun bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,0872 \$/kWh olarak hesaplanmıştır. Bozcaada için diğer sonuçlar incelendiği zaman, rüzgar türbini sabit kalırken fotovoltaik panel ve batarya sayılarında küçük değişiklikler gözlemlenmiştir. Her iki lokasyon karşılaştırıldığı zaman, Bozcaada lokasyonuna eklenen rüzgar türbinlerinin bir değere getirilmiş elektrik enerjisi üretim maliyeti değerini oldukça düşürdüğü ve PV panel ve batarya sayısını da azalttığı gözlemlenmiştir.

Çizelge 5.11. PV/Batarya/Rüzgar Türbini ile kurulan sistemde keşfedilen en optimum 10 konfigürasyon

En iyi 10 sonuç	Niğde				Bozcaada			
	Panel Sayısı	Rüzgar Türbin Seçimi	Batarya Sayısı	LCOE	Panel Sayısı	Rüzgar Türbin Seçimi	Batarya Sayısı	LCOE
1	18	1	23	0,159908	2	3	14	0,087149
2	18	1	24	0,161111	3	3	13	0,087758
3	18	1	25	0,162314	3	3	14	0,088366
4	17	1	23	0,162849	2	3	15	0,089052
5	18	1	26	0,163517	3	3	15	0,089583
6	17	1	24	0,16412	2	3	16	0,090346
7	18	1	27	0,164721	3	3	16	0,0908
8	17	1	25	0,165392	2	3	17	0,091641
9	18	1	28	0,165924	3	3	17	0,092017
10	16	1	23	0,166143	1	3	18	0,092596

BÖLÜM VI

SONUÇLAR VE TARTIŞMA

Bu çalışmada, öncelikle Türkiye’deki çeşitli lokasyonlar için meteorolojik ölçüm istasyonlarından alınan rüzgar hızı ve güneş radyasyonu gibi meteorolojik veriler kullanarak çeşitli makine öğrenmesi metotlarıyla rüzgar ve güneş gücü için kısa ve uzun dönem tahminleri yapılmış, daha sonra belirli bir yük talebi oluşturularak yine Türkiye’de ki farklı noktalarda kurulacağı düşünülen yenilenebilir enerji güç üretim sistemlerinin optimal boyutlarının belirlenmesi, Güç Tedariki Kaybı Olasılığı güvenilirlik göstergesi ile minimum bir değere getirilmiş maliyet değeri göz önünde bulundurularak zaman serisi analizi metoduyla deterministik bir yaklaşımla ve ayrıca yapay zeka yöntemleri kullanılarak yapılmıştır.

Rüzgar ve güneş gücü tahmini işleminde, 5 farklı lokasyondan elde edilen 5 yıl boyunca ölçülmüş olan saatlik meteoroloji verilerinden rüzgar hızı verisi rüzgar güç tahmini için, güneş radyasyonu ve ortam sıcaklığı verileri güneş güç tahmini için kullanılmıştır. Rüzgar güç tahmini için saatlik rüzgar hızı verileri, günlük ortalama rüzgar hızı ve günlük standart sapma hazırlamak için kullanılmıştır. Güneş güç tahmini için ise saatlik güneş radyasyonu ve ortam sıcaklığı verileri günlük ortalamalar haline getirilmiştir.

Rüzgar ve güneş enerjisi güç tahmini için makine öğrenmesi algoritmalarından LASSO, kNN, xGBoost, Rastgele Orman ve SVR regresyon algoritmaları kullanılmıştır. Bu algoritmalara 4 yıllık günlük ortalama değerler eğitim amacıyla verilmiş ve algoritmaların regresyon modelleri üretmesi sağlanmıştır. Son yıldaki günlük ortalama değerler kullanılarak üretilen regresyon modellerinin performansları analiz edilmiş ve rüzgar ve güneş enerjisi güç tahmini için kullanılabilirlikleri incelenmiştir.

Makine öğrenmesi algoritmalarından elde edilen sonuçlar incelendiği zaman, regresyon modellerinin rüzgar ve güneş enerjisi güç tahmini için oldukça başarılı oldukları gözlemlenmiştir. Rüzgar enerjisi tahminde LASSO algoritmasının en düşük performansı gösterdiği, kNN ve xGBoost algoritmalarının LASSO algoritmasına göre daha iyi oldukları ve Rastgele Orman ve SVR algoritmalarının en başarılı sonuçları ürettiği görülmüştür. Algoritmalar arasındaki performans farkı, regresyon modelinin

oluşturulmasındaki farklarından kaynaklanmaktadır. Ayrıca, rüzgar hızının değişkenlikler içermesi ve tam anlamıyla tahmin edilemez olması algoritmaların başarımlarını etkilemektedir. Güneş enerjisi tahmininde tüm regresyon algoritmalarının yüksek performans gösterdiği görülmüştür. Bunun sebebi ise güneş güç üretiminin güneş radyasyonu ve ortam sıcaklığına göre doğrusal olarak modellenebilmesidir.

Rüzgar ve güneş enerjisi güç üretim tahmini sonuçları karşılıklı incelendiği zaman, algoritmaların rüzgar güç üretimi için ürettikleri tahminlerin güneş güç üretimi için ürettikleri tahminlerden daha düşük kaldığı gözlemlenmiştir. Ayrıca, farklı lokasyonlara göre algoritmaların başarımları da değişkenlik göstermektedir. Bunun sebebi ise, farklı lokasyonlardaki meteorolojik parametrelerin değişkenlik göstermesidir.

Bu tez çalışması kapsamında geliştirilen rüzgar ve güneş enerjisi güç tahmini için kullanılan makine öğrenmesi modellerinin çok yüksek performansa sahip oldukları ve gerçek değerlere oldukça yakın sonuçlar üretebildikleri görülmüştür. Bu kapsamda, rüzgar ve güneş enerjisi güç tahmini için bu tez çalışmasında kullanılan algoritmaların uygun oldukları ve başarılı çalıştıkları ifade edilebilir.

Ayrıca bu çalışmada, gözönünde bulundurulmuş yük talebi ve tekno-ekonomik göstergelere göre Niğde ve Bozcaada lokasyonlarında kurulması düşünülen pv/batarya ve pv/rüzgar türbini/batarya hibrit yenilenebilir enerji güç sistemlerinin optimal boyutlandırılması Deterministik Algoritma (DA), Genetik Algoritma (GA) ve Yapay Arı Kolonisi (ABC) algoritması kullanılarak yapılmıştır. Kullanılan algoritma sonuçlarına göre, Niğde lokasyonu için bulunan en iyi sonuç 19 fotovoltaik panel ve 24 batarya ile oluşturulan sistemden elde edilmiş ve bu sistem için bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,1514 \$/kWh olarak hesaplanmıştır. Oluşturulan optimum sistemin yıllık elektrik enerjisi üretimi değeri 35939,71 kWh/yıl olarak hesaplanmıştır. Bozcaada lokasyonu için ise, fotovoltaik panel/batarya ile elde edilen optimum sistem 17 fotovoltaik panel ve 64 bataryadan oluşmuş, bu sistemin bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,1898 \$/kWh olarak hesaplanmıştır. Bozcaada lokasyonu için oluşturulan optimum sistemin yıllık elektrik enerjisi üretim değeri 35466,27 kWh/yıl olarak hesaplanmıştır. Aynı algoritmalar kullanılarak oluşturulan optimal pv/rüzgar türbini/bataryahibrit yenilenebilir enerji güç sistemi Niğde lokasyonu için 18 fotovoltaik panel, 1 rüzgar türbini ve 23 bataryadan meydana

gelmiştir. Bu kombinasyon için bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,1599 \$/kWh olarak hesaplanmıştır. Oluşturulan optimum sistemin yıllık elektrik enerjisi üretimi değeri 35490,21 kWh/yıl olarak hesaplanmıştır. Bozcaada lokasyonu için ise optimum sistem, 2 fotovoltaik panel, 3 rüzgar türbini ve 14 bataryadan oluşmuştur. Bozcaada lokasyonu için oluşturulan optimum sistemin yıllık elektrik enerjisi üretim değeri 32787,04 kWh/yıl olarak hesaplanmıştır. Bu kombinasyonun bir değere getirilmiş elektrik enerjisi üretim maliyeti değeri 0,0872 \$/kWh olarak hesaplanmıştır. Bu sistem için her iki lokasyon karşılaştırıldığı zaman, Bozcaada lokasyonuna eklenen rüzgar türbinlerinin bir değere getirilmiş elektrik enerjisi üretim maliyeti değerini oldukça düşürdüğü ve PV panel ve batarya sayısını da azalttığı gözlemlenmiştir.

Bu tez çalışmasında gerçekleştirilen güç tahmini algoritmaları farklı veri setleri kullanılarak potansiyel farklı lokasyonlar için bir tahmin metodu olarak kullanılabilir. Diğer taraftan, optimum hibrit güç üretim sisteminin boyutlandırılması ile ilgili önerilen algoritmalar ise hidrojen üretimi, deniz suyu arıtımı, elektrikli araç şarj istasyonları gibi enerji ihtiyacı duyulan sistemler için hibrit yenilenebilir enerji güç üretim sistemlerinin tasarımı aşamalarında bir araç olarak kullanılabilir.

KAYNAKLAR

Abdin, Z., Zafaranloo, A., Rafiee, A., Mérida, W., Lipiński, W. and Khalilpour, K. R. "Hydrogen as an energy vector", *Renewable and Sustainable Energy Reviews* 120, 109620, 2020.

Ahmadi, S., and Abdi, S. "Application of the Hybrid Big Bang-Big Crunch algorithm for optimal sizing of a stand-alone hybrid PV/wind/battery system", *Solar Energy* 134, 366-374, 2016.

Al-falahi, M. D. A., Jayasinghe, S. D. G., and Enshaei, H. "A review on recent size optimization methodologies for standalone solar and wind hybrid renewable energy system", *Energy Conversion and Management* 143, 252-274, 2017.

Al-Sharafi, A., Sahin, A. Z., Ayar, T., and Yilbas, B. S. "Techno-economic analysis and optimization of solar and wind energy systems for power generation and hydrogen production in Saudi Arabia", *Renewable and Sustainable Energy Reviews* 69, 33-49, 2017.

Abdelaziz, A. Y., Rahman, M. A., El-Khayat, M. M., Hakim, M. A. "Short Term Wind Power Forecasting Using Autoregressive Integrated Moving Average Modeling", *15th International Middle East Power Systems Conference (MEPCON'12)*, Alexandria, Egypt, 23-25 December, 2012.

Alpaydin, E., Introduction to Machine Learning, 2nd Edition, *In The MIT Press*, London, England, 2010.

Amutha, W. M., and Rajini, V. "Cost benefit and technical analysis of rural electrification alternatives in southern India using HOMER", *Renewable and Sustainable Energy Reviews* 62, 236-246, 2016.

Andreopoulou, Z., Koliouka, C., Galariotis, E., and Zopounidis, C. "Renewable energy sources: Using PROMETHEE II for ranking websites to support market opportunities", *Technological Forecasting and Social Change* 131, 31-37, 2018.

Anoune, K., Bouya, M., Astito, A., and Abdellah, A. B. "Sizing methods and optimization techniques for PV-wind based hybrid renewable energy system: A review", *Renewable and Sustainable Energy Reviews* 93, 652-673, 2018.

Dokuz A.S., Demolli, H., Gökçek M, and Ecemiş A. "Year-ahead wind speed forecasting using a clustering-statistical hybrid method", *International Conference on Innovative Engineering Applications*, Sivas, Turkey 971–975, 20-22 September, 2018.

Baneshi, M., and Hadianfard, F. "Techno-economic feasibility of hybrid diesel/PV/wind/battery electricity generation systems for non-residential large electricity consumers under southern Iran climate conditions", *Energy Conversion and Management* 127, 233-244, 2018.

Barbounis, T. G., Theocharis, J. B., Alexiadis, M. C., and Dokopoulos, P. S. "Long-term wind speed and power forecasting using local recurrent neural network models", *IEEE Transactions on Energy Conversion* 21(1), 273-284, 2006.

Breiman, L. "Random forests" Machine Learning, *Kluwer Academic Publishers* 45, 5-32, 2001.

Cadenas, E., Rivera, W., Campos-Amezcu, R., and Heard, C. "Wind speed prediction using a univariate ARIMA model and a multivariate NARX model", *Energies* 9(2), 1-15, 2016.

Çavuş, V., and Tuncer, A. "İnsansız Hava Araçları İçin Yapay Arı Kolonisi Algoritması Kullanarak Rota Planlama", *Karaelmas Fen ve Mühendislik Dergisi* 7(1), 259–265, 2017.

Chen, T., and Guestrin, C. "xGBoost: A scalable tree boosting system", *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, CA, USA, 13-17 August, 2016.

Das, B. K., Hoque, N., Mandal, S., Pal, T. K., and Raihan, M. A. "A techno-economic feasibility of a stand-alone hybrid power generation for remote area application in Bangladesh", *Energy* 134, 775-788, 2017.

Dash, V., and Bajpai, P. "Power management control strategy for a stand-alone solar photovoltaic-fuel cell-battery hybrid system", *Sustainable Energy Technologies and Assessments* 9, 68-80, 2015.

Goldberg, D. E. "Genetic algorithms in search, optimization, and machine learning". *In Addison-Wesley Professional*, Boston, USA, 1989.

De Alencar, D. B., De Mattos A., C., De Oliveira, R. C. L., Rodríguez, J. L. M., Leite, J. C., and Filho, J. C. R. "Different Models for Forecasting Wind Power Generation: Case Study", *Energies* 10, 1-27, 2017.

Diaf, S., Notton, G., Belhamel, M., Haddadi, M., and Louche, A. "Design and techno-economical optimization for hybrid PV/wind system under various meteorological conditions", *Applied Energy* 85(10), 968-987, 2008.

Dowell, J., and Pinson, P. "Very-Short-Term Probabilistic Wind Power Forecasts by Sparse Vector Autoregression", *IEEE Transactions on Smart Grid* 7(2), 763-770, 2016.

Drucker, H., Surges, C. J. C., Kaufman, L., Smola, A., and Vapnik, V. "Support vector regression machines", *Advances in Neural Information Processing Systems* 9, 1997.

Duffie, J. A., and Beckman, W. A. "Solar Engineering of Thermal Processes" Fourth Edition, *In Solar Engineering of Thermal Processes*, Hoboken, New Jersey, USA, 2013.

Dumitru, C. D., and Gligor, A. "Daily Average Wind Energy Forecasting Using Artificial Neural Networks", *Procedia Engineering* 181, 829-836, 2017.

Ekström, J., Koivisto, M., Mellin, I., Millar, R. J., and Lehtonen, M. "A statistical modeling methodology for long-term wind generation and power ramp simulations in new generation locations" *Energies*, 11, 1-18, 2018.

Eldali, F. A., Hansen, T. M., Suryanarayanan, S., and Chong, E. K. P. "Employing ARIMA models to improve wind power forecasts: A case study in ERCOT", *NAPS 2016 - 48th North American Power Symposium, Proceedings*, Denver, CO, USA, 18-20, September, 2016.

Eteiba, M. B., Barakat, S., Samy, M. M., and Wahba, W. I. "Optimization of an off-grid PV/Biomass hybrid system with different battery technologies", *Sustainable Cities and Society* 40, 713-727, 2018.

Fathima, A. H., and Palanisamy, K. "Optimization in microgrids with hybrid energy systems - A review", *Renewable and Sustainable Energy Reviews* 45, 431-446, 2015.

Fathy, A. "A reliable methodology based on mine blast optimization algorithm for optimal sizing of hybrid PV-wind-FC system for remote area in Egypt", *Renewable Energy* 95, 367-380, 2016.

Filipović, V. "Fine-grained tournament selection operator in genetic algorithms", *Computing and Informatics* 22, 143-161, 2003.

Frías-Paredes, L., Mallor, F., Gastón-Romeo, M., and León, T. "Assessing energy forecasting inaccuracy by simultaneously considering temporal and absolute errors", *Energy Conversion and Management* 142, 533-546, 2017.

Ghofrani, M., and Hosseini, N. N. "Optimizing Hybrid Renewable Energy Systems: A Review", *In Sustainable Energy - Technological Issues, Applications and Case Studies, INTECH*, 2016.

Gökçek, M., Bayülken, A., and Bekdemir, Ş. "Investigation of wind characteristics and wind energy potential in Kirklareli, Turkey", *Renewable Energy* 32(10), 1739-1752, 2007.

Gökçek, M., and Kale, C. "Optimal design of a Hydrogen Refuelling Station (HRFS) powered by Hybrid Power System", *Energy Conversion and Management* 161, 215-224, 2018.

Guo, S., Liu, Q., Sun, J., and Jin, H. "A review on the utilization of hybrid renewable energy", *Renewable and Sustainable Energy Reviews* 91, 1121-1147, 2018.

Yousif, H. J., and Kazem, A. H. "Modeling of Daily Solar Energy System Prediction using Soft Computing Methods for Oman", *Research Journal of Applied Sciences, Engineering and Technology* 13(3), 237-244, 2016.

Moghaddam, H. M. J., Kalam, A., Nowdeh, S. A., Ahmadi, A., Babanezhad, M., and Saha, S. "Optimal sizing and energy management of stand-alone hybrid photovoltaic/wind system based on hydrogen storage considering LOEE and LOLE reliability indices using flower pollination algorithm", *Renewable Energy* 135, 1412-1434, 2019.

Hafez, O., and Bhattacharya, K. "Optimal planning and design of a renewable energy based supply system for microgrids", *Renewable Energy* 45, 7-15, 2012.

Halabi, L. M., Mekhilef, S., Olatomiwa, L., and Hazelton, J. "Performance analysis of hybrid PV/diesel/battery system using HOMER: A case study Sabah, Malaysia", *Energy Conversion and Management* 144, 322-339, 2017.

Hatata, A. Y., Osman, G., and Aladl, M. M. "An optimization method for sizing a solar/wind/battery hybrid power system based on the artificial immune system", *Sustainable Energy Technologies and Assessments* 27, 83-93, 2018.

Doctors, R., and Kelman, R. "Homer Energy", *HOMER Pro Version 3.7 User Manual*, Colorado, 2016

Hossain, M. R., Oo, A. M. T., and Ali, A. B. M. S. "Hybrid prediction method of solar power using different computational intelligence algorithms", *2012 22nd Australasian Universities Power Engineering Conference: "Green Smart Grid Systems"*, AUPEC 2012, Bali, Indonesia, 26-26 September, 2012.

Hu, C., Jain, G., Zhang, P., Schmidt, C., Gomadam, P., and Gorka, T. "Data-driven method based on particle swarm optimization and k-nearest neighbor regression for estimating capacity of lithium-ion battery" *Applied Energy* 129, 49-55, 2014.

Jamshidi, M., and Askarzadeh, A. "Techno-economic analysis and size optimization of an off-grid hybrid photovoltaic, fuel cell and diesel generator system", *Sustainable Cities and Society* 44, 310-320, 2019.

Jang, J. S. R. "Neuro-Fuzzy and Soft Computing: A Computational Approach To Learning and Machine Intelligence", *In Chapter 7: Derivative-Free Optimization* USA, Prentice-Hall, 173–196, 1997.

Karaboğa, D. "Yapay Zeka Optimizasyon Algoritmaları", *In Yapay Zeka Optimizasyon Algoritmaları*, Turkey, 2018.

Khatri, R. "Design and assessment of solar PV plant for girls hostel (GARGI) of MNIT University, Jaipur city: A case study", *Energy Reports* 2, 89-98, 2016.

Khan, G. M., Ali, J., and Mahmud, S. A. "Wind power forecasting - An application of machine learning in renewable energy", *International Joint Conference on Neural Networks (IJCNN)*, Beijing, China, 06-11 July, 2014.

Khiareddine, A., Salah, B. C., Rekioua, D., and Mimouni, M. F. "Sizing methodology for hybrid photovoltaic /wind/ hydrogen/battery integrated to energy management strategy for pumping system", *Energy* 153, 743-762, 2018.

Khodayar, M. E. "Rural electrification and expansion planning of off-grid microgrids", *Electricity Journal* 30(4), 68-74, 2017.

Lahouar, A., and Slama, B. H. J. "Hour-ahead wind power forecast based on random forests", *Renewable Energy* 109, 529-541, 2017.

Li, C., Lin, S., Xu, F., Liu, D., and Liu, J. "Short-term wind power prediction based on data mining technology and improved support vector machine method: A case study in Northwest China", *Journal of Cleaner Production* 205, 909-922, 2018.

Lian, J., Zhang, Y., Ma, C., Yang, Y., and Chaima, E. "A review on recent sizing methodologies of hybrid renewable energy systems", *Energy Conversion and Management* 199, 2019.

Lima, J. M., Guetter, A. K., Freitas, S. R., Panetta, J., and de Mattos, J. G. Z. "A Meteorological-Statistic Model for Short-Term Wind Power Forecasting", *Journal of Control, Automation and Electrical Systems* 28, 679-691, 2017.

Luna-Rubio, R., Trejo-Perea, M., Vargas-Vázquez, D., and Ríos-Moreno, G. J. "Optimal sizing of renewable hybrids energy systems: A review of methodologies", *Solar Energy* 86(4), 1077-1088, 2012.

Ma, T., and Javed, M. S. "Integrated sizing of hybrid PV-wind-battery system for remote island considering the saturation of each renewable energy resource", *Energy Conversion and Management* 182, 178-190, 2019.

Maleki, A., and Pourfayaz, F. "Optimal sizing of autonomous hybrid photovoltaic/wind/battery power system with LPSP technology by using evolutionary algorithms", *Solar Energy* 115, 471-483, 2015.

Maleki, A., and Pourfayaz, F. "Optimization of grid independent diesel-based hybrid system for power generation using improved particle swarm optimization algorithm", *30th Power System Conference, PSC 2015*, Tehran, Iran, 23-25 November, 2017.

Maleki, A., Pourfayaz, F., Hafeznia, H., and Rosen, M. A. "A novel framework for optimal photovoltaic size and location in remote areas using a hybrid method: A case study of eastern Iran", *Energy Conversion and Management* 153, 129-143, 2017.

Maleki, A., and Rosen, M. A. "Design of a cost-effective on-grid hybrid wind–hydrogen based CHP system using a modified heuristic approach", *International Journal of Hydrogen Energy* 42(25), 15973-15989, 2017.

Maroufpoor, S., Sanikhani, H., Kisi, O., Deo, R. C., and Yaseen, Z. M. "Long-term modelling of wind speeds using six different heuristic artificial intelligence approaches", *International Journal of Climatology* 39(8), 3543-3557, 2019.

Martín, M., and Grossmann, I. E. "Optimal integration of renewable based processes for fuels and power production: Spain case study", *Applied Energy* 213, 595-610, 2018.

Melikoglu, M. "Vision 2023: Feasibility analysis of Turkey's renewable energy projection", *Renewable Energy* 50, 570-575, 2013.

Nafeh, A. E. S. A. "Optimal economical sizing of a PV-wind hybrid energy system using genetic algorithm", *International Journal of Green Energy* 8(1), 25-43, 2011.

Najeebullah, Zameer, A., Khan, A., and Javed, S. G. "Machine Learning based short term wind power prediction using a hybrid learning model", *Computers and Electrical Engineering* 45, 122-133, 2015.

Pareek, A., Dom, R., Gupta, J., Chandran, J., Adepur, V., and Borse, P. H. "Insights into renewable hydrogen energy: Recent advances and prospects", *Materials Science for Energy Technologies* 3, 319-327, 2020.

Pearre, N. S., and Swan, L. G. "Statistical approach for improved wind speed forecasting for wind power production", *Sustainable Energy Technologies and Assessments* 27, 180-191, 2018.

Peng, T., Zhou, J., Zhang, C., and Zheng, Y. "Multi-step ahead wind speed forecasting using a hybrid model based on two-stage decomposition technique and AdaBoost-extreme learning machine", *Energy Conversion and Management* 153, 589-602, 2017.

Qin, Y., Li, K., Liang, Zh., Lee, B., Zhang, F., Gu, Y., Zhang, L., Wu, F., Rodriguez, D. "Hybrid forecasting model based on long short term memory network and deep learning neural network for wind signal", *Applied Energy* 236, 262-272, 2019.

Rahman, S. M., and Miah, M. D. "The impact of sources of energy production on globalization: Evidence from panel data analysis", *Renewable and Sustainable Energy Reviews* 74, 110-115, 2017.

Rahmani, R., Yusof, R., Seyedmahmoudian, M., and Mekhilef, S. "Hybrid technique of ant colony and particle swarm optimization for short term wind energy forecasting", *Journal of Wind Engineering and Industrial Aerodynamics* 123(A), 163-170, 2013.

Rajagopalan, S., and Santoso, S. "Wind power forecasting and error analysis using the autoregressive moving average modeling", *2009 IEEE Power and Energy Society General Meeting, PES '09*, Calgary, AB, Canada, 26-30 July, 2009.

Ramli, M. A. M., Boucekara, H. R. E. H., and Alghamdi, A. S. "Optimal sizing of PV/wind/diesel hybrid microgrid system using multi-objective self-adaptive differential evolution algorithm", *Renewable Energy* 121, 400-411, 2018.

Robles-Rodriguez, C. E., and Dochain, D. "Decomposed Threshold ARMAX Models for short- to medium-term wind power forecasting", *IFAC-PapersOnLine* 51(13), 49-54, 2018.

Rullo, P., Braccia, L., Luppi, P., Zumoffen, D., and Feroldi, D. "Integration of sizing and energy management based on economic predictive control for standalone hybrid renewable energy systems", *Renewable Energy* 140, 436-451, 2019.

Samuel, A. L. "Some Studies in Machine Learning Using the Game of Checkers. II—Recent Progress", *IBM Journal of Research and Development* 44(1.2), 206-226, 2000.

Sanajaoba, S., and Fernandez, E. "Maiden application of Cuckoo Search algorithm for optimal sizing of a remote hybrid renewable energy System", *Renewable Energy* 96(A), 1-10, 2016.

Sanchez, V. M., Chavez-Ramirez, A. U., Duron-Torres, S. M., Hernandez, J., Arriaga, L. G., and Ramirez, J. M. "Techno-economical optimization based on swarm intelligence algorithm for a stand-alone wind-photovoltaic-hydrogen power system at south-east region of Mexico", *International Journal of Hydrogen Energy* 39(29), 16646-16655, 2014.

Sharma, N., Sharma, P., Irwin, D., and Shenoy, P. "Predicting solar generation from weather forecasts using machine learning", *2011 IEEE International Conference on Smart Grid Communications, SmartGridComm 2011*, Brussels, Belgium, 17-20 October, 2011.

Shi, J., Lee, W. J., Liu, Y., Yang, Y., and Wang, P. "Forecasting power output of photovoltaic systems based on weather classification and support vector machines", *2011 IEEE Industry Applications Society Annual Meeting*, Orlando, FL, USA, 9-13 October, 2011.

Shi, X., Lei, X., Huang, Q., Huang, S., Ren, K., and Hu, Y. "Hourly day-ahead wind power prediction using the hybrid model of variational model decomposition and long short-term memory", *Energies* 11(11), 3227, 2018.

Sideratos, G., and Hatziargyriou, N. D. "An advanced statistical method for wind power forecasting", *IEEE Transactions on Power Systems* 22(1), 258-265, 2007.

Sun, G., Jiang, C., Cheng, P., Liu, Y., Wang, X., Fu, Y., and He, Y. "Short-term wind power forecasts by a synthetical similar time series data mining method", *Renewable Energy* 115, 575-584, 2018.

Tang, N., Mao, S., Wang, Y., and Nelms, M. "LASSO-based single index model for solar power generation forecasting", *2017 IEEE Global Communications Conference, GLOBECOM 2017 - Proceedings*, Singapore, Singapore, 4-8 December, 2017.

Tibshirani, R. "Regression Shrinkage and Selection Via the Lasso", *Journal of the Royal Statistical Society: Series B (Methodological)* 58(1), 267-288, 1996.

Wang, C., and Nehrir, M. H. "Power management of a stand-alone wind/photovoltaic/fuel cell energy system", *IEEE Transactions on Energy Conversion* 23(3), 957-967, 2008.

Wang, F., Zhen, Z., Wang, B., and Mi, Z. "Comparative study on KNN and SVM based weather classification models for day ahead short term solar PV power forecasting", *Applied Sciences (Switzerland)* 8(28), 1-23, 2018.

Wang, H., Lei, Z., Zhang, X., Zhou, B., and Peng, J. "A review of deep learning for renewable energy forecasting", *Energy Conversion and Management* 198, 111799, 2019.

Wang, Jianzhou, Qin, S., Zhou, Q., and Jiang, H. "Medium-term wind speeds forecasting utilizing hybrid models for three different sites in Xinjiang, China", *Renewable Energy* 76, 91-101, 2015.

Wang, Jingmin, Zhou, Q., and Zhang, X. "Wind power forecasting based on time series ARMA model", *IOP Conference Series Earth and Environmental Science* 199(2), 1-6, 2018.

Wang, K., Qi, X., Liu, H., and Song, J. "Deep belief network based k-means cluster approach for short-term wind power forecasting", *Energy* 165(A), 840-852, 2018.

Whitley, D. "A genetic algorithm tutorial", *Statistics and Computing* 4, 65-85, 1994.

Worighi, I., Geury, T., El Baghdadi, M., Van Mierlo, J., Hegazy, O., and Maach, A. "Optimal design of hybrid PV-Battery system in residential buildings: End-user economics, and PV penetration", *Applied Sciences (Switzerland)* 9, 1-22, 2019.

Wu, B., Maleki, A., Pourfayaz, F., and Rosen, M. A. "Optimal design of stand-alone reverse osmosis desalination driven by a photovoltaic and diesel generator hybrid system", *Solar Energy* 163, 91-103, 2018.

Xu, Z., Nthontho, M., and Chowdhury, S. "Rural electrification implementation strategies through microgrid approach in South African context", *International Journal of Electrical Power and Energy Systems* 82, 452-465, 2016.

Yahiaoui, A., Fodhil, F., Benmansour, K., Tadjine, M., and Cheggaga, N. "Grey wolf optimizer for optimal design of hybrid renewable energy system PV-Diesel Generator-Battery: Application to the case of Djanet city of Algeria", *Solar Energy* 158, 941-951, 2017.

Yan, J., and Ouyang, T. "Advanced wind power prediction based on data-driven error correction", *Energy Conversion and Management* 180, 302-311, 2019.

Yang, H. T., Huang, C. M., Huang, Y. C., and Pai, Y. S. "A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output", *IEEE Transactions on Sustainable Energy* 5(3), 917-926, 2014.

Yang, H., Zhou, W., Lu, L., and Fang, Z. "Optimal sizing method for stand-alone hybrid solar-wind system with LPSP technology by using genetic algorithm", *Solar Energy* 82(4), 354-367, 2008.

Yao, Z., and Ruzzo, W. L. "A regression-based K nearest neighbor algorithm for gene function prediction from heterogenous data", *BMC Bioinformatics* 7(1), 1-11, 2006.

Yu, R., Gao, J., Yu, M., Lu, W., Xu, T., Zhao, M., Zhang, J., Zhang, R., Zhang, Zh. "LSTM-EFG for wind power forecasting based on sequential correlation features", *Future Generation Computer Systems* 93, 33-42, 2019.

Zahraee, S. M., Khalaji Assadi, M., and Saidur, R. "Application of Artificial Intelligence Methods for Hybrid Energy System Optimization", *Renewable and Sustainable Energy Reviews* 66, 617-630, 2016.

Zeng, J., and Qiao, W. "Short-term solar power prediction using a support vector machine", *Renewable Energy* 52, 118-127, 2013.

Zhang, C., Wei, H., Zhu, T., Zhang, K., and Liu, T. "Comparison of two multi-step ahead forecasting mechanisms for wind speed based on machine learning models", *Chinese Control Conference, CCC. 2015*, Hangzhou, China, 28-30 July, 2015.

Zhang, G., Wu, B., Maleki, A., and Zhang, W. "Simulated annealing-chaotic search algorithm based optimization of reverse osmosis hybrid desalination system driven by wind and solar energies", *Solar Energy* 173, 946-975, 2018.

Zhang, Y., and Wang, J. "GEFCom2014 probabilistic solar power forecasting based on k-nearest neighbor and kernel density estimator", *IEEE Power and Energy Society General Meeting*, Denver, CO, USA, 26-30 July, 2015.

Zheng, D., Semero, Y. K., Zhang, J., and Wei, D. "Short-term wind power prediction in microgrids using a hybrid approach integrating genetic algorithm, particle swarm optimization, and adaptive neuro-fuzzy inference systems", *IEEJ Transactions on Electrical and Electronic Engineering* 13(11), 1561-1567, 2018.

ÖZ GEÇMİŞ

Halil Demolli 24.06.1982 tarihinde Kosova, Kamenica'da doğdu. İlk, orta ve lise öğrenimini Kamenica'da tamamladı. 2001 yılında girdiği Priştina Üniversitesi Makine Mühendisliği Fakültesi'nden Nisan 2005'de mezun oldu. 2005-2008 yılları arasında Priştina Üniversitesi Makine Mühendisliği Fakültesi'nde Yüksek Lisansını tamamladı. 2009 yılında bu yana Priştina Üniversitesi Makine Mühendisliği Fakültesi'nde araştırma görevlisi olarak görev yapmaktadır.

2014 yılında Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı'nda başladığı Doktora eğitimine devam etmektedir. Evli ve iki çocuk babasıdır.

TEZ ÇALIŞMASINDAN ÜRETİLEN ESERLER

Bu tez çalışmasından, 1(bir) adet uluslararası makale ve 4(dört) adet uluslararası konferans bildirisi üretilmiştir, bu üretilen çalışmalar aşağıda sunulmuştur,

Sunulmuş ve 1 adet SCIE indexli makale;

1. Halil Demolli, Ahmet Sakir Dokuz, Alper Ecemis, Murat Gokcek, "*Wind power forecasting based on daily wind speed data using machine learning algorithms*", Energy Conversion and Management, 198, 111823, 2019,

Çalışmalar ile ilgili 4 adet uluslararası konferansta sözlü bildiri:

1. Ahmet Şakir Dokuz, Halil Demolli, Murat Gökçek, Alper Ecemiş "*Year-Ahead Wind Speed Forecasting using a Clustering-Statistical Hybrid Method*" International Conference on Innovative Engineering Applications (CIEA' 2018), Sivas, Turkey, 20-22 September, 2018.
2. Halil Demolli, Alper Ecemiş, Ahmet Şakir Dokuz, Murat Gökçek "*Makine öğrenmesi algoritmalarıyla güneş enerjisi tahmini: Niğde ili örneği*" International Turkish World Science and Engineering Congress UTUFEM, Niğde, Turkey, 17-18 Haziran, 2019.
3. Alper Ecemiş, Halil Demolli, Ahmet Şakir Dokuz, Murat Gökçek "*Belirli yük talepleri için makine öğrenmesi algoritmalarıyla rüzgâr türbini seçimi*" International Turkish World Science and Engineering Congress UTUFEM, Niğde, Turkey, 17-18 Haziran, 2019.
4. Alper Ecemiş, Halil Demolli, Murat Gökçek, Ahmet Şakir Dokuz "*Evaluation of Wind-Solar Hybrid Renewable Energy Systems using Loss of Power Supply Probability*" 3th International Conference, ICENTE Konya, Turkey, October 25-27, 2019.

