



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**PROTON ELEKTROLİT MEMBRANLI YAKIT
HÜCRESİNDE(PEMYH)ELEKTROLİZ YÖNTEMİYLE
HİDROJEN ÜRETİMİNİN YAPAY ZEKA İLE OPTİMİZASYONU**

Muhammed Yusuf PİLATİN

**Temmuz-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**PROTON ELEKTROLİT MEMBRANLI YAKIT
HÜCRESİNDE(PEMYH)ELEKTROLİZ YÖNTEMİYLE
HİDROJEN ÜRETİMİNİN YAPAY ZEKA İLE OPTİMİZASYONU**

Muhammed Yusuf PİLATİN

**Danışman
Dr. Öğr. Üyesi. Davut SEVİM**

Diğer Jüri Yeleri

Doç. Dr. Yılmaz KAYA

Doç. Dr. Murat AKDEMİR

Doç. Dr. Ömer Ali Karaman

Dr. Öğr. Üyesi. Rıdvan ÇETİN

**Temmuz-2025
BATMAN**

TEZ KABUL VE ONAYI

Muhammed Yusuf PİLATİN tarafından hazırlanan tarafından hazırlanan “Proton Elektrolit Membranlı Yakıt Hücresinde (PEMYH) Elektroliz Yöntemiyle Hidrojen Üretiminin Yapay Zekâ ile Optimizasyonu” adlı tez çalışması 31/07/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Yılmaz KAYA

.....

Danışman

Dr. Öğr. Üyesi. Davut SEVİM

.....

Üye

Doç. Dr. Murat AKDEMİR

.....

Üye

Doç. Dr. Ömer Ali Karaman

.....

Üye

Dr. Öğr. Üyesi. Rıdvan ÇETİN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Muhammed Yusuf PİLATİN
Tarih:31.07.2025

ÖZET

YÜKSEK LİSANS TEZİ

PROTON ELEKTROLİT MEMBRANLI YAKIT HÜCRESİNDE(PEMYH) ELEKTROLİZ YÖNTEMİYLE HİDROJEN ÜRETİMİNİN YAPAY ZEKA İLE OPTİMİZASYONU

Muhammed Yusuf PİLATIN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi. Davut SEVİM

2025, 89 Sayfa

Bu çalışma, sıcaklığın, Proton Değişim Membranlı Yakıt Hücrelerinin (PEMYH) performansı üzerindeki etkisini deneysel olarak incelemektedir. Deneyler, sabit 12 Volt doğru akım altında, 5 ila 35 gram arasında değişen miktarlarda potasyum hidroksit (KOH) kullanılarak ve 25-30°C sıcaklık aralığında gerçekleştirilmiştir. Bulgular, sıcaklık artışının proton iletkenliğini artırarak elektrokimyasal reaksiyon hızını olumlu yönde etkilediğini göstermektedir. Özellikle 25-30°C aralığında hidrojen ve oksijen üretiminde belirgin artışlar gözlemlenmiştir. Ancak, sıcaklık 70°C'yi aştığında membran yapısında bozulmalar ve verimlilikte düşüşler meydana geldiği görülmüştür. Bu durum, sıcaklık kontrolünün, PEMYH sistemlerinde kritik bir parametre olduğunu ortaya koymaktadır. Ayrıca, KOH miktarındaki artış, su çözünme oranını ve gaz üretimini artırmış, fakat aşırı katalizör kullanımı membran stabilitesini olumsuz etkileyebileceğinden miktarın dikkatli yönetilmesi gerektiği vurgulanmıştır. Çalışma optimum sıcaklık aralığının, 25-30°C olduğu ve bu koşullarda PEM yakıt hücrelerinin hem verimli hem de uzun ömürlü çalıştığı ortaya konulmuştur. Deneysel veriler, literatürdeki benzer çalışmalarla uyumlu olup, gelecekteki araştırmalar için önemli bir referans niteliği taşımaktadır. Özellikle membran malzemelerinin geliştirilmesi, alternatif katalizörlerin kullanımı ve sıcaklık dengeleme mekanizmalarının iyileştirilmesi, PEMYH teknolojisinin daha da ileriye taşınması açısından öncelikli araştırma alanlarıdır.

Anahtar Kelimeler: Proton Değişim Membranlı Yakıt Hücresi, Sıcaklık Etkisi, Proton İletkenliği, Optimum Çalışma Koşulları.

ABSTRACT

MASTER THESIS

EFFECTS OF TEMPERATURE ON PERFORMANCE IN PEM FUEL CELLS: AN EXPERIMENTAL STUDY

Muhammed Yusuf PİLATİN

Batman University Graduate Education Institute

Electric-Electronic Engineering Department of Science

Advisor: Asst. Prof. Davut SEVİM

2025, 89 Pages

This study experimentally investigates the effect of temperature on the performance of Proton Exchange Membrane Fuel Cells (PEMFCs). The experiments were conducted under a constant 12 Volt direct current, using varying amounts of potassium hydroxide (KOH) in amounts ranging from 5 to 35 grams, and within a temperature range of 25–30°C. The findings indicate that increasing temperature enhances proton conductivity and improves the rate of electrochemical reactions. Notably, significant increases in hydrogen and oxygen production were observed within the 25–30°C range. However, it was observed that when the temperature exceeded 70°C, membrane degradation and efficiency losses were recorded. This highlights the importance of temperature control as a critical parameter in PEMFC systems. Additionally, increasing the amount of KOH improved water dissociation and gas production, but it was emphasized that the amount should be managed carefully since excessive catalyst use may negatively affect membrane stability. The study has shown that the optimum temperature range is 25-30°C and that PEM fuel cells operate both efficiently and for a long time under these conditions. The experimental results are consistent with similar studies in the literature and serve as a valuable reference for future research. In particular, advancements in membrane materials, the use of alternative catalysts, and improvements in temperature regulation mechanisms are recommended as priority research areas to further enhance PEMFC performance.

Keywords: Proton Exchange Membrane Fuel Cell, Temperature Effect, Proton Conductivity, Optimal Operating Conditions.

ÖN SÖZ

Yenilenebilir enerji kaynaklarından biri olan ve son yıllarda yüksek ölçüde gelişim kaydeden yakıt pilleri üzerinde çalışmama vesile olan ve Yüksek lisans tez çalışmamda emeği olan değerli hocam Dr. Öğr. Üyesi Davut SEVİM' e, bu çalışmanın ortaya çıkmasında gösterdiği ilgiden dolayı Doç. Dr. Yılmaz KAYA ve Doç. Dr. Selman AYDIN' a, yaptığımız çalışmanın deneysel düzeneğinin kurulmasında katkısı olan İdris GÜN'e ve manevi destekleriyle tüm tez sürecinde yanımda olan sevgili aileme teşekkürü bir borç bilirim.

Muhammed Yusuf PİLATİN
BATMAN-2025



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	2
3. HİDROJEN ENERJİSİ	4
3.1. Hidrojen Gazı	4
3.2. Hidrojen Enerjisinin Avantajları.....	5
3.3. Hidrojen Enerjisinin Dezavantajları	5
3.4. Hidrojen Enerjisinin Yakıt Olarak Kullanımı.....	6
3.5. Hidrojen Enerjisinin Kullanım Alanları	6
4. YAKIT PİLLERİ	7
4.1. Yakıt Pili Tarihçesi	7
4.2. Yakıt Pilinin Çalışması	9
4.3. Yakıt Pili Çeşitleri	10
4.3.1. Polimer Elektrolit Yakıt Pili (PEMFC)	11
4.3.1.1 Elektrolit membran	14
4.3.1.2 Gaz difüzyon tabakası.....	15
4.3.2. Fosforik asit yakıt pili (PAFC)	16
4.3.3. Doğrudan metanol yakıt pili (DMFC)	17
4.3.4. Alkali yakıt pili (AYP)	18
4.3.5. Erimiş karbon yakıt pilleri (EKYP)	19
4.3.5. Katı oksit yapıdaki yakıt pilleri (KOYP).....	20

5. PEM ELEKTROLİZÖRLERDE NEM DİNAMİKLERİ VE GDL TASARIMININ FLOODİNG ÜZERİNDEKİ ROLÜ.....	22
5.1. Nem ve Verim İlişkisi.....	22
5.2. Flooding: Mekanizma ve Etkileri	23
5.2.1. Su birikiminin başlangıcı	23
5.2.2. Gözenek tıkanması ve difüzyon engeli	23
5.2.3. Elektriksel ve mekanik etkiler	23
5.2.4. Koşullara bağlı görülme sıklığı.....	24
5.3. GDL Tasarımı ile Flooding'in Azaltılması.....	24
5.3.1. Hidrofobik Yüzey Kaplamaları	24
5.3.2. Gradyan Gözenek Yapısı	24
5.3.3. Mikrokanal Sistemleri.....	25
5.3.4. Hibrit malzeme entegrasyonu	25
5.4. Grotthuss Mekanizması ile İlgili Araştırma ve Bildiri ile Bağlantı.....	25
5.4.1. Eigen katyonun ($H_3O_4^+$) tanımı ve yapısı	25
5.4.2. Zundel katyonun ($H_5O_2^+$) tanımı ve yapısı	26
6. MATERYAL METOD	27
6.1. PEM Yakıt Hücresi Deney Düzeneği	28
6.1.1. Deneyde kullanılan malzemeler.....	29
6.2. Makine Öğrenmesi Metotlar	34
6.2.1. Random forest regressor	34
6.2.2. K-Nearest neighbors (KNN).....	35
6.2.3. Linear regresyon	36
6.2.4. Decision tree regressor.....	38
6.2.5. Gradient boosting regressor	40
6.3. Performans Metrikleri.....	41
6.3.1. Mean squared error (MSE)	41
6.3.2. Root mean squared error (RMSE)	42
6.3.3. Mean absolute error (MAE).....	42
6.3.4. Coefficient of determination (R^2)	42

7. BULGULAR.....	43
8. TARTIřMA VE SONUÇ	84
KAYNAKLAR	86



TABLÖLER LİSTESİ

Tablo 7.1 5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	55
Tablo 7.2 7,5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	58
Tablo 7.3 10 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	61
Tablo 7.4 12,5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	64
Tablo 7.5 15 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	67
Tablo 7.6 17,5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	70
Tablo 7.7 20 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	73
Tablo 7.8 22,5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	76
Tablo 7.9 25 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	79
Tablo 7.10 27,5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	82
Tablo 7.11 30 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	85
Tablo 7.12 32,5 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	88
Tablo 7.13 35 gr KOH ait H_2 ve O_2 Gazı Hacmi Tahmin Sonuçları	91

ŞEKİLLER LİSTESİ

Şekil 4.1. Sir William Grove’ın ürettiği yakıt pili (Dalğış,2019)	21
Şekil 4.2. Francis Bacon ve 5 kW’lık alkali yakıt pili yığını	22
Şekil 4.3. Yakıt pilinin çalışma prensibi	23
Şekil 4.4. Kimyasal enerjinin elektrik enerjisine dönüşümü (Karaman ve ark.,2017)	24
Şekil 4.5. Yakıt hücresinin çalışma prensibi (Taner ve Eroğlu, 2008)	25
Şekil 4.6. PEMFC hücresinin bileşenleri	26
Şekil 4.7. Elektrolit Membran	28
Şekil 4.8. Yakıt pili bileşenleri	29
Şekil 4.9. Fosforik Asit yakıt pilinin yapısı ve çalışma şekli	30
Şekil 4.10. Doğrudan metanol yakıt pilinin boyuna kesitindeki katmanlar	31
Şekil 4.11. Alkali yakıt pilinin yapısı ve çalışma şekli	32
Şekil 4.12. Erimiş karbonat yakıt pili çalışma şekli	33
Şekil 4.13. Katı oksit yakıt pili çalışma şekli	34
Şekil 6.14. PEM çalışma düzeneği tasarımı	42
Şekil 6.15. Hidrojen tankı	43
Şekil 6.16. Oksijen tankı	45
Şekil 6.17. Ayarlanabilir güç kaynağı	45
Şekil 6.18. Volt ampermetre	45
Şekil 6.19. Potasyum Hidroksit	46
Şekil 6.20. Hassas terazi	46
Şekil 7.21. 5 gr için Random Forest ile H Tahmin ve hata değerleri	58
Şekil 7.22. 5 gr için Random Forest ile O Tahmin ve hata değerleri	59
Şekil 7.23. 7.5 gr için Random Forest ile H Tahmin ve hata değerleri	61
Şekil 7.24. 7.5 gr için Random Forest ile O Tahmin ve hata değerleri	62
Şekil 7.25. 10 gr için Random Forest ile H Tahmin ve hata değerleri	64
Şekil 7.26. 10 gr için Random Forest ile O Tahmin ve hata değerleri	65

Şekil 7.27. 12,5 gr için Random Forest ile H Tahmin ve hata değerleri	67
Şekil 7.28. 12,5 gr için Random Forest ile O Tahmin ve hata değerleri	68
Şekil 7.29. 15 gr için Random Forest ile H Tahmin ve hata değerleri	70
Şekil 7.30. 15 gr için Random Forest ile O Tahmin ve hata değerleri	71
Şekil 7.31. 17.5 gr için Random Forest ile H Tahmin ve hata değerleri	73
Şekil 7.32. 17.5 gr için Random Forest ile O Tahmin ve hata değerleri	74
Şekil 7.33. 20 gr için Random Forest ile O Tahmin ve hata değerleri	76
Şekil 7.34. 20 gr için Random Forest ile O Tahmin ve hata değerleri	77
Şekil 7.35. 22.5 gr için Random Forest ile H Tahmin ve hata değerleri	79
Şekil 7.36. 22.5 gr için Random Forest ile O Tahmin ve hata değerleri	80
Şekil 7.37. 25 gr için Random Forest ile H Tahmin ve hata değerleri	82
Şekil 7.38. 25 gr için Random Forest ile O Tahmin ve hata değerleri	83
Şekil 7.39. 27.5 gr için Random Forest ile H Tahmin ve hata değerleri	85
Şekil 7.40. 27.5 gr için Random Forest ile O Tahmin ve hata değerleri	86
Şekil 7.41. 30 gr için Random Forest ile H Tahmin ve hata değerleri	88
Şekil 7.42. 30 gr için Random Forest ile O Tahmin ve hata değerleri	89
Şekil 7.43. 32.5 gr için Random Forest ile H Tahmin ve hata değerleri	91
Şekil 7.44. 32.5 gr için Random Forest ile O Tahmin ve hata değerleri	92
Şekil 7.45. 35 gr için Random Forest ile H Tahmin ve hata değerleri	94
Şekil 7.46. 35 gr için Random Forest ile O Tahmin ve hata değerleri	95

SİMGELER VE KISALTMALAR

Simgeler

H_2	: Hidrojen gazı
O_2	: Oksijen gazı
H^+	: Proton (hidrojen iyonu)
OH^-	: Hidroksit iyonu
H_3O^+	: Hidronyum iyonu
$H_5O_2^+$	: Zundel katyonu
$H_9O_4^+$	: Eigen katyonu
V	: Voltaj (gerilim)
A	: Akım (amper)
$^{\circ}C$	: Santigrat derece (sıcaklık birimi)
MJ/kg	: Megajoule/kilogram (enerji yoğunluğu)
$RMSE$	: Root Mean Squared Error (Kök Ortalama Kare Hata)
MSE	: Mean Squared Error (Ortalama Kare Hata)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
R^2	: Determination coefficient (model açıklayıcılığı)

Kısaltmalar

PEM	: Proton Exchange Membrane (Proton Değişim Membranı)
PEMFC	: Proton Exchange Membrane Fuel Cell (Proton Değişim Membranlı Yakıt Pili)
PEMYH	: Proton Elektrolit Membranlı Yakıt Hücresi
KOH	: Potasyum Hidroksit
GDL	: Gas Diffusion Layer (Gaz Difüzyon Tabakası)
AI	: Artificial Intelligence (Yapay Zekâ)
ML	: Machine Learning (Makine Öğrenmesi)
KNN	: K-Nearest Neighbors (En Yakın Komşular Algoritması)
RF	: Random Forest (Rastgele Orman Algoritması)
LR	: Linear Regression (Doğrusal Regresyon)
DT	: Decision Tree (Karar Ağacı)
GB	: Gradient Boosting (Gradyan Artırmalı Öğrenme)
DA	: Doğru Akım

SOFC	: Solid Oxide Fuel Cell (Katı Oksit Yakıt Pili)
DMFC	: Direct Methanol Fuel Cell (Doğrudan Metanol Yakıt Pili)
PAFC	: Phosphoric Acid Fuel Cell (Fosforik Asit Yakıt Pili)
MCFC	: Molten Carbonate Fuel Cell (Erimiş Karbonat Yakıt Pili)
AYP	: Alkali Yakıt Pili
YSA	: Yapay Sinir Ağı
SVM	: Support Vector Machine (Destek Vektör Makineleri)
DC	: Direct Current (Doğru Akım)
sPEEK	: Sulfonated Polyether Ether Ketone (Sülfonlanmış Polieter Eter Keton)
YSZ	: Yttria Stabilized Zirconia (İttriya Stabilize Zirkonya).



1. GİRİŞ

Enerji, insanlığın temel ihtiyaçlarını karşılamada vazgeçilmez bir unsurdur ve bu ihtiyaç, sanayileşme, nüfus artışı ve yeni teknolojilerle birlikte hızla artmaktadır. Ancak, son yüzyılda enerji talebinin büyük ölçüde fosil yakıtlarla (petrol, kömür, doğal gaz) karşılanması hem sınırlı rezervler hem de ciddi çevresel sorunlar nedeniyle sürdürülebilir bir çözüm olmaktan çıkmıştır (Erdoğan, 2003). Fosil yakıtların kullanımı, küresel ısınma, asit yağmurları ve hava kirliliği gibi çevresel problemlere yol açarken, bu yakıtların rezervlerinin tükenmekte olması alternatif enerji kaynaklarına yönelimi zorunlu kılmaktadır (Veziroğlu, 1998). Bu bağlamda, hidrojen enerjisi, sınırsız, temiz ve yüksek verimli bir enerji kaynağı olarak öne çıkmaktadır. Hidrojen, evrende en bol bulunan elementlerden biri olup, su gibi yaygın bir kaynaktan üretilebilir ve oksijenle reaksiyona girerek yalnızca su ve ısı gibi çevre dostu yan ürünler üretir (Barbir, 2003). Bu özellikleriyle hidrojen, özellikle Proton Değişim Membranı yakıt hücreleri aracılığıyla enerji dönüşümünde önemli bir rol oynamaktadır. PEM yakıt hücreleri, kimyasal enerjiyi doğrudan elektrik enerjisine dönüştüren, yüksek verimli ve düşük emisyonlu bir teknoloji olarak otomotiv, sabit enerji sistemleri ve taşınabilir güç uygulamalarında büyük potansiyel taşımaktadır (Çetinkaya, 2003). Bu tez çalışmasında, Proton Değişim Membranlı yakıt hücrelerinin performansı üzerinde sıcaklığın etkisi deneysel olarak incelenmiştir. Deneyler, sabit olarak uygulanan 12 Volt Doğru Akım (DA) altında farklı miktarlarda potasyum hidroksit (5-35 gr arasında) ve değişken sıcaklık aralıkları (25-30°C) kullanılarak gerçekleştirilmiştir. Elde edilen bulgular, sıcaklık artışının proton iletkenliğini artırarak elektrokimyasal reaksiyon hızını iyileştirdiğini, ancak 70°C'nin üzerindeki sıcaklıklarda membran içyapısını ve elektroliz verimliliğini olumsuz yönde etkilediğini göstermiştir. Hidrojen ve oksijen üretiminde, sıcaklık artışının belirli bir noktaya kadar pozitif etkisi bulunmuş, ancak bu sınır aşıldığında verim düşüşleri kaydedilmiştir. PEM yakıt hücrelerinin verimli ve uzun ömürlü çalışması, optimum sıcaklık aralığına bağlı olduğu görülmüştür. Çalışmada, seçilen PEM yakıt hücresi uygulamasına göre 25-30 °C arasındaki sıcaklık aralığının ve 5-35 gramlık uygun KOH miktarının belirlenmesinin kritik öneme sahip olduğu ortaya konmuştur.

2. KAYNAK ARAŞTIRMASI

Sıcak baskı sıcaklık değerin PEM yakıt hücresi performansı üzerindeki etkisini değerlendirmiştir. Üç farklı sıcaklık seviyesinde yapılan deneylerde, yüksek sıcaklıkların membran-elektrot ara yüzeyindeki bağlanma kalitesini artırdığı, ancak aşırı yüksek sıcaklıkların membran yapısına zarar verebileceği gösterilmiştir. Çalışma, optimum sıcaklık aralığının hücre verimliliği ve uzun vadeli dayanıklılık açısından kritik olduğunu vurgulamaktadır. Ayrıca, sıcaklık artışının gaz difüzyon tabakasındaki poroziteyi etkilediği ve bu durumun akım yoğunluğuna yansıdığı belirtilmiştir (Özden, 2023). PEM yakıt hücrelerinin çalışma sıcaklığı, nem ve basınç gibi parametrelerin performans üzerindeki etkilerini incelemiştir. Yüksek sıcaklıkların proton iletkenliğini artırdığı, ancak 80°C üzerindeki sıcaklıklarda membran kurummasının hücre verimliliğini düşürdüğü belirtilmiştir. Çalışma, sıcaklık kontrol sistemlerinin tasarımında termal yönetim stratejilerinin önemini vurgulamış ve optimum çalışma sıcaklığı olarak 60-80°C aralığını önermiştir (Aydın, 2023). PEM yakıt hücrelerinin çalışma prensiplerini ve sıcaklık etkilerini tarihsel bir perspektifle incelemiştir. Çalışma, düşük sıcaklıklarda (40-60°C) hücre verimliliğinin sınırlı olduğunu, ancak 60-80°C aralığında proton değişim membranının iletkenliğinin optimum seviyelere ulaştığını göstermiştir. Yüksek sıcaklıkların (100°C üzeri) katalizör bozulmasına ve membran ömrünün kısılmasına neden olabileceği belirtilmiştir (Kılıç, 2023). Otomotiv uygulamalarına yönelik PEM yakıt hücrelerinde nem kontrolünün önemini incelemiştir. Yüksek nem seviyelerinin gaz difüzyon tabakasını tıkadığı, düşük nemin ise membran direncini artırdığı belirtilmiştir. Çalışma, dinamik nem kontrol sistemlerinin, özellikle değişken yük koşullarında, enerji verimliliği ve sistem dayanıklılığı için kritik olduğunu vurgulamıştır. Optimum nem aralığı olarak yüzde 55-75 önerilmiştir (Yılmaz, 2024). PEM yakıt hücrelerinde nemin su yönetimi üzerindeki etkisini incelemiştir. DeneySEL sonuçlar, yüzde 50-70 bağıl nem oranlarının proton iletkenliğini optimize ettiğini, ancak yüzde 90'ın üzerindeki nem seviyelerinin gaz difüzyon tabakasında su birikmesine neden olduğunu göstermiştir. Çalışma, nem kontrolü için dinamik su yönetim sistemlerinin gerekliliğini vurgulamış ve optimum nem aralığının hücre verimliliği için kritik olduğunu belirtmiştir (Li, 2008). PEM yakıt hücrelerinin performans parametrelerini (güç yoğunluğu, verimlilik, dayanıklılık) değerlendiren son gelişmeleri incelemektedir. Yazarlar, termal yönetim, su davranışı ve katalizör stabilitesi gibi operasyonel faktörlerin önemini vurgulamaktadır.

Ayrıca, doğrudan görselleştirme teknikleri ve yapay zekâ destekli optimizasyon yöntemlerinin performans analizinde nasıl kullanıldığını tartışmaktadır. Makale, bu yeniliklerin PEM yakıt hücrelerinin ticari ölçekte uygulanabilirliğini artırabileceğini öne sürmektedir (Santos, 2025). PEM yakıt hücrelerinin iki kritik bileşeni olan proton değişim membranları ve bipolar plakalar üzerine son araştırmaları incelemektedir. Yazarlar, membranların iletkenlik ve dayanıklılık özelliklerini iyileştirmek için yapılan yenilikleri (örneğin, kompozit membranlar) ve bipolar plakaların korozyon direncini artırmak için geliştirilen yeni malzemeleri (örneğin, grafen kaplamalar) tartışmaktadır. Makale, bu bileşenlerin performansının yakıt hücresinin genel verimliliğini doğrudan etkilediğini ve maliyet azaltımı için daha fazla araştırmaya ihtiyaç olduğunu belirtmektedir (Ogunbemi, 2024). PEM yakıt hücresi performansını tahmin etmek için yapay sinir ağlarını kullanmıştır. Nem, sıcaklık ve gaz akış hızı gibi giriş parametrelerinin hücre performansı üzerindeki etkileri modellenmiş ve YSA modelinin deneysel verilere kıyasla yüksek doğruluk sağladığı gösterilmiştir. Çalışma, YSA tabanlı optimizasyonun gerçek zamanlı kontrol sistemlerinde kullanılabileceğini vurgulamıştır (Özden, 2019). Makine öğrenimi algoritmalarını kullanarak PEM yakıt hücrelerinde termal yönetimi optimize etmeyi incelemiştir. Çalışma, derin öğrenme modellerinin sıcaklık ve nem parametrelerini gerçek zamanlı olarak tahmin ederek enerji verimliliğini artırdığını göstermiştir. Özellikle, destek vektör makineleri (SVM) ve rastgele orman algoritmalarının termal kontrol sistemlerinde başarılı sonuçlar verdiği belirtilmiştir (Wang,2020). Genetik algoritmaların PEM yakıt hücrelerinin çalışma parametrelerini optimize etmede kullanımını araştırmıştır. Nem, sıcaklık ve basınç gibi parametrelerin optimizasyonu için genetik algoritmalar kullanılmış ve bu yöntemin hücre verimliliğini yüzde 10'a kadar artırdığı gösterilmiştir. Çalışma, özellikle otomotiv uygulamalarında AI tabanlı optimizasyonun potansiyelini vurgulamıştır (Aydın, 2021).

3. HİDROJEN ENERJİSİ

Hidrojen enerjisi, hidrojen gazının kimyasal enerjisinin çeşitli yöntemlerle (örneğin, yakıt hücreleri, içten yanmalı motorlar) elektrik, ısı veya mekanik enerjiye dönüştürülmesiyle elde edilen bir enerji taşıyıcısıdır. Hidrojen, evrende en bol bulunan elementlerden biri olup, su, biyokütle ve hidrokarbonlar gibi kaynaklardan üretilir. PEM yakıt hücreleri, hidrojen ve oksijenin elektrokimyasal reaksiyonu yoluyla enerji üretir ve yalnızca su ile ısı gibi çevre dostu yan ürünler oluşturur. Hidrojen enerjisi, yenilenebilir enerji kaynaklarıyla entegre edilerek sıfır emisyonlu enerji sistemleri oluşturma potansiyeline sahiptir. Üretim yöntemleri arasında elektroliz, buhar reformasyonu ve termokimyasal süreçler yer alır; özellikle yenilenebilir enerjiyle çalışan elektroliz, temiz hidrojen üretimi için öne çıkmaktadır. Hidrojen enerjisi, enerji depolama ve taşıma açısından da esneklik sağlar, bu da onu gelecekteki enerji sistemlerinin temel bir bileşeni haline getirir (Veziroğlu, 1998; Babir, 2005; Erdoğan, 2003).

3.1. Hidrojen Gazı

Hidrojen gazı (H_2), evrende en yaygın bulunan element olan hidrojenin iki atomlu gaz formudur. Renksiz, kokusuz ve oldukça yanıcı bir gaz olan hidrojen, düşük yoğunluğu nedeniyle hafif bir yapıya sahiptir. Doğada genellikle su, hidrokarbonlar veya biyokütle gibi bileşikler içinde bulunur ve bu kaynaklardan çeşitli yöntemlerle (örneğin, elektroliz, buhar reformasyonu) ayrıştırılarak elde edilir. Hidrojen gazı, yüksek enerji içeriğine sahiptir; birim kütle başına enerji değeri, fosil yakıtlardan çok daha yüksektir (yaklaşık 120- 142 MJ/kg). Ancak, düşük hacimsel enerji yoğunluğu nedeniyle depolama ve taşıma süreçlerinde sıkıştırma veya sıvılaştırma gerektirir. PEM yakıt hücrelerinde, hidrojen gazı anot tarafında oksijenle reaksiyona girerek elektrik enerjisi üretir ve bu süreçte yalnızca su açığa çıkar. Hidrojen gazının temiz enerji üretimindeki rolü, özellikle yenilenebilir kaynaklarla birleştiğinde, çevre dostu bir alternatif sunar (Veziroğlu, 1998; Babir, 2005).

3.2. Hidrojen Enerjisinin Avantajları

Hidrojen enerjisi, sürdürülebilir enerji sistemleri için birçok avantaja sahiptir. İlk olarak, çevre dostudur; PEM yakıt hücrelerinde hidrojenin oksijenle reaksiyonu yalnızca su ve ısı üretir, böylece karbon emisyonları veya hava kirliliği oluşturmaz. İkinci olarak, hidrojen bol bir kaynaktır ve su, biyokütle veya yenilenebilir enerjiyle elektroliz yoluyla üretilir, bu da enerji bağımsızlığını destekler. Üçüncü olarak, yüksek enerji verimliliği sunar; PEM yakıt hücreleri, içten yanmalı motorlara kıyasla daha yüksek enerji dönüşüm verimliliği sağlar (%40-60). Ayrıca, hidrojen enerjisi esnek bir enerji taşıyıcısıdır; otomotiv, sabit enerji sistemleri ve taşınabilir cihazlar gibi farklı sektörlerde kullanılabilir. Hidrojen, yenilenebilir enerji kaynaklarından üretilen fazla elektriğin depolanmasında da etkili bir çözüm sunar, böylece enerji şebekesi stabilitesini artırır. Türkiye gibi bor rezervlerine sahip ülkelerde, hidrojen üretimi yerel kaynaklarla desteklenebilir (Verziroğlu, 1998; Çetinkaya, 2003; Larmin, 2003).

3.3. Hidrojen Enerjisinin Dezavantajları

Hidrojen enerjisinin yaygınlaşması, bazı teknik ve ekonomik zorluklarla karşı karşıyadır. İlk olarak, hidrojen üretimi pahalıdır; özellikle yenilenebilir enerjiyle elektroliz yöntemi, yüksek enerji tüketimi nedeniyle maliyetlidir. İkinci olarak, hidrojen gazının depolanması ve taşınması zordur; düşük hacimsel enerji yoğunluğu, yüksek basınçlı tanklar veya sıvılaştırma gibi karmaşık yöntemler gerektirir, bu da maliyetleri artırır. Üçüncü olarak, hidrojenin yanıcı doğası güvenlik riskleri oluşturur; sızıntılar veya yanlış kullanım patlama riskini artırabilir. Ayrıca, hidrojen altyapısı (üretim, depolama, dağıtım) henüz küresel ölçekte yeterince gelişmemiştir, bu da ticarileşmeyi sınırlar. PEM yakıt hücrelerinin yüksek üretim maliyetleri ve katalizörlerde kullanılan pahalı malzemeler (örneğin, platin) de ekonomik bir engeldir. Türkiye gibi gelişmekte olan ülkelerde, hidrojen altyapısının kurulması için önemli yatırımlar gerekmektedir (Babir, 2005; Erdoğan, 2003; Ewald, 2003).

3.4. Hidrojen Enerjisinin Yakıt Olarak Kullanımı

Hidrojen gazının PEM yakıt hücrelerinde yakıt olarak kullanımını ve otomotiv sektöründeki uygulamalarını incelemiştir. Hidrojenin, 60-80°C sıcaklık aralığında çalışan PEM yakıt hücrelerinde yüksek verimlilikle (%40-60) elektrik enerjisine dönüştürüldüğü belirtilmiştir. Çalışma, hidrojen yakıt hücreli araçların (örneğin, Toyota Mirai) şehir içi ulaşımında sıfır emisyon sunduğunu ve toplu taşıma sistemlerinde (hidrojen otobüsleri) yaygınlaştığını göstermiştir. Ancak, hidrojen depolama sistemlerinin hacimsel sınırlamaları ve altyapı eksiklikleri ticarileşme önünde engel olarak tanımlanmıştır (Wang, 2011). Hidrojen gazının havacılık sektöründe yakıt olarak kullanımına odaklanmıştır. Eylül 2020’de Avrupa’da tanıtılan sıvı hidrojenle çalışan yolcu uçağı konseptleri incelenmiştir. Hidrojenin, gazyağına alternatif olarak yüksek enerji içeriği sunduğu, ancak sıvı hidrojen depolama sistemlerinin düşük sıcaklık (-253°C) gereksinimi nedeniyle teknolojik zorluklar yarattığı belirtilmiştir. Çalışma, hidrojenin havacılıkta karbon nötr bir geleceğe katkı sağlayabileceğini, ancak altyapı yatırımlarına ihtiyaç duyulduğunu vurgulamıştır (Baroutaji, 2021)

3.5. Hidrojen Enerjisinin Kullanım Alanları


Hidrojen enerjisi, günlük yaşantıda ve endüstriyel uygulamalarda geniş bir kullanım yelpazesine sahiptir. Otomotiv sektöründe, PEM yakıt hücreli araçlar (örneğin, Toyota Mirai, Hyundai Nexa) sıfır emisyonlu ulaşım sağlar ve şehir içi toplu taşıma sistemlerinde (hidrojen yakıtlı otobüsler) yaygınlaşmaktadır. Sabit enerji sistemlerinde, hidrojen enerjisi evsel enerji üretimi, hastaneler, veri merkezleri ve uzak bölgelerdeki enerji ihtiyacını karşılamak için kullanılır. Taşınabilir cihazlarda, hidrojen yakıt hücreleri dizüstü bilgisayarlar, cep telefonları ve acil durum jeneratörleri gibi uygulamalarda kompakt güç kaynakları sunar. Endüstriyel uygulamalarda, hidrojen amonyak üretimi, petrol rafinerileri ve çelik üretiminde kullanılır. Ayrıca, hidrojen enerjisi, yenilenebilir enerji kaynaklarından üretilen fazla elektriğin depolanması ve gerektiğinde kullanılması için bir enerji depolama çözümü olarak öne çıkar. Türkiye’de, bor rezervleri ve Karadeniz’deki hidrojen sülfür kaynakları, hidrojen enerjisinin yerel uygulamalarını destekleme potansiyeline sahiptir (Çetinkaya, 2003; Larminie, 2003; Erdoğan, 2003).

4. YAKIT PİLLERİ

Yakıt pili; uygun bir yakıt ve oksitleyicinin elektrokimyasal bir reaksiyonu ile elektrik enerjisi üreten bir sistemdir. Yani yakıt pili, yakıt ve havanın elektrokimyasal tepkimesi ile yakıt kimyasal enerjisini doğrudan elektrik enerjisine dönüştüren bir üreteçtir. Elektrolizin ters reaksiyonu olarak da tanımlanabilecek olan yakıt pili reaksiyonu sonrası, doğru akım formunda elektrik üretilir. Yakıt pilleri yakıt ve hava sağlandığı sürece bu dönüşümü sürekli gerçekleştirebilen enerji üretim sistemidir. Yakıt pilleri hareketli parça içermeyen ve yüksek verimli, doğalgaz veya diğer hidrojen içeren gazlardan elektrik ve ısı enerjisi üretim teknolojisi. Yakıt pilinde doğrudan birincil enerji kaynağı olarak, hidrojen kullanılabileceği gibi, dönüştürme yapıldığı takdirde, doğalgaz, LPG, metanol, nafta veya benzin gibi hidrojen içeren yakıtlar da kullanılabilmektedir. Yakıt pili 3 temel kısımdan meydana gelir. Anot (negatif elektrot), Katot (pozitif elektrot), ve bu iki elektrot arasında kalan elektrolit (değişim zarı)

4.1. Yakıt Pili Tarihçesi

Yakıt pili, çok eski tarihlere dayanmasına rağmen ilk kullanımı 1958 yılında NASA'nın uzay programında Apollo, Gemini ve Space Shuttle uzay gemilerinde yakıt olarak kullanılmasına dayanmaktadır. 1838- Sir William Grove ilk yakıt pili çalışmaları Sir William Grove tarafından H₂ -O₂ pili üzerinde yapılmıştır. Yaptığı çalışmalar sırasında suyun elektrolizinin ters reaksiyonu sonucunda sabit akım ve gücün üretildiğini fark eden Grove, böylece tesadüfen çok büyük bir buluş gerçekleştirmiştir. (Şekil 4.1)



Şekil 4.1. Sir William Grove'ın ürettiği yakıt pili (Dalğış,2019)


1893 -Friedrich Wilhelm Ostwald, Yakıt pili içindeki her elemanın yakıt pili çalışmasındaki görevini ve etkisini araştırmıştır.1896 -William W. Jacques, Eriyik elektrolitli yakıt pillerinin temelini atmıştır. Kömürün elektrokimyasal enerjisinden doğrudan elektrik üretmeyi amaçlamıştır.1937- Emil Baur, 1900 yılında, ünlü bilim adamı Nerst'in başlattığı katı oksit elektrolit ile çalışan yakıt hücresi projesinin başarıya ulaşmasını sağlamıştır.1959- Francis Thomas Bacon, belki de yakıt pilinin günümüzdeki yere gelmesini sağlayan en önemli çalışma Bacon tarafından alkalin yakıt pilleri üzerinde yapılan çalışmalar olmuştur. Bu çalışmanın önemini anlayan Pratt & Whitney şirketi bu projeye lisans vererek NASA programlarında kullanılmasını sağlamıştır. 40 Hücreden oluşan ve 5kW güç üretebilen Şekil 4.2'de görünen yakıt pili yığını üretti. Bu yığın, kaynak makinesi ve elektrikli testereyi çalıştırdı.



Şekil 4.2. Francis Bacon ve 5 kW'lık alkali yakıt pili yığını

4.2. Yakıt Piliin Çalışması

Yakıt pilleri, kimyasal enerjiyi doğrudan elektrik enerjisine çeviren çevre dostu bir teknolojidir. Yanma olmadan, elektrokimyasal reaksiyonla çalışır ve karbon salımı yapmaz. Temel olarak anot, katot ve elektrolitten oluşur (Şekil 4.3). Anotta hidrojen, katalizörle proton ve elektrona ayrışır; protonlar elektrolit üzerinden katoda geçer, elektronlar ise dış devreden akarak elektrik üretir. Katotta oksijen, protonlar ve elektronlarla birleşip su oluşturur. Elektrolit, iyon geçişine izin verirken yalıtımı sağlar. Doğru akım üreten yakıt pilleri, yüksek verimlidir. Gerilim için hücreler seri bağlanır, akım için yüzey alanı artırılır. Hidrojen yerine hidrokarbonlar kullanılabilir, ancak verim düşer.



Şekil 4.3. Yakıt pilinin çalışma prensibi

4.3. Yakıt Pili Çeşitleri

Yakıt türü, oksitleyici türü, kullanılan yakıtın yakıt pilinin işlenişi, elektrolit tipi, işletme sıcaklığı, yakıtın besleme şekli gibi parametre değişimi gibi farklı türleri ortaya çıkarmaktadır. Yakıt pili uygulamasında ise yakıt pili sıcaklığı, elektrolit tipi ve kullanılan yakıt cinsine göre sınıflandırırız. Sonuç olarak yakıt pillerini altıya ayırabilmekteyiz;


- Polimer elektrolit yakıt pili (PEMFC)
- Fosforik asit yakıt pili (PAFC)
- Doğrudan metanol yakıt pili (DMFC)
- Alkali yakıt pili (AYP)
- Erimiş karbonatlı yakıt pili (MCFC)
- Katı oksitli yakıt pili (SOFC)

Hücre sıcaklığı ve yakıt pilinin yapımında kullanılan malzeme pillerin ömürlerini belirlemektedir. Hücre sıcaklığına bağlı olarak kimyasal reaksiyon hızı ortaya çıkmakta ve bu hızın düşük veya yüksek olması durumunda uygun katalizörler ilave edilir. Yüksek sıcaklıkta katalizör ihtiyacı minimum iken düşük sıcaklıklarda performansın artması için

maliyeti yüksek olan Platin katalizörünü kullanmak zorunda kalınır. Buda ekonomik açıdan istenilen bir durum değildir.

4.3.1. Polimer Elektrolit Yakıt Pili (PEMFC)


Proton Değişim Membranlı yakıt hücreleri, çevresel sürdürülebilirlik açısından büyük bir öneme sahiptir. Bu yakıt hücreleri, hidrojenin doğrudan elektrik enerjisine dönüşmesini sağlayarak fosil yakıtların yanmasıyla oluşan karbon salınımını tamamen ortadan kaldırır (Mohamed Ali,2011). PEM yakıt hücreleri, sıfır emisyonlu enerji üretimi sağladığı için hem ulaşım hem de sabit enerji üretimi için temiz bir alternatif olarak görülmektedir (Erdener,2013). Ayrıca, düşük çalışma sıcaklığı ve hızlı başlatılabilirlik özellikleri, otomotiv sektöründe içten yanmalı motorlara kıyasla büyük avantajlar sunmaktadır. Bunun yanı sıra, PEM yakıt hücreleri, yüksek enerji dönüşüm verimliliği ile yakıt tüketimini azaltarak enerji tasarrufu sağlamaktadır (Taner ve Eroğlu,2008).



Şekil 4.4. Kimyasal enerjinin elektrik enerjisine dönüşümü (Karaman ve ark.,2017)


Yakıt hücrelerinde, yakıtın kimyasal enerjisi doğrudan elektrik enerjisine dönüştürülürken, klasik çevrim teknolojisinde bu süreç tamamen farklıdır. Şekil 4.4'te kimyasal enerjinin elektrik enerjisine dönüşümü görülmektedir. Geleneksel fosil yakıtlı enerji üretim süreçlerinde, ilk olarak yakıtın yanmaya uygun hale getirilmesi sağlanır, ardından kimyasal enerjisi ısı enerjisine, bu enerji ise mekanik harekete ve son olarak jeneratörler aracılığıyla elektrik enerjisine dönüştürülür. Ancak yakıt hücrelerinde bu ara süreçler olmadığı için enerji dönüşüm verimliliği çok daha yüksektir (Karaman ve ark., 2017). Yakıt hücreleri, anot, katot ve elektrolit olmak üzere üç temel bileşenden oluşur. Tipik bir yakıt hücresinin çalışma prensibi Şekil 4.5'te görülmektedir. Anot, negatif

elektrot; katot ise pozitif elektrottur. Yakıt anoda, oksitleyici ise katoda sürekli olarak beslenir. Yakıt ile oksijen arasında indirgenme-yükseltgenme reaksiyonları gerçekleşirken, elektrik akımı ve ısı üretilir. PEMFC’inde hidrojenin anot tarafında ayrılarak proton ve elektronlara ayrıldığı, protonların membran aracılığıyla katoda taşındığı, elektronların ise harici devre aracılığıyla katoda ulaştığı temel prensip geçerlidir. Son aşamada, katotta oksijen ile hidrojen birleşerek su oluşur ve bu süreç sıfır emisyonlu bir enerji dönüşümü sağlar (Lee, 2007).



Şekil 4.5. Yakıt hücresinin çalışma prensibi (Taner ve Eroğlu, 2008)



Bipolar plakaların kanalları sayesinde anot tarafına gönderilen hidrojen, katalizör yüzeye ulaştığında hidrojen iyonlarına ayrışır ve elektronlarını serbest bırakır. Polimer membran, yalnızca protonların geçişine izin verirken, elektronlar harici devrede hareket ederek elektrik üretir. Son aşamada, katotta oksijen, hidrojen iyonları ve elektronlar birleşerek su oluşturur ve sistemden ayrılır (Sethuraman, 2020). PEMFC’nin verimli çalışabilmesi için katalizör seçimi büyük önem taşımaktadır. Günümüzde platin (Pt), en yaygın kullanılan katalizördür ancak yüksek maliyeti nedeniyle alternatif katalizörler araştırılmaktadır. Potasyum hidroksit gibi kimyasal bileşikler, düşük maliyetli katalizör alternatifleri arasında yer almaktadır (J. Larminie, 2003). Tekli bir PEMFC’nin bileşenleri Şekil 4.6’da gösterilmiştir.



Şekil 4.6. PEMFC hücresinin bileşenleri


Yakıt hücrelerinin performansını artırmak amacıyla gerçekleştirilen çalışmalar, çeşitli faktörlerin etkisini incelemektedir. (C. Spiegel, 2008), PEMFC anot ve katot bölgelerindeki hidrojen peroksit oluşum oranlarını sıcaklık ve nem değişkenleri altında analiz etmiştir. Çalışma, oksijen indirgeme kayıpları sırasında hidrojen peroksit oluşumunun nem ve sıcaklık koşullarına bağlı olarak değiştiğini ve yakıt hücrelerinin genel performansı üzerinde önemli etkiler yarattığını göstermiştir. Benzer şekilde (Arvay vd., 2017), yeni nesil akış kanalı tasarımlarının yakıt hücrelerinin verimliliği üzerindeki etkisini araştırmış ve bu tasarım değişikliklerinin elektrokimyasal reaksiyon hızını iyileştirdiğini ortaya koymuştur. Yakıt hücrelerinin performansını artırmada sıcaklık önemli bir parametredir. (Liu vd, 2019) tarafından yapılan bir çalışmada, farklı sıcaklık aralıklarında yakıt hücresi performansına yönelik detaylı analizler gerçekleştirilmiştir. Sonuçlar, belirli bir sıcaklık eşiğinin üzerine çıkıldığında membran bozulmasının hızlandığını ve bu durumun uzun vadede hücre ömrünü azalttığını göstermektedir. Ayrıca, hücre içi nem seviyesinin yakıt hücresinin iletkenliği üzerindeki kritik rolü vurgulanmıştır. Son yıllarda yapılan araştırmalar (Victor vd, 2020), PEMFC teknolojisinin gelişimine katkı sağlamaktadır. Sınırlı alanlarda kullanılan PEMFC sistemlerinin termal analizini gerçekleştirmiş ve sıcaklık dağılımlarının hücre verimi üzerindeki etkilerini incelemiştir. Bulgular, sıcaklık artışının belirli bir noktaya kadar elektrokimyasal reaksiyonları hızlandırdığını ancak aşırı sıcaklık durumlarında performans kayıplarına yol açtığını göstermiştir. Bu nedenle, yakıt hücrelerinde optimum sıcaklık aralıklarının belirlenmesi büyük önem taşımaktadır. Sonuç olarak, Proton Değişim Membranlı Yakıt Hücreleri, enerji verimliliği ve çevre dostu yapıları sayesinde

geleceğin sürdürülebilir enerji sistemleri arasında önemli bir yere sahiptir. Yapılan araştırmalar, sıcaklık, nem ve katalizör malzemesi gibi parametrelerin yakıt hücresinin performansı üzerinde kritik etkileri olduğunu göstermektedir. Gelecekte, bu teknolojinin daha verimli hale getirilmesi için yeni malzemeler, gelişmiş elektrot yapıları ve optimize edilmiş işletme koşulları üzerine çalışmaların artırılması gerekmektedir. Bu doğrultuda, literatürdeki veriler ışığında daha yüksek verimli ve ekonomik yakıt hücrelerinin geliştirilmesi hedeflenmektedir. PEM Yakıt Pili Anot ve katot kısmında oluşan kimyasal reaksiyonlar aşağıdaki gibi olmaktadır:



4.3.1.1 Elektrolit membran


Elektrolit membranlar, yakıt hücreleri, elektrolizörler, bataryalar ve sensörler gibi elektrokimyasal sistemlerde iyonların (proton, hidroksit, lityum veya oksijen iyonu) bir elektrottan diğerine geçişini sağlayan katı, yarı katı veya sıvı bazlı malzemelerdir. Bu membranlar, yüksek iyon iletkenliği, düşük gaz geçirgenliği ve kimyasal/termal stabilite gibi özellikleriyle enerji dönüşümünde kritik bir rol oynar (Çelik & Bozkurt, 2020). Elektrolit membranlar, malzeme türüne ve iyon iletim mekanizmasına göre çeşitlenir: polimer bazlı membranlar (ör. Nafion, sülfonlanmış polieter eter keton-sPEEK), seramik bazlı membranlar (ör. itriya stabilize zirkonya-YSZ), kompozit membranlar (ör. silika katkılı polimerler) ve sıvı elektrolitler (ör. potasyum hidroksit-KOH) (Kapusuz, 2025). Polimer elektrolit membranlar (PEM), proton (H^+) veya hidroksit iyonu (OH^-) ileten polimer bazlı membranlar olup, özellikle polimer elektrolit membran yakıt hücrelerinde (PEMYH) ve elektrolizörlerde kullanılır. Nafion, yüksek proton iletkenliği ve kimyasal kararlılığıyla en yaygın PEM malzemesidir, ancak yüksek maliyeti ve nem bağımlılığı sınırlamalardır (Erdem, 2005). Hidrokarbon bazlı membranlar, örneğin sPEEK, maliyet avantajı sunarken kimyasal stabilite açısından geride kalabilir (Çelik & Bozkurt, 2020). Seramik bazlı membranlar, katı oksit yakıt hücrelerinde (SOFC) oksijen iyonu (O^{2-}) iletimi için kullanılır ve yüksek sıcaklıklarda ($600-1000^\circ C$) çalışabilir, bu da onları sabit enerji sistemleri için ideal kılar. Kompozit membranlar, polimer ve inorganik malzemelerin (ör. silika, alümina) kombinasyonu ile su tutma kapasitesini ve termal stabiliteyi artırır. (Şekil 4.7)



Şekil 4.7. Elektrolit Membran

4.3.1.2 Gaz difüzyon tabakası


Gaz difüzyon tabakası (GDL), polimer elektrolit membran yakıt hücrelerinde (PEMYH) membran-elektrot düzeneğinin temel bir bileşenidir ve reaktant gazların (hidrojen ve oksijen) katalizör tabakasına ulaşmasını, elektron iletimini, su yönetimini ve mekanik stabiliteyi sağlar (Cindrella et al., 2009). GDL, genellikle karbon bazlı gözenekli bir yapıya sahiptir ve katalizör tabakası ile gaz akış kanalları arasında yer alır (Park et al., 2012). Bu tarama, GDL'nin yapısal özellikleri, malzemeleri, su yönetimi, son gelişmeler ve gelecek yönelimlerini kapsamaktadır. (Şekil 4.8)



Şekil 4.8. Yakıt pili bileşenleri


4.3.2. Fosforik asit yakıt pili (PAFC)

Fosforik Asit Yakıt Pili (PAFC), fosforik asit elektrolit kullanarak kimyasal enerjiyi elektrik enerjisine dönüştüren bir yakıt pili teknolojisidir. 150-220°C sıcaklıklarda çalışır, platinyum katalizörle yüksek verimlilik sağlar ve sabit enerji üretim sistemlerinde (örneğin, hastaneler, veri merkezleri) yaygın olarak kullanılır. PAFC teknolojisi, verimlilik artışı, maliyet azaltımı, dayanıklılık ve çevresel etkiler üzerine yapılan araştırmalarla önemli bir yer edinmiştir. PAFC'lerin %40-41 elektrik üretim verimliliğini artırmak için elektrolit matrisinin stabilitesini iyileştiren yeni malzemeler önerdi. Çalışma, yüksek sıcaklık toleransı ve katalizör optimizasyonuna odaklandı (Sammes v.d, 2004). Oluşan reaksiyon aşağıdaki gibi olmaktadır.



PAFC'lerin çevresel etkilerini değerlendiren kapsamlı bir yaşam döngüsü analizi yayımlandı. Bu çalışma, PAFC sistemlerinin üretim, işletme ve imha aşamalarındaki çevresel etkilerini fosil yakıtlı sistemlerle (örneğin, kömür ve doğalgaz santralleri)

karşılaştırdı. Bulgular, PAFC'lerin karbon dioksit (CO₂) emisyonlarını %30-40 oranında azalttığını ve yenilenebilir enerji kaynaklarıyla (örneğin, biyogaz) entegre edildiğinde daha düşük çevresel ayak izine sahip olduğunu gösterdi. Ayrıca, çalışmada PAFC'lerin enerji üretiminde yüksek verimlilik sağladığı ve atık ısı geri kazanımıyla kombine ısı ve güç sistemlerinde kullanıldığında enerji kayıplarını azalttığı vurgulandı., PAFC'lerin üretiminde kullanılan platinyum gibi nadir metallerin çevresel etkilerini ve geri dönüşüm süreçlerinin önemine dikkat çekti. PAFC'lerin düşük emisyonlu enerji üretiminde fosil yakıtlı sistemlere kıyasla avantajlı olduğunu ortaya koyarak, enerji politikaları ve çevre dostu teknolojiler üzerine yapılan tartışmalara katkı sağladı (Pehnt, 2001). (Şekil 4.9)




Şekil 4.9. Fosforik Asit yakıt pilinin yapısı ve çalışma şekli

4.3.3. Doğrudan metanol yakıt pili (DMFC)

Bu yakıt pillerinde kullanılan membranın yapısı polimerdir ve kompakt basit yapılıdır. Çalışma sıcaklığı 50°C- 90°C olup bu sıcaklık aralığında %40-45 verimli çalışmaktadır. Anot kısmında çözelti şeklinde olan sıvı sulu metanol hidrojen gazının protonlarıyla polimer membrandan katot kısmına birlikte geçen çalışma prensibine sahiptir. Bu taşınma işlemi oluşurken anotta hidrojeninden kopmuş metanol karbondioksit döndü anot kısmından çıkar. Hidrojenin iyonları dış kısımdan bağlanmış olan teller




aracılığıyla anottan katoda geçiş yapar ve bunun sonucunda bir enerji açığa olur. (Şekil 4.10)




Şekil 4.10. Doğrudan metanol yakıt pilinin boyuna kesitindeki katmanlar

4.3.4. Alkali yakıt pili (AYP)

En eski ve en basit yakıt pilidir. NASA tarafından uzay uygulamalarında kullanılmıştır. %70'e varan verimlere ulaşabilirler. Bu tip yakıt pilinde elektrolit olarak potasyum hidroksit (KOH) kullanılır. İçerdiği KOH miktarına göre çalışma sıcaklığı değişir. %85 KOH içerenleri yüksek sıcaklıklarda (~250°C), %35–50 KOH içerenleri ise daha düşük (<120°C) sıcaklıklarda çalışır. Oluşan reaksiyon aşağıdaki gibi olmaktadır. (Şekil.11)









Şekil 4.11. Alkali yakıt pilinin yapısı ve çalışma şekli

4.3.5. Erimiş karbon yakıt pilleri (EKYP)

Erimiş Karbon Yakıt Pillerinde elektrolit olarak seramik matrikste Magnezyum oksit, lityum alüminyum oksit ve alüminyum oksit gibi alkali karbonatlar kullanılır. Yakıt pillerinin çalışma aralığı ise 600 -700 °C olup bu sıcaklıkta alkali karbonatlar yüksek iletkenliğe sahip erimiş tuz oluştururlar bu da karbonat iyonlarına yüksek iyonik iletkenlik sağlar. Elektrolitin içerisinde geçerek karbonat hidrojen ile birleşip karbondioksit ve su oluşturmaktadır. Bu yakıt pilinden alınan performans %50 verimdir. Kısımlar içerisindeki nikel erimiş karbonat yakıt pilinin yüksek sistem sıcaklığı sayesinde reaksiyonlar yeterli düzeyde artırılır. Oluşan reaksiyon aşağıdaki gibi olmaktadır. (Şekil 4.12)









Şekil 4.12. Erimiş karbonat yakıt pili çalışma şekli

4.3.5. Katı oksit yapıdaki yakıt pilleri (KOYP)

Katı oksit yapıdaki yakıt pili yakıttan doğrudan elektrik üreten, elektrokimyasal bir dönüşüm aygıtıdır. KOYP'nin elektrolit malzemesi katı oksit veya seramiktir. Seramik yakıt hücreleri, polimer esaslı olanlardan çok daha yüksek sıcaklıklarda çalışırlar. Çoğunlukla sabit uygulamalar için tasarlanmış olup 700-1000oC arası sıcaklıklarda çalışır ve 1- 2 kW arasında güç sağlarlar. Atık gazlar, elektriksel verimi artırmak için bir gaz türbinine gönderilir. Bu tür hibrid sistemlerde verim %70'lere kadar çıkabilir. Bu hücrelerde oksijen katı oksit elektrolit içinden geçerek anotta hidrojenle reaksiyona girer. Oluşan reaksiyon aşağıdaki gibi olmaktadır. (Şekil 4.13)





Şekil 4.13. Katı oksit yakıt pili çalışma şekli

5. PEM ELEKTROLİZÖRLERDE NEM DİNAMİKLERİ VE GDL TASARIMININ FLOODİNG ÜZERİNDEKİ ROLÜ

Proton Değişim Membran (PEM) elektrolizörlerde, uygulanan DC gerilimle suyun hidrojen ve oksijene ayrışması, sistemin nem koşullarına bağlıdır. Nem, proton iletkenliğini desteklerken, aşırı birikimi (flooding) gaz üretimini baltalar. Bu çalışmada, nemin etkisi analiz edilmiş, flooding'ın mekanizmaları incelenmiş ve Gaz Difüzyon Katmanı (GDL) tasarımının bu sorunu hafifletmedeki rolü değerlendirilmiştir. Optimum nemde maksimum verim elde edilirken, kuru veya suyla tıkanmış koşullar performansı düşürür. GDL'nin hidrofobik kaplamalar, gradyan gözenekler, mikrokanallar ve hibrit yapılarla optimize edilmesi, su yönetimini iyileştirerek flooding'ı önler (Babir,2005, Bakangura,2016). PEM elektrolizörler, yenilenebilir enerji entegrasyonunda hidrojen üretiminde kritik bir rol oynar. Sistemde su, anotta oksijen ve protonlara ayrışır ($2\text{H}_2\text{O} \rightarrow \text{O}_2 + 4\text{H}^+ + 4\text{e}^-$), protonlar membrandan katoda geçerek hidrojen oluşturur ($4\text{H}^+ + 4\text{e}^- \rightarrow 2\text{H}_2$). Bu süreçte nem, membranın iletkenliğini sağlarken, elektrotlarda su birikimi (flooding) gaz difüzyonunu engeller (Babir,2005). Nemlendirme, proton geçişini kolaylaştırırken, aşırı su gaz üretimini kısıtlar (Karanfil,2020). Bu bildiri, nemin gaz çıkışına etkisini, flooding'ın dinamiklerini ve GDL tasarım çözümlerini kapsamlı bir şekilde ele alır.

5.1. Nem ve Verim İlişkisi

PEM elektrolizörlerde nem, membranın proton iletkenliğini belirleyen temel unsurdur. Membran (örneğin Nafion), protonların (H^+) anottan katoda taşınması için suya ihtiyaç duyar; bu nedenle nem eksikliği iletkenliği azaltır ve gaz üretimini sınırlar (Bakangura, 2016). Optimum nem (%80-100 bağıl nem), proton hareketliliğini maksimize ederken, elektrotlarda su birikimi olmadan hidrojen ve oksijen çıkışını artırır (Karanfil, 2020). Ancak, nemin aşırılığı elektrotlarda “flooding”e yol açar ve gaz difüzyonunu engeller. Sıcaklık, nemin etkisini şekillendirir düşük sıcaklıklarda (40°C altı) su buharlaşmaz ve sıvı halde birikir; yüksek sıcaklıklarda (80°C üstü) ise nemlendirme yetersizse membran kurur, direnç artar ve verim düşer (Genç, 2018). En yüksek verim, $60\text{-}80^\circ\text{C}$ aralığında, sabit su beslemesi ve kontrollü nemlendirmeye elde

edilir. Örneğin, %90 nem seviyesinde proton iletkenliği optimumdur ve gaz üretimi %20'ye kadar artar (Dalğıç, 2019). Tersine, kuru membranlarda reaksiyon hızı %30'a kadar azalabilir (Barbir, 2005).

5.2.Flooding: Mekanizma ve Etkileri

Flooding, PEM elektrolizörlerde elektrotların veya GDL'nin aşırı suyla dolması sonucu gaz akışının kesintiye uğramasıdır. Bu durum, sistemin performansını ciddi şekilde baltalar ve hidrojen ile oksijen üretimini kısıtlar (Barbir, 2005). Flooding'in oluşumu, karmaşık bir dizi fiziksel ve kimyasal etkileşimin sonucudur:

5.2.1. Su birikiminin başlangıcı

Anotta su molekülleri oksijen, protonlar ve elektronlara ayrışır ($2H_2O \rightarrow O_2 + 4H^+ + 4e^-$). Üretilen oksijen gazı, GDL aracılığıyla tahliye edilir. Ancak, su girişi veya reaksiyon artıkları gözeneklerde birikirse, gaz çıkışı zorlaşır. Katotta ise protonlar hidrojen gazına dönüşür ($4H^+ + 4e^- \rightarrow 2H_2$); burada nemlendirme veya sıvı su birikimi flooding'i tetikleyebilir (Bakangura2016). Yüksek akım yoğunluklarında su üretimi artar ve bu risk yükselir (Karanfil, 2020).

5.2.2.Gözenek tıkanması ve difüzyon engeli

GDL'nin karbon fiber bazlı gözenekli yapısı, gazların katalizör yüzeyine ulaşmasını sağlar. Su, gözenekleri doldurduğunda, oksijen ve hidrojen difüzyon yolları kapanır. Bu, katalizör yüzeyindeki aktif bölgelerin gazlarla temasını keser ve reaksiyon oranını düşürür. Bir çalışmada, flooding'in gaz difüzyon katsayısını %40 azalttığı rapor edilmiştir (Dalğıç, 2015). Kapiler kuvvetler, suyun gözeneklerde tutulmasını şiddetlendirir (Barbir, 2005).

5.2.3.Elektriksel ve mekanik etkiler

Flooding, iç direnci artırır çünkü su birikimi protonların membrandan geçişini zorlaştırabilir. Katotta su, hidrojen saflığını etkileyerek basınç dalgalanmalarına neden

olur (Genç, 2018). Mekanik olarak, uzun süreli flooding GDL'nin yapısını bozabilir; gözenekler çökebilir veya katalizör tabakası ayrılabilir (Bakangura, 2016).

5.2.4.Koşullara bağlı görülme sıklığı

Düşük sıcaklıklar (40°C altı) suyun buharlaşmasını yavaşlatır ve birikimi artırır. %100 nem, su yoğunlaşmasını tetikler. Düşük gaz akış hızları, suyu tahliye edemez ve flooding'ı hızlandırır. Yüksek akım yoğunluklarında ise su üretimi tahliye kapasitesini aşar (Karanfil, 2020). Flooding, gaz üretimini %20-30 düşürebilir ve sistem kararlılığını bozabilir (Dalğış, 2019).

5.3.GDL Tasarımı ile Flooding'in Azaltılması

GDL, gaz difüzyonunu ve su tahliyesini dengeleyen bir bileşendir. Flooding'i önlemek için GDL tasarımı, su yönetimi ile gaz geçişi arasında optimize edilmelidir. Aşağıda yenilikçi yaklaşımlar detaylandırılmıştır:

5.3.1.Hidrofobik Yüzey Kaplamaları

Mekanizma PTFE kaplamalar, suyun gözeneklere nüfuzunu engeller. Su damlacıkları, yüzey geriliminden dolayı tutunamaz ve tahliye kanallarına kayar (Barbir, 2005). PTFE oranı %20-30 arasında optimize edilir, fazlası gaz difüzyonunu kısıtlar. Avantajları flooding kayıpları %15-25 azalır ve gaz yolları açık kalır (Dalğış, 2019).

5.3.2.Gradyan Gözenek Yapısı

Mekanizma katalizöre yakın küçük gözenekler (5-10 μm) gaz akışını, dıştaki büyük gözenekler (50-100 μm) su tahliyesini optimize eder (Bakangura, 2016). Su, kapiler hareketle dışa yönelir. Avantajları su birikimi %30 azalır, gaz difüzyonu artar (Genç, 2018).

5.3.3. Mikrokanal Sistemleri

Mekanizma 20-50 µm genişliğinde mikrokanallar, suyu tahliye çıkışlarına yönlendirir. Kanal düzeni, tahliye hızını optimize eder (Karanfil, 2020). Avantajları gaz üretimi %20 artar, flooding önlenir (Dalğış, 2019).

5.3.4. Hibrit malzeme entegrasyonu

Mekanizma grafen veya karbon nanotüpler, GDL'yi hidrofobik ve iletken yapar. Grafen suyu iter, nanotüpler yapıyı güçlendirir (Genç, 2018). Avantajları su tahliyesi %10-20 iyileşir, iletkenlik artar (Bakangura, 2016).

5.4. Grotthuss Mekanizması ile İlgili Araştırma ve Bildiri ile Bağlantı

Grotthuss mekanizması, Theodor Grotthuss tarafından 1806'da önerilen ve protonların (H^+) su molekülleri arasında hidrojen bağı ağı üzerinden sıçrama (proton hopping) yoluyla iletimini tanımlayan bir modeldir (Agmon, 1995). PEM elektrolizörlerde, bu mekanizma protonların membrandan katoda geçişini açıklar. Mekanizma, su moleküllerinin protonu kabul edip bir diğerine aktarması ile işler; bu, H_3O^+ (hidronyum iyonu) gibi ara yapıların oluşumunu içerir (Bakangura, 2016). Bildiride, nemin proton iletkenliğini artırması ve optimum nemin verimi maksimize etmesi, Grotthuss mekanizmasının temel prensipleriyle uyumludur. Ancak, flooding durumunda aşırı su, bu sıçrama sürecini engelleyerek gaz difüzyonunu kesintiye uğratar (Dalğış, 2019). Araştırmalar, Grotthuss mekanizmasının iki ana formunu öne sürer: Eigen katyonu ($H_9O_4^+$) ve Zundel katyonu ($H_5O_2^+$). Bu yapılar arasında geçiş, proton iletiminin dinamiklerini belirler. Bildirideki “nem eksikliği iletkenliği azaltır” ifadesi, Grotthuss mekanizmasının su molekülleri olmadan işleyemeyeceğini destekler (Barbir, 2005).

5.4.1. Eigen katyonun ($H_9O_4^+$) tanımı ve yapısı

Eigen katyonu, bir hidronyum iyonunun (H_3O^+) üç ek su molekülü ile hidrojen bağları aracılığıyla çevrelenmesiyle oluşan $H_9O_4^+$ yapısıdır. Merkezdeki H_3O^+ , protonun bir su molekülüne bağlanmasıyla oluşur ve bu yapı, çevresindeki üç H_2O molekülü ile

simetrik bir tetrahedral düzen oluşturur (Kreuer, 1996). Hidrojen bağlarının uzunluğu yaklaşık 2.5-2.8 Å'dir (Bakangura, 2016). Kimyasal gösterim: $\text{H}_3\text{O}^+ \cdot 3\text{H}_2\text{O}$. Eigen katyonu, suyun yoğun olduğu ortamlarda protonun stabilize olduğu bir durumdur. Proton, bir su molekülüne bağlanarak H_3O^+ oluşturur; ardından çevredeki su molekülleri bu yapıyı koordine eder. Bu, Grotthuss mekanizmasında protonun “yerleşik” bir ara hali olarak tanımlanır (Marx, 1999). Moleküler dinamik simülasyonları, Eigen katyonunun yüksek nemde baskın olduğunu gösterir (Kreuer, 1996). Eigen katyonu, protonun sıçramadan önceki kararlı bir konfigürasyonudur. Hidrojen bağlarının simetrisi, protonun çevrede eşit dağılımını sağlar, ancak sıçrama için bir bozulma gereklidir (Bakangura, 2016). Bildirideki yüksek nem koşullarında (%80-100) proton iletkenliğinin artması, Eigen katyonunun oluşumunu destekler (Barbir, 2005). Ancak, flooding bu yapının gaz difüzyonunu engelleyecek şekilde gözenekleri tıkayabilir (Dalğıç, 2019). Kızılötesi spektroskopi, Eigen katyonunun O-H gerilme frekanslarını ($2500\text{-}3000\text{ cm}^{-1}$) tespit etmiştir (Kreuer, 1996). Teorik modeller, bu yapının Zundel katyonuna göre daha kararlı olduğunu gösterir (Marx, 1999).

5.4.2. Zundel katyonun (H_5O_2^+) tanımı ve yapısı

Zundel katyonu, bir protonun iki su molekülü arasında paylaşıldığı H_5O_2^+ yapısıdır. Proton, iki H_2O molekülü arasında bir hidrojen bağı köprüsü oluşturur ve bağı ortasında yer alır. Hidrojen bağı uzunluğu yaklaşık 2.4 Å'dir ve proton, iki oksijen atomu arasında simetrik salınır (Bakangura, 2016). Kimyasal gösterim: $\text{H}_2\text{O} \cdot \text{H}^+ \cdot \text{H}_2\text{O}$. Zundel katyonu, protonun iki su molekülü arasında hızlı geçiş yaptığı dinamik bir ara durumdur. Grotthuss mekanizmasında proton sıçramasının “geçiş” hali olarak tanımlanır (Kreuer, 1996). Protonun konumu termal titreşimlerle değişir, bu da Zundel katyonunu daha az kararlı ancak daha mobil yapar (Marx, 1999). Orta nem seviyelerinde (%50-80) baskındır (Barbir, 2005). Zundel katyonu, protonun su molekülleri arasında doğrudan sıçramasını sağlar. Bildirideki optimum nemde proton hareketliliğinin maksimize olması, Zundel katyonunun katkısını yansıtır (Karanfil, 2020). Nem azaldığında su molekülleri arasındaki ağ kopar ve iletim durur; aşırı nemde ise flooding bu yapıları bozar (Dalğıç, 2019). Raman spektroskopisi, Zundel katyonunun O-H titreşimlerini ($1200\text{-}1700\text{ cm}^{-1}$) tespit etmiştir (Marx, 1999). Simülasyonlar, Zundel ve Eigen katyonları arasında düşük enerji bariyeriyle (2-3 kcal/mol) geçiş olduğunu doğrular (Kreuer, 1996).


6. MATERYAL METOD

Bu çalışmada, bir PEM (Proton Değişim Membranlı) yakıt hücresi sistemi kullanılarak gerçekleştirilen deneysel bir süreci kapsamaktadır. Deneyde, belirli bir akım altında hidrojen ve oksijen gazlarının üretimi izlenmiş, her saniyede gazların kütlesi ve hacmi ayrı ayrı ölçülmüştür. Ayrıca sistemde kullanılan elektrolit miktarı (KOH), saf su miktarı ve toplam çözelti kütlesi gibi başlangıç girdileri de detaylı biçimde kaydedilmiştir. Deney süresince ortam sıcaklığı, maksimum sıcaklık ve ortam nem oranı gibi çevresel koşullar da izlenmiş, sistemin voltajı ve çalışma süresi boyunca oluşan değişimlerle birlikte değerlendirilmiştir. Deney sonunda sistemde kalan çözeltinin ağırlığı ölçülerek çözeltide meydana gelen azalma hesaplanmış ve bu verilerden çözünme yüzdesi elde edilmiştir. Böylece sistemdeki buharlaşma, elektroliz gibi kayıplar da dikkate alınarak toplam verimlilik değerlendirilmiştir. Aynı zamanda sıcaklık ve nem gibi çevresel değişkenlerin hidrojen ve oksijen üretimine olan etkisi de analiz edilmek üzere not edilmiştir. Elde edilen bu detaylı ölçüm ve gözlemlerle, PEM yakıt hücresi sisteminin verimi, çevresel duyarlılığı ve performans karakteristikleri çok boyutlu olarak değerlendirilmiştir. Bu çalışmada, farklı oranlarda hazırlanan çözeltilerle gerçekleştirilen PEM yakıt hücresi deneylerinden elde edilen veriler kullanılarak, sistem akımına bağlı olarak üretilen hidrojen (Volume H₂) ve oksijen (Volume O₂) gaz hacimlerinin tahmini amaçlanmıştır. Deneysel verilerde, sistem akımı sabit tutularak farklı çözeltilik kompozisyonlarında gaz üretim miktarları ölçülmüş ve bu ölçümler makine öğrenmesi algoritmaları ile modellenmiştir. Modelleme sürecinde, bağımsız değişken olarak sistem akımı kullanılmış ve bağımlı değişkenler olarak hidrojen ve oksijen hacimleri ayrı ayrı değerlendirilmiştir. Her bir gaz türü için tahminsel modeller oluşturulmuş, böylece iki farklı regresyon problemi çözülmüştür. Tahminleme performanslarını karşılaştırmak amacıyla beş farklı makine öğrenmesi algoritması uygulanmıştır: Random Forest Regressor, K-Nearest Neighbors (KNN), Linear Regression, Decision Tree Regressor ve Gradient Boosting Regressor. Bu algoritmalar, deneysel veriler üzerinde eğitilmiş ve test edilmiştir. Modellerin başarı düzeylerini değerlendirebilmek için dört farklı regresyon metriği kullanılmıştır: Determinasyon katsayısı (R²), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Hata (MAE). Bu metrikler aracılığıyla hem doğruluk hem de hata dağılımı yönünden her bir yöntemin performansı karşılaştırmalı olarak analiz edilmiştir. Elde edilen bulgular, gaz üretim miktarlarının

yalnızca sistem akımına bağlı olarak tahmin edilebilirliğini ve farklı algoritmaların bu tahmin performansındaki katkı düzeyini ortaya koymaktadır.

6.1. PEM Yakıt Hücresi Deney Düzeneği

PEM yakıt hücresinden hidrojen ve oksijen üretmek için tasarlanan deney düzeneğine hassas terazi ile ölçülen saf su ve aynı şekilde hassas terazi ile ölçülen KOH çözeltisinin, sabit 12 Volt doğru akım üreten güç kaynağı ile elektrolizi sistem performansını analiz etmek için Şekil 6.14'te görünen çalışma düzeneğinin tasarım gösterilmektedir. Deney süresi 120 dakika ile sabit tutulmuş olup 1 litre saf suyun içerisine 5gr, 7,5gr, 10gr, 12,5gr, 15gr, 17,5gr, 20gr, 22,5gr, 25gr, 27,5gr, 30gr, 32,5gr ve 35gr KOH eklenerek iletkenlik arttırılmış sulu çözelti oluşturulmuştur. Her bir KOH değeri için ayrı ölçümler ve analizleri ayrı yapılmıştır. Neopran conta malzemesi konarak üretilen üst üste 11 adet 1 mm kalınlık ve 120*160 mm ebadında çelik sacın arasına 2 mm kalınlığında, dikdörtgen şeklinde olan yakıt hücresinin eni 53 mm, boyu 142 mm, yüksekliği ise 190 mm'dir. Yakıt hücresinin dış yöne konumlandırılmış 1 adet giriş, 2 adet çıkış olmak üzere 3 adet başlık çıkarılmıştır. Başlık ebadı 8mm olan esnek, şeffaf plastik hortumlar vasıtasıyla su ve gaz alışverişi gerçekleşmektedir. Yakıt piline enerji verilmesi ile hidrojen ve oksijen tanklarından yakıt piline su gelirken, yakıt pilinden de tanklara suyla karışık hidrojen ve oksijen gaz akışı sirküle edilmektedir. Kapalı sistem olarak oluşturulan sisteminde su, tankların altında bulunan uçtan yakıt piline tekrar akmakta ve sirküle edilen su tekrar kullanılmaktadır. Böylece sisteme ilave edilecek ek bir depo yapılmasına gerek kalmadığı gibi ek maliyetin oluşması da engellenmiştir. Sistem performansını analiz etmek için her saniye için sistemin çekmiş olduğu amper değeri kaydedilmiş toplamda 7200 saniye için ayrı arı veri kayıtları edilmiştir. Her saniye alınan amper değeri için üretilen hidrojen ve oksijen miktarlarının yapay zekâ yardımı ile hacimsel ve kütleli değerleri belirlenmiş olup yapay zekâ optimizasyonu ile veriler işlenmiştir.



Şekil 6.14. PEM çalışma düzeneği tasarımı

6.1.1. Deneyde kullanılan malzemeler

Dikdörtgen şeklinde şeffaf plastik malzemeden üretilen hidrojen tankı içinde bulunan suyun seviyesini ve türünü görmek için şeffaf malzemeden yapılmıştır. Hidrojen tankının boyutu yaklaşık olarak eni 60 mm, boyu 105 mm, yüksekliği 180 mm kadardır. Şekil 6.15’te hidrojen tankının görseli gösterilmektedir. Hidrojen tankının alt kısmında yakıt piline suyun akmasını sağlayan uç, sirkülasyon için ise üst kısmında iki adet uç bulunmaktadır. Hidrojen tankının uçlarından birincisine yakıt pilinden su ile karışık hidrojen gazı gelmektedir. Tank içerisinde belirli seviyeye kadar kimyasal madde ile iletkenliği arttırılmış saf su, geri kalan kısmında ise hidrojen gazı bulunmaktadır. Böylece yakıt pilinden gelen nemli gazın çözeltisi aşağı inip suya karışırken gaz kısmı ise yukarıda kalmaktadır. Üst kısımda biriken hidrojen gazı ise uç kısmından atmosfere bırakılmaktadır.



Şekil 6.15. Hidrojen tankı

Silindir şeklinde şeffaf cam malzemeden üretilen oksijen tankı, içinde bulunan suyun seviyesini ve türünü görmek için şeffaf cam malzemeden yapılmıştır. Oksijen tankının çapı 40 mm, yüksekliği ise 190 mm dir. Şekil 6.16’da oksijen tankının görseli gösterilmektedir. Üst kısımda yer alan ilk çıkış ucunun görevi, yakıt pilinden ayrılan nemli ve sulu oksijen gazının tanka ulaşmasını sağlamaktır. Böylece tankın içinde belirli bir seviyeye kadar su bulunurken diğer bölümde ise oksijen gazı bulunur. Oksijen tankının son ucunun görevi ise ayrılan oksijen gazının atmosfere bırakmasıdır. Oksijen tankındaki bu durum, hidrojen tankındaki duruma benzemektedir. Oksijen tankı ve hidrojen tankının arasında sadece çözelti su ve üretilen gazların akışını sağlayan plastik hortum bağlantıları vardır. Herhangi bir elektriksel veya mekaniksel bağlantı mevcut değildir.



Şekil 6.16. Oksijen tankı

Deney için özel olarak tasarlanan 0-20 volt aralığında ayarlanabilen doğru akım üreten maksimum 20 amper seviyesinde güç üreten güç kaynağını Şekil 6.17’de görülmektedir. Sistem içerisinde sadece yakıt pilinin artı (+) ve eksi (-) uçlarına bağlı olan çıkış uçları aynı zamanda deney sistemine montajı yapılmış olan volt ampermetre ile seri bağlanmıştır. Şekil 6.18’de volt ampermetrenin görseli gösterilmektedir.




Şekil 6.17. Ayarlanabilir güç kaynağı




Şekil 6.18. Volt ampermetre

Deney sisteminde kullanılan, her gramı hassas terazi ile ölçülen potasyum hidroksitin saflık seviyesi ve etiket değeri Şekil 6.19’da gösterilmektedir.



Şekil 6.19. Potasyum Hidroksit

Deney sistemine eklenecek olan saf su ve KOH miktarlarının ölçümü için 3 kilogramlık kapasiteli, 0,1 gramlık hassasiyete sahip olan dijital göstergeli hassas terazi kullanılmış olup görseli Şekil 6.20’de gösterilmektedir.



Şekil 6.20. Hassas terazi

6.2. Makine Öğrenmesi Metotlar

6.2.1. Random forest regressor

Random Forest Regressor, gözetimli öğrenme problemlerinde kullanılan bir topluluk (ensemble) öğrenme yöntemidir ve özellikle regresyon ve sınıflandırma görevlerinde yüksek doğruluk ve genelleme başarımı ile öne çıkar. Bu yöntem, temelinde Karar Ağaçları (Decision Trees) bulundurmakta olup, Bootstrap Aggregation (Bagging) tekniğini kullanarak birden fazla karar ağacının oluşturulması ve bu ağaçların sonuçlarının ortalaması alınarak tahminin gerçekleştirilmesi prensibine dayanır. Random Forest, model varyansını azaltırken aşırı öğrenmeyi (overfitting) önleyerek daha stabil ve güvenilir tahminler yapılmasına olanak tanır. Random Forest'ta her bir karar ağacı, eğitim verisinin rastgele seçilmiş bir alt kümesi (bootstrap örnekleme) kullanılarak eğitilir. Her ağaç için örnekleme işlemi şu şekilde ifade edilir (El Mrabet ve ark., 2022)

$$D_b = \{(x_i, y_i)\}_{i=1}^n, \text{ burada } D_b \subset D, b = 1, 2, \dots, B \quad (6.1)$$

Burada D : Orjinal veri seti, B : toplam karar ağaç sayısı, D_b : b -inci karar ağacına ait bootstrap alt kümesini belirtir. Her bir alt küme ile eğitilen karar ağacı, veri üzerinde bağımsız olarak öğrenme yapar. Her karar ağacı düğümünde, ayırım (split) işlemi için rastgele seçilen bir öznelilik alt kümesi göz önüne alınır. Bu, korelasyonlu ağaçların oluşumunu engeller ve model çeşitliliğini artırır. Düğümlerdeki ayırım ölçütü genellikle MSE (Mean Squared Error) minimizasyonudur (Khalyasmaa ve ark., 2019).

$$MSE_{split} = \frac{1}{N_L} \sum_{i \in L} (y_i - \bar{y}_L)^2 + \frac{1}{N_R} \sum_{i \in R} (y_i - \bar{y}_R)^2 \quad (6.2)$$

Burada, L ve R : Sol ve sağ düğümler, N_L , N_R : Sol ve sağ düğümlerdeki örnek sayısı, $\bar{y}_L$ ve $\bar{y}_R$ Düğümlerdeki hedef değişkenin ortalamalarını belirtir. Regresyon problemlerinde Random Forest, tüm ağaçların çıktılarının aritmetik ortalamasını alarak nihai tahmini üretir:

$$f(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (6.3)$$

Burada $f(x)$: Random Forest tarafından yapılan tahmin, $T_b(x)$ b -inci karar ağacının x girdisi için yaptığı tahmini belirtir.

6.2.2. K-Nearest neighbors (KNN)

K-Nearest Neighbors (KNN), denetimli öğrenme sınıfında yer alan hem sınıflandırma hem de regresyon problemlerinde kullanılan, parametresiz (non-parametric) ve örnek tabanlı (instance-based) bir makine öğrenmesi yöntemidir. Özellikle KNN Regressor, verilen bir giriş örneğine karşılık en yakın komşulara bakarak sürekli (sayısal) hedef değişken değerinin tahmin edilmesini amaçlar. Bu yöntemin temel varsayımı, benzer girdilerin benzer çıktılar üreteceği prensibine dayanır. Modelin eğitimi sırasında herhangi bir öğrenme (parametre güncellemesi) yapılmaz; tüm öğrenme, tahmin sırasında gerçekleşir (lazy learning) (Imandoust ve ark., 2013). KNN regresyonda bir gözlem $x \in R^d$ için hedef değer tahmini, x 'e en yakın k komşunun hedef değerlerinin ortalaması alınarak yapılır. Bu komşuluk, genellikle öklidyen mesafe ile belirlenir.

$$\hat{y}(x) = \frac{1}{k} \sum_{i \in N_k(x)} y_i \quad (6.4)$$

Burada;

$\hat{y}(x)$: Gözlem x için tahmin edilen değer,

$i \in N_k(x)$: x 'e en yakın k komşunun indeks kümesi,

y_i : i -inci komşunun hedef değerini belirtir.

KNN'nin başarımı büyük ölçüde kullanılan mesafe ölçütüne bağlıdır. En yaygın olanlar (Yıldız ve Karabağ, 2025).

Öklidyen Mesafe:

$$d(x, x') = \sqrt{\sum_{j=1}^d (x_j - x'_j)^2} \quad (6.5)$$

Manhattan (L1) Mesafesi:

$$d(x, x') = \sum_{j=1}^d |x_j - x'_j| \quad (6.6)$$

Minkowski Mesafesi (genel form):

$$d(x, x') = \left(\sum_{j=1}^d |x_j - x'_j|^p \right)^{1/p} \quad (6.7)$$

Bazı durumlarda, daha yakın komşulara daha yüksek ağırlık verilerek daha doğru tahmin yapılabilir. Bu durumda tahmin formülü şu hale gelir:

$$\hat{y}(x) = \frac{\sum_{i \in N_k(x)} w_i y_i}{\sum_{i \in N_k(x)} w_i} \quad (6.8)$$

Ağırlıklar genellikle mesafenin tersine bağlı olarak atanır.

$$w_i = \frac{1}{d(x, x_i) + \epsilon} \quad (6.9)$$

K-Nearest Neighbors (KNN) algoritması, bazı temel özellikleriyle diğer regresyon yöntemlerinden ayrılır. Öncelikle, parametresiz bir yöntemdir; bu nedenle modelin eğitim sürecinde herhangi bir parametre güncellemesi yapılmaz ve öğrenme süreci test aşamasında gerçekleşir. Bu yapı, modeli "tembel öğrenme" (lazy learning) kategorisine sokar. Ancak bu avantaj, tahmin sırasında daha yüksek hesaplama maliyetine neden olur. KNN, veri yoğunluğuna oldukça duyarlıdır; veri dağılımının seyrek olduğu bölgelerde genelleme yeteneği azalır ve model güvenilir tahminler üretemeyebilir. Bu nedenle, eğitim verisinin temsili ve yoğunluğu, model performansı açısından kritiktir. Bununla birlikte, KNN algoritması aykırı değerlere ve veri ölçeğine karşı hassastır. Özellikle öznitelikler farklı ölçeklerdeyse, büyük değerli özellikler mesafe hesaplamasında daha baskın hale gelir; bu da modelin dengesiz kararlar vermesine neden olabilir. Bu yüzden veri normalizasyonu, KNN için genellikle zorunlu bir ön işlem adıdır. KNN'nin doğruluk-karmaşıklık dengesi, seçilen k değeri ile doğrudan ilişkilidir: Küçük k değerleri daha düşük önyargı (bias) ama yüksek varyans üretirken, büyük k değerleri daha yüksek önyargı fakat daha düşük varyans ile daha stabil sonuçlar verir. Son olarak, KNN yöntemi boyutsallık laneti (curse of dimensionality) problemine açıktır; veri boyutu arttıkça örnekler arasındaki mesafeler anlamsızlaşır ve yakın komşuların seçimi zorlaşır, bu da performans düşüşüne neden olur. Bu nedenlerle KNN, dikkatli öznitelik seçimi ve ön işleme adımları gerektiren, sezgisel olarak güçlü fakat hesaplama açısından maliyetli bir yöntemdir.

6.2.3. Linear regresyon

Lineer regresyon, en temel ve en yaygın kullanılan regresyon modellerinden biridir. Temel amacı, bir ya da birden fazla bağımsız değişken kullanarak sürekli bir bağımlı değişkeni tahmin etmektir. Bu yöntem, bağımlı değişken ile bağımsız değişkenler

arasındaki ilişkiyi doğrusal bir denklem ile modellemeye çalışır. Lineer regresyon hem yorumlana bilirlik hem de uygulama kolaylığı açısından makine öğrenmesinde temel bir başlangıç noktasıdır. En basit haliyle tek değişkenli (simple linear regression) model şu şekilde ifade edilir (Uyanık ve Güler, 2013).

$$\hat{y} = \beta_0 + \beta_1 x \quad (6.10)$$

Burada;

$\hat{y}$: Tahmin edilen hedef değişken (bağımlı değişken),

x : Girdi (bağımsız değişken),

β_0 : Y-intercept (kesişim noktası),

β_1 : Doğrunun eğimi (slope)

β_0 ve β_1 modelin öğrenilmesi gereken parametrelerdir.

Çoklu değişkenli (multiple linear regression) durumda model aşağıdaki hale gelir.

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p = x^T \beta \quad (6.11)$$

Veya matris gösterimiyle:

$$\hat{y} = X\beta \quad (6.12)$$

Burada $\hat{y}$: Tahmin edilen hedef değişken vektörü, X : Girdi veri matrisi (her satır bir örnek, ilk sütun genellikle sabit 1'lerden oluşur) ve β : Modelin katsayı vektörünü belirtir. Modelin öğrenme süreci, tahmin edilen değerler ile gerçek değerler arasındaki farkı minimize etmek üzerine kuruludur. En yaygın kullanılan kayıp fonksiyonu, En Küçük Kareler (Ordinary Least Squares – OLS) yöntemine dayanır (Şahinler, 2000).

$$L(\beta) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \|y - X\beta\|^2 \quad (6.13)$$

Bu fonksiyonun minimum değeri, β katsayılarının kapalı formda (analitik) çözümüyle bulunabilir.

$$\beta = (X^T X)^{-1} X^T y \quad (6.14)$$

Bu formül $X^T X$ matrisinin tersinin alınabildiği durumlarda geçerlidir. Aksi halde, regülerizasyon gibi yöntemler devreye girer. Lineer regresyon modelinin güvenilir ve geçerli sonuçlar verebilmesi için belirli istatistiksel varsayımların sağlanması

gerekmektedir. Öncelikle, modelin temel varsayımı olan lineerlik koşulu sağlanmalıdır; bu, bağımsız değişkenlerle bağımlı değişken arasında doğrusal bir ilişki bulunduğu anlamına gelir. Ayrıca, model tarafından yapılan tahminler ile gerçek değerler arasındaki farklar, yani artık terimler (residuals), normal dağılıma sahip olmalıdır. Bu varsayım, parametrik testlerin geçerliliği açısından önemlidir. Bir diğer kritik varsayım, hataların sabit varyansa (homoscedasticity) sahip olmasıdır; bu da tüm gözlemlerde hata terimlerinin benzer varyansa sahip olduğunu ve sistematik bir sapmanın bulunmadığını ifade eder. Modelin doğruluğunu etkileyebilecek bir başka unsur ise çoklu doğrusal bağlantı (multicollinearity) problemidir. Bağımsız değişkenler birbirleriyle yüksek korelasyona sahipse, model katsayılarının güvenilirliği azalır ve tahminler kararsız hale gelir. Bu durum, özellikle yorumlanabilirlik açısından sorun teşkil eder. Son olarak, modelin tahmin gücünün korunabilmesi için gözlemler arasında bağımsızlık sağlanmalıdır; yani bir gözlemdaki hata, diğer gözlemlerle ilişkili olmamalıdır. Bu beş temel varsayımın sağlanması, lineer regresyon modelinin istatistiksel geçerliliğini artırır ve elde edilen sonuçların güvenilirliğini teminat altına alır.

6.2.4. Decision tree regressor

Decision Tree Regressor (Karar Ağacı Regresyonu), verileri ağaç yapısı şeklinde dallara ayırarak sürekli hedef değişkenleri tahmin etmeye yönelik, sezgisel ve esnek bir makine öğrenmesi yöntemidir. Modelin temel amacı, veri kümesini farklı bölgelere ayırarak her bölge için en iyi sabit tahmini (genellikle ortalama değer) sağlamaktır. Karar ağacı regresyonu, doğrusal olmayan ilişkilerle başa çıkabilmesi, yorumlana bilirliği ve veri ön işleme ihtiyacının azlığı nedeniyle özellikle mühendislik uygulamalarında yaygın biçimde kullanılmaktadır. Karar ağacı, kök düğümden başlayarak veri kümesini özniteliklere göre ikili dallara ayırır. Her düğümden, bir öznitelik ve bu öznitelik için bir eşik değeri belirlenir; bu sayede veri iki alt gruba bölünür. Bu süreç, belirli bir durma (durma kriteri) koşuluna kadar rekürsif olarak devam eder (Xu ve ark., 2005). Her bölünmede amaç, hedef değişkenin varyansını mümkün olduğunca azaltmaktır. Bu amaçla kullanılan ayırım ölçütü (impurity function) genellikle Mean Squared Error (MSE)'dir. Veri kümesini R olarak düşünelim. Eğer bu küme, bir öznitelik x_j ve eşik değeri t ile iki alt kümeye bölünüyorsa;

$$R_{left}(j, t) = \{(x, y) \in R: x_j \leq t\}, \quad R_{right}(j, t) = \{(j, t) \in R: x_j > t\} \quad (6.15)$$

Amaç, bu bölünmenin getirdiği toplam hata değerini minimize etmektir. Hata ölçütü genellikle MSE olup şöyle hesaplanır:

$$MSE_{split} = \frac{|R_{left}|}{|R|} Var(y_{left}) + \frac{|R_{right}|}{|R|} Var(y_{right}) \quad (6.16)$$

Burada $|R|$: Veri kümesindeki örnek sayısı, $Var(y) = \frac{1}{|R|} \sum_{i \in R} (y_i - \bar{y}R)^2$ Kümedeki hedef değişkenin varyansı ve $\bar{y}R$: Kümedeki ortalama hedef değerini belirtir. Model, tüm öznitelik ve eşik kombinasyonları arasında bu MSE değerini minimize eden bölünmeyi seçer. Her bir düğümde yukarıdaki işlem tekrarlanarak veri sürekli daha küçük kümelere ayrılır. Ağaç büyüdükçe, her yaprak düğüm (terminal node) kendi ortalama hedef değerini tahmin olarak döndürür (Czajkowski ve Kretowski, 2016).

$$\hat{y}_{leaf} = \frac{1}{|R_{leaf}|} \sum_{i \in R_{leaf}} y_i \quad (6.17)$$

Decision Tree Regressor yönteminin önemli avantajlarından biri, doğrusal olmayan ilişkileri etkili bir şekilde modelleyebilmesidir. Bu özelliği sayesinde, geleneksel lineer modellerin yetersiz kaldığı durumlarda daha esnek ve başarılı tahminler yapabilir. Ayrıca modelin yapısı ağaç biçiminde olduğu için kolayca yorumlanabilir ve görselleştirilebilir; bu da karar süreçlerinin şeffaf şekilde izlenmesini sağlar. Karar ağacı modelleri, özellik ölçeklendirmesi gerektirmez; yani giriş verilerinin normalizasyonu veya standartlaştırılması gibi ön işlemlere ihtiyaç duymaz. Buna ek olarak, belirli ölçüde eksik verilere karşı toleranslıdır ve bazı eksik değerlerin model performansını tamamen bozması engellenebilir. Bununla birlikte, Decision Tree modellerinin bazı belirgin dezavantajları da vardır. En büyük sorunlardan biri, özellikle derin ağaçlarda karşılaşılan aşırı öğrenme (overfitting) riskidir; model eğitim verisine çok iyi uyum sağlar ancak genelleme yeteneği zayıf olur. Ayrıca, karar ağaçları küçük veri değişikliklerine karşı hassastır; veri kümesinde yapılan küçük değişiklikler bile ağacın yapısını ciddi ölçüde değiştirebilir, bu da modelin istikrarsız olmasına neden olur. Son olarak, karar sınırları keskin ve kademeli biçimde oluştuğu için sürekli ve düzgün değişim gösteren verilerde doğruluğu sınırlı olabilir. Bu nedenle, özellikle sürekli değişen sistemlerde karar ağacı yerine daha yumuşak sınırlara sahip modellerin tercih edilmesi gerekebilir.

6.2.5. Gradient boosting regressor

Gradient Boosting Regressor, topluluk (ensemble) yöntemlerinden biridir ve tahmin hatalarını giderek azaltmak amacıyla ardışık olarak zayıf öğrencilerin (genellikle karar ağaçları) oluşturulması ve birleştirilmesi prensibine dayanır. Bu yöntem, her adımda kalan hataları (residual) modelleyerek genel modelin performansını iyileştirmeyi amaçlar. Gradient Boosting, özellikle karmaşık ve doğrusal olmayan ilişkiler içeren veri kümelerinde yüksek doğruluk elde etmesiyle öne çıkar. Regresyon görevlerinde oldukça güçlü sonuçlar üreten bu yaklaşım, istatistiksel öğrenme teorisi ile optimizasyon yöntemlerinin birleşimidir. Gradient Boosting, ardışık olarak MMM adet zayıf modelin (örneğin karar ağaçları) oluşturulmasıyla çalışır. Amaç, bu modellerin birleşimiyle daha güçlü bir tahmin modeli elde etmektir. Her adımda, mevcut modelin hatası analiz edilerek, bu hatayı en iyi düzeltecek yeni bir model eklenir. Bu işlem, gradyan inişi (gradient descent) ile kayıp fonksiyonun minimize edilmesi olarak yorumlanır (Keprate ve Ratnayake, 2017).

Tahmin fonksiyonu şu şekilde tanımlanır;

$$F_M(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (6.18)$$

Burada $F_M(x)$: M adet zayıf modelin toplamından oluşan nihai model, $h_m(x)$: m-inci zayıf model (örneğin küçük bir karar ağacı), γ_m : Bu modelin katkı oranı (öğrenme oranı ile ilişkilidir).

İlk model genellikle tüm örneklerin ortalamasını tahmin eder:

$$F_0(x) = \operatorname{argmin}(\gamma) \sum_{i=1}^n L(y_i, \gamma) \quad (6.19)$$

Örneğin kare hata (MSE) için bu, ortalama değeri verir (Peter ve ark., 2017).

$$F_0(x) = \bar{y} \quad (6.20)$$

Gradient Boosting yönteminde öğrenme süreci adım adım ilerleyen bir yapıdadır ve her iterasyonda modelin mevcut hatalarını azaltacak yeni bir zayıf öğrenci (örneğin küçük bir karar ağacı) eğitilir. Sürecin ilk aşamasında, mevcut modelin tahminleri ile gerçek değerler arasındaki farktan türetilen negatif gradyanlar hesaplanır. Bu gradyanlar, modelin her bir veri noktası için ne kadar hata yaptığını ve bu hatanın hangi yönde düzeltilmesi gerektiğini gösterir. Matematiksel olarak bu gradyanlar, kayıp

fonksiyonunun tahmin edilen değerlere göre türevlerinin negatifidir ve her iterasyon için ayrı ayrı hesaplanır. İkinci aşamada, elde edilen bu gradyan değerlerini tahmin etmeye çalışan yeni bir regresyon modeli eğitilir. Bu yeni model, önceki modelin hatalarını azaltmaya odaklanarak sistemin genel tahmin başarımını iyileştirir. Sonrasında, öğrenilen bu yeni modelin ne kadar katkı sağlayacağı belirlenir; bu işlem line search olarak adlandırılır ve optimal katkı katsayısı (γ_m) ile gerçekleştirilir. Bu katsayı, kayıp fonksiyonunu en fazla azaltacak şekilde seçilir. Son olarak, mevcut model bu katkı kadar güncellenerek yeni bir modele dönüştürülür. Güncellenmiş model, önceki model ile yeni zayıf modelin öğrenme oranı (η) ile çarpılmış hali kadar birleştirilmesinden oluşur. Bu öğrenme oranı, modelin aşırı öğrenmesini (overfitting) önlemek için genellikle küçük bir değer olarak ayarlanır. Gradient Boosting algoritması, regresyon problemlerinde farklı kayıp fonksiyonları ile uygulanabilir. En yaygın kullanılan kayıp fonksiyonu kare hata $L(y, \hat{y}) = \frac{1}{2}(y - \hat{y})^2$ olsa da uç değerlerin etkisini azaltmak için Huber Loss, medyana dayalı tahminlerde ise Quantile Loss gibi alternatif fonksiyonlar da tercih edilebilir. Bu esneklik, Gradient Boosting yöntemini sadece klasik regresyon problemleri için değil, aynı zamanda robust (sağlam) tahminleme gereken durumlar için de son derece uyarlanabilir ve güçlü bir araç haline getirir.

6.3. Performans Metrikleri

Bu çalışmada, regresyon modellerinin performansını değerlendirmek ve karşılaştırmak amacıyla dört farklı doğruluk ve hata ölçütü kullanılmıştır. Bu metrikler, her bir modelin tahmin başarımını hem mutlak hata miktarı hem de istatistiksel uygunluk açısından değerlendirmeye olanak tanır (Botchkarev , 2018; Pal ve ark., 2010).

6.3.1. Mean squared error (MSE)

İlk olarak kullanılan Ortalama Kare Hata (MSE), modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını alarak toplam hata büyüklüğünü yansıtır ve büyük hataları cezalandıran bir yapıya sahiptir. Bu metrik, aşağıdaki formülle ifade edilir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6.21)$$

6.3.2. Root mean squared error (RMSE)

MSE değerin karekökü alınarak elde edilen Kök Ortalama Kare Hata (RMSE) metriği ise, hatayı orijinal birimlere dönüştürerek yorumlamayı kolaylaştırır ve özellikle büyük hatalara karşı hassasiyet gösterir:

$$RMSE = \sqrt{MSE} \quad (6.22)$$

6.3.3. Mean absolute error (MAE)

Bir diğer önemli ölçüt olan Ortalama Mutlak Hata (MAE), her bir tahminin gerçek değerden ne kadar saptığını mutlak değer cinsinden ölçer ve ortalamasını alır. Bu metrik, uç değerlere karşı daha az duyarlıdır ve şu şekilde tanımlanır:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6.23)$$

6.3.4. Coefficient of determination (R^2)

Son olarak, modellerin açıklayıcılık düzeyini değerlendirmek amacıyla Belirleme Katsayısı (R^2) kullanılmıştır. Bu metrik, modelin toplam veri varyansının ne kadarını açıkladığını gösterir. R^2 değeri 1'e yaklaştıkça modelin başarımı artar.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (6.24)$$

Bu dört metrik birlikte kullanılarak, geliştirilen regresyon modellerinin hata düzeyleri ve açıklayıcılıkları çok yönlü bir biçimde incelenmiş, böylece en uygun modelin belirlenmesi hedeflenmiştir.

7. BULGULAR

Bu çalışmada, farklı oranlarda hazırlanmış deneysel çözeltilere ait sistem akımı değerleri kullanılarak, ortaya çıkan hidrojen (H_2) ve oksijen (O_2) gaz hacimlerinin tahmini amacıyla çeşitli regresyon modelleri eğitilmiştir. Girdi olarak yalnızca "Sistem Akımı" kullanılmış, hedef değişken olarak ise sırasıyla "Volume $H_2(L)$ " ve "Volume $O_2(L)$ " değerleri seçilmiştir. Bu hedeflerin tahmini için Random Forest, K-Nearest Neighbors (KNN), Linear Regression, Decision Tree ve Gradient Boosting Regressor olmak üzere beş farklı makine öğrenmesi algoritması uygulanmıştır. Her model, çözeltinin türüne (örneğin 5 gr KOH / 7200 sn deney süresi gibi) göre ayrı ayrı değerlendirilmiş ve tahmin başarımı, R^2 (determination coefficient), RMSE (Root Mean Squared Error), MSE (Mean Squared Error) ve MAE (Mean Absolute Error) metrikleri ile nicel olarak karşılaştırılmıştır. Elde edilen regresyon başarımları, her bir çözüm koşulunda ve model türünde sistematik olarak kayıt altına alınmış ve karşılaştırmalı analiz için Excel tablosu halinde sunulmuştur. Bu sonuçlar, hangi modelin hangi çözeltide daha başarılı tahminlerde bulunduğunu göstermek ve model seçiminde objektif bir temel sağlamak amacıyla aşağıda detaylı şekilde yorumlanmıştır. Çalışmada, farklı gramaj (gr) değerlerine sahip potasyum hidroksit (KOH) kullanılarak çeşitli derişimlerde çözeltiler hazırlanmıştır. Her bir çözelti, sistematik olarak belirli sürelerde deneysel olarak test edilmiştir. Bu çözeltilere karşılık gelen sistem akımı verileri kullanılarak, hidrojen (H_2) ve oksijen (O_2) gazlarının hacimsel üretim miktarları, makine öğrenmesi modelleri aracılığıyla tahmin edilmiştir. Her çözeltiye ait tahmin sonuçları hem H_2 hem de O_2 hacimleri için ayrı ayrı değerlendirilmiş ve ilgili regresyon modelleri kullanılarak hesaplanan tahmin performans metrikleri ile aşağıdaki Tablo 1- Tablo 13 arasındaki tablolarda sunulmuştur. Böylece, farklı derişimlerdeki çözeltilerin gaz üretim tahminlerindeki model başarımı karşılaştırmalı olarak ortaya konmuştur. Tablo 7.1’de, 5 gr KOH ve 7200 saniyelik deney süresi ile elde edilen çözelti için hidrojen (H_2) ve oksijen (O_2) gazı hacimlerinin tahmini sonuçları verilmiştir. Beş farklı regresyon modeli karşılaştırılmıştır: Random Forest, KNN, Linear Regression, Decision Tree, ve Gradient Boosting. Hem H_2 hem de O_2 için Random Forest, KNN, Linear Regression ve Decision Tree modelleri, R^2 değerinin 1.0 olması ve son derece düşük hata metrikleriyle neredeyse mükemmel tahmin performansı sergilemiştir. Gradient Boosting modeli de yüksek başarı göstermiştir (H_2 için $R^2 = 0.9999982$, O_2 için $R^2 = 0.99999608$), ancak diğer modellere


kıyasla hata değerleri bir miktar daha yüksektir. Bu sonuçlar, söz konusu çözümlerde gaz üretiminin sistem akımı ile oldukça güçlü ve doğrusal bir ilişki gösterdiğini ve çoğu modelin bu ilişkiyi yüksek doğrulukla öğrenebildiğini göstermektedir. Şekil 7.21’de, 5 gr KOH ve 7200 sn deney süresi için Random Forest modeliyle tahmin edilen hidrojen gazı hacmi (Volume H₂) değerlerinin analizine yönelik dört farklı grafiği içermektedir: (1) üst sol grafikte tahmin değerleri ile gerçek değerler karşılaştırılmış ve verilerin kırmızı kesikli $y = x$ doğrusuna yakın seyretmesi, modelin yüksek doğrulukta çalıştığını göstermektedir; (2) üst sağdaki histogramda tahmin hatalarının (gerçek – tahmin) dağılımı sunulmuş ve hataların simetrik biçimde, ortalama hataya yakın yoğunlaştığı görülmektedir; (3) alt sol grafikte hata değerlerinin zamana (örnek sırasına) göre değişimi gösterilmiş ve hataların genellikle $\pm 1 \times 10^{-18}$ bandında, rastgele dağıldığı gözlemlenmiştir; (4) alt sağ grafikte ise gerçek ve tahmin edilen hacim değerleri zaman ekseninde birlikte gösterilmiş, iki eğrinin büyük ölçüde çakıştığı görülmüş, bu da modelin zaman boyunca kararlı ve isabetli tahminler yaptığını ortaya koymuştur. Şekil 7.22’de, 5 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeliyle tahmin edilen oksijen gazı hacmi (Volume O₂) sonuçlarının analizine ait dört grafik sunmaktadır. Üst sol grafikte, tahmin edilen değerlerle gerçek değerler karşılaştırılmış ve noktaların kırmızı kesikli $y = x$ doğrusuna çok yakın yerleştiği görülmüştür; bu durum modelin yüksek doğrulukta çalıştığını göstermektedir. Üst sağdaki histogram, tahmin hatalarının (gerçek – tahmin) dağılımını göstermekte olup hataların büyük çoğunluğu sıfıra yakın değerlerde yoğunlaşmış, dağılım simetrik biçimde ortalama hata etrafında şekillenmiştir. Alt sol grafikte, hata değerlerinin örnek bazında zamana göre değişimi verilmiş; hatalar çoğunlukla $\pm 4 \times 10^{-19}$ bandında dağılmış ve rastgele bir yapıda seyretmiştir. Alt sağ grafikte ise gerçek ve tahmin değerleri zaman ekseninde karşılaştırılmış, iki eğrinin büyük ölçüde çakıştığı görülerek modelin zaman boyunca tutarlı ve yüksek isabetli tahminler yaptığı doğrulanmıştır.

Tablo 7.1. 5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
5 gr 7200	H2(L)	RandomForest	1	4,92283E-19	2,42342E-37	3,61344E-19
5 gr 7200	H2(L)	KNN	1	1,3665E-20	1,86732E-40	6,8892E-21

5 gr 7200	H2(L)	LinearRegression	1	4,39965E-20	1,93569E-39	3,36554E-20
5 gr 7200	H2(L)	DecisionTree	1	5,34578E-19	2,85773E-37	3,70944E-19
5 gr 7200	H2(L)	GradientBoosting	0,9999982	2,16085E-08	4,66926E-16	8,46612E-09
5 gr 7200	O2(L)	RandomForest	1	2,52988E-19	6,40031E-38	1,85717E-19
5 gr 7200	O2(L)	KNN	1	7,19618E-21	5,1785E-41	3,82106E-21
5 gr 7200	O2(L)	LinearRegression	1	2,68188E-20	7,19251E-40	2,16746E-20
5 gr 7200	O2(L)	DecisionTree	1	2,6825E-19	7,19582E-38	1,88757E-19
5 gr 7200	O2(L)	GradientBoosting	0,99999608	1,59371E-08	2,53992E-16	6,39877E-09

5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.21. 5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.22. 5 gr için RandomForest ile O Tahmin ve hata değerleri

Tablo 7.2’de, 7.5 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözelti için tahmin edilen hidrojen (H_2) ve oksijen (O_2) hacimlerine ait model başarımları sunulmuştur. Tüm modellerin R^2 değerleri 1’e çok yakın olup, özellikle Random Forest, KNN, Linear Regression ve Decision Tree modelleri için hata metrikleri neredeyse sıfıra yakın değerlere sahiptir. Özellikle KNN modeli hem H_2 hem de O_2 için RMSE, MSE ve MAE değerlerini sıfır olarak vermiştir; bu durum, tahminlerin gerçek değerlerle birebir örtüştüğünü ve eğitim verisine mükemmel uyum sağladığını gösterir. Gradient Boosting modeli yine oldukça başarılı sonuçlar vermiş, ancak diğer modellere kıyasla hata oranları daha yüksektir (örneğin H_2 için RMSE: $2.86E-08$). Bu farklılıklar çok küçük olmakla birlikte, Gradient Boosting modelinin diğer yöntemlere göre daha az hassas ayarlamalar yapabildiğini göstermektedir. Genel olarak, bu çözeltide de sistem akımı ile gaz üretimi arasında güçlü ve oldukça deterministik bir ilişki bulunmakta olup, tüm regresyon modelleri bu yapıyı yüksek başarıyla öğrenebilmiştir. Şekil 7.23’te 7.5 gr KOH ve 7200 saniyelik deney süresi için RandomForest modeli ile tahmin edilen hidrojen gazı hacmi (Volume H_2) sonuçlarına ilişkin dört farklı analiz grafiğini içermektedir. Üst sol grafikte, gerçek ve tahmin edilen değerler karşılaştırılmış; verilerin büyük ölçüde kırmızı kesikli y


= x doğrusu üzerine düştüğü görülmüş ve bu da modelin yüksek doğrulukla tahmin yaptığını göstermektedir. Üst sağdaki histogram, tahmin hatalarının dağılımını (gerçek – tahmin) sunmakta olup hataların çoğunlukla ortalama hata çevresinde ve simetrik biçimde toplandığı görülmektedir. Alt sol grafik, hata değerlerini örnek bazında zamana göre göstermekte olup hataların $\pm 2 \times 10^{-18}$ aralığında dalgalandığı ve düzensiz şekilde dağıldığı dikkat çekmektedir. Alt sağ grafikte, gerçek ve tahmin değerleri zaman eksenini boyunca birlikte çizilmiştir; iki eğri büyük oranda çakışmakta ve bu da modelin zaman boyunca kararlı ve tutarlı tahmin performansı sergilediğini ortaya koymaktadır. Şekil 7.24'te, 7,5 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli ile tahmin edilen oksijen gazı hacmi (Volume O₂) sonuçlarının değerlendirilmesine yönelik dört farklı grafik içermektedir. Üst sol grafikte, gerçek ve tahmin edilen değerlerin karşılaştırması verilmiş olup, noktaların kırmızı kesikli y = x doğrusuna yakınlığı, modelin yüksek doğrulukla çalıştığını göstermektedir. Üst sağdaki histogram, tahmin hatalarının (gerçek – tahmin) dağılımını sunmakta ve hataların çoğunlukla negatif yönde, ortalama- 0.6×10^{-18} civarında yoğunlaştığını göstermektedir. Alt sol grafikte, hata değerleri zamana bağlı olarak incelenmiş ve hataların çoğunun- 1.0×10^{-18} ile 0 arasında dalgalandığı gözlemlenmiştir. Alt sağ grafikte, gerçek ve tahmin hacimleri örnek bazında karşılaştırılmış; iki eğri neredeyse üst üste binmiş ve modelin zaman boyunca tutarlı ve güvenilir tahminler yaptığını ortaya koymuştur.

Tablo 7.2. 7,5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
7,5 gr 7200	H2(L)	RandomForest	1	9,97198E-19	9,94403E-37	8,54562E-19
7,5 gr 7200	H2(L)	KNN	1	0	0	0
7,5 gr 7200	H2(L)	LinearRegression	1	8,78769E-20	7,72234E-39	6,56545E-20
7,5 gr 7200	H2(L)	DecisionTree	1	1,57395E-18	2,47732E-36	1,25722E-18
7,5 gr 7200	H2(L)	GradientBoosting	0,9999993	2,86027E-08	8,18115E-16	1,08324E-08
7,5 gr 7200	O2(L)	RandomForest	1	6,07782E-19	3,69399E-37	5,37508E-19
7,5 gr 7200	O2(L)	KNN	1	0	0	0

7,5 gr 7200	O2(L)	LinearRegression	1	6,38713E-20	4,07954E-39	5,29678E-20
7,5 gr 7200	O2(L)	DecisionTree	1	6,11406E-19	3,73817E-37	5,18497E-19
7,5 gr 7200	O2(L)	GradientBoosting	0,9999991	1,64197E-08	2,69606E-16	6,17649E-09

7,5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.23. 7.5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.24. 7.5 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.3' te 10 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözeltiye ait regresyon model sonuçları incelendiğinde, tahmin performanslarının yine oldukça yüksek olduğu görülmektedir. Random Forest, KNN, Linear Regression ve Decision Tree modelleri hem hidrojen (H_2) hem de oksijen (O_2) için R^2 değerinde 1.0'a ulaşmış ve hata metriklerinde son derece düşük değerlere sahiptir. Özellikle KNN modeli, tüm hata metriklerinde sıfır değeri ile teorik olarak mükemmel bir tahmin gerçekleştirmiştir; bu, modelin eğitim verisini eksiksiz bir şekilde öğrendiğini göstermektedir. Gradient Boosting modeli diğerlerine kıyasla yine biraz daha yüksek hata değerleri vermiş olsa da R^2 değeri 0.99999958 – 0.99999989 aralığında kalmıştır ve bu da modelin oldukça başarılı olduğunu göstermektedir. RMSE ve MAE değerleri $\sim 1.5E-08$ ve altındadır; bu seviyede hatalar, pratikte ihmal edilebilir düzeydedir. Sonuç olarak, bu çözültide de gaz üretimiyle sistem akımı arasında güçlü ve açık bir matematiksel ilişki olduğu görülmekte ve kullanılan tüm regresyon modelleri bu ilişkiyi yüksek başarıyla yakalayabilmektedir. Şekil 7.25'te, 10 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli ile tahmin edilen hidrojen gazı hacmi (Volume H_2) verilerinin analizine yönelik dört temel grafik sunmaktadır. Üst sol grafikte, gerçek ve tahmin edilen değerler karşılaştırılmış,


verilerin büyük oranda $y = x$ doğrusu üzerinde kümелendiği gözlemlenmiş; bu da modelin yüksek doğrulukla tahmin yaptığını göstermektedir. Üst sağdaki histogram, tahmin hatalarının (gerçek – tahmin) dağılımını göstermekte olup, hataların büyük kısmı ortalama hata civarında simetrik biçimde yoğunlaşmıştır. Alt sol grafikte, hata değerleri örnek sırasına göre incelenmiş; hataların $\pm 4 \times 10^{-18}$ bandında rastgele dağıldığı görülmüştür. Alt sağ grafikte ise gerçek ve tahmin edilen hacimler zaman ekseninde birlikte sunulmuş, iki eğrinin büyük ölçüde üst üste bindiği ve modelin tahminlerinin zaman boyunca oldukça tutarlı olduğu net bir şekilde anlaşılmıştır. Şekil 7.26’da 10 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli ile tahmin edilen oksijen gazı hacmi (Volume O₂) verilerinin analizine ait dört grafik içermektedir. Üst sol grafikte, tahmin edilen değerler ile gerçek değerler karşılaştırılmış ve noktaların kırmızı kesikli $y = x$ doğrusuna çok yakın yerleştiği görülmüş; bu da modelin oldukça isabetli tahminler yaptığını göstermektedir. Üst sağdaki histogram, hata dağılımını (gerçek – tahmin) sunmakta olup hataların büyük kısmı sıfıra yakın yoğunlaşmış ve dağılım simetrik yapıya sahiptir. Alt sol grafikte, hata değerleri örnek sırasına göre gösterilmiş ve hataların genellikle $\pm 3 \times 10^{-18}$ aralığında düzensiz fakat sınırlı bir biçimde dağıldığı gözlemlenmiştir. Alt sağ grafikte ise zaman (örnek sırası) boyunca gerçek ve tahmin değerleri birlikte çizilmiş, iki eğrinin büyük ölçüde çakıştığı ve modelin zaman içinde tutarlı tahminler ürettiği anlaşılmıştır. Genel olarak, Random Forest modeli bu çözültide de yüksek doğruluk ve düşük hata ile başarılı tahminler gerçekleştirmiştir.

Tablo 7.3. 10 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözülti	Target	Model	R2	RMSE	MSE	MAE
10 gr 7200	H2(L)	RandomForest	1	2,58508E-18	6,68262E-36	2,04914E-18
10 gr 7200	H2(L)	KNN	1	0	0	0
10 gr 7200	H2(L)	LinearRegression	1	3,54836E-19	1,25909E-37	2,91229E-19
10 gr 7200	H2(L)	DecisionTree	1	3,40502E-18	1,15941E-35	2,78083E-18
10 gr 7200	H2(L)	GradientBoosting	0,99999989	1,55751E-08	2,42583E-16	6,75718E-09
10 gr 7200	O2(L)	RandomForest	1	1,30423E-18	1,70102E-36	1,00515E-18

10 gr 7200	O2(L)	KNN	1	0	0	0
10 gr 7200	O2(L)	LinearRegression	1	1,3735E-19	1,88651E-38	1,11808E-19
10 gr 7200	O2(L)	DecisionTree	1	1,73628E-18	3,01467E-36	1,38627E-18
10 gr 7200	O2(L)	GradientBoosting	0,99999958	1,54442E-08	2,38524E-16	9,15803E-09

10 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.25. 10 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.26. 10 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.4’te 12.5 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözeltiye ait regresyon model sonuçları, önceki çözeltilerde gözlemlenen genel eğilimi sürdürmektedir. Random Forest, KNN, Linear Regression ve Decision Tree modelleri, hem hidrojen (H_2) hem de oksijen (O_2) tahminlerinde R^2 değerinin 1.0 olmasıyla dikkat çekmektedir. Bu durum, modellerin tahminlerinin gözlenen değerlere neredeyse birebir uyum sağladığını göstermektedir. Özellikle KNN modeli, tüm hata metriklerinde sıfır değer vererek teorik olarak kusursuz tahmin başarımı sergilemiştir. Diğer yandan, Gradient Boosting modeli bu çözeltilerde de yüksek doğruluk sağlamış ancak diğer modellere kıyasla nispeten daha yüksek hata değerleri üretmiştir. H_2 için RMSE değeri yaklaşık 8.7×10^{-8} , O_2 içinse yaklaşık 4.7×10^{-8} olarak hesaplanmıştır. Bununla birlikte, R^2 değerlerinin 0.9999975 ve üzeri olması, bu modelin de başarılı tahminler yapabildiğini göstermektedir. Genel olarak, 12.5 gr çözeltide sistem akımı ile gaz üretimi arasındaki doğrusal ilişki tüm modeller tarafından güçlü biçimde öğrenilmiş ve oldukça düşük hata oranlarıyla yüksek performans elde edilmiştir. Şekil 7.27’de, 12.5 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli kullanılarak tahmin edilen hidrojen gazı hacmi (Volume H_2) verilerine ait dört temel grafik sunmaktadır. Üst sol grafikte,


tahmin edilen değerler ile gerçek değerler karşılaştırılmış ve verilerin büyük ölçüde kırmızı kesikli $y = x$ doğrusuna hizalanması, modelin yüksek doğrulukta tahminler yaptığını göstermektedir. Üst sağdaki histogram, hata dağılımını (gerçek – tahmin) göstermektedir ve hataların çoğunlukla ortalama hatanın çevresinde yoğunlaştığı, simetrik ve dağınık bir dağılım sergilediği görülmektedir. Alt sol grafikte, örnek bazında hata değişimi verilmiş olup hatalar $\pm 4 \times 10^{-18}$ bandında seyretmekte ve rastgele dağılmaktadır. Alt sağ grafikte ise gerçek ve tahmin hacimleri zaman ekseninde birlikte gösterilmiş, iki eğrinin büyük ölçüde çakıştığı ve modelin zaman boyunca istikrarlı, yüksek isabetli tahminler yaptığı açıkça gözlemlenmiştir. Şekil 7.28’de, 12.5 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli ile tahmin edilen oksijen gazı hacmi (Volume O₂) verilerinin analizine ilişkin dört grafik sunmaktadır. Üst sol grafikte, tahmin edilen ve gerçek değerler karşılaştırılmış, noktaların kırmızı kesikli $y = x$ doğrusuna çok yakın konumlandığı görülmüş ve bu durum modelin tahmin doğruluğunun oldukça yüksek olduğunu göstermektedir. Üst sağdaki histogram, tahmin hatalarının (gerçek – tahmin) dağılımını sunmakta olup hatalar $\pm 1.5 \times 10^{-18}$ aralığında dağılmış ve ortalama hatanın sıfıra çok yakın olduğu gözlemlenmiştir. Alt sol grafikte, örnek bazında hata değerleri zamana göre çizilmiş ve hataların rastgele şekilde yukarı-aşağı dalgalandığı görülmektedir. Alt sağ grafikte, zaman eksenine göre gerçek ve tahmin değerleri karşılaştırılmış ve her iki eğri neredeyse tamamen çakışarak modelin tutarlı ve başarılı bir tahmin performansı sergilediğini ortaya koymuştur.

Tablo 7.4. 12,5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözeltili	Target	Model	R2	RMSE	MSE	MAE
12,5 gr 7200	H2(L)	RandomForest	1	2,03209E-18	4,12938E-36	1,66847E-18
12,5 gr 7200	H2(L)	KNN	1	0	0	0
12,5 gr 7200	H2(L)	LinearRegression	1	3,39361E-19	1,15166E-37	2,60058E-19
12,5 gr 7200	H2(L)	DecisionTree	1	2,59612E-18	6,73986E-36	1,83968E-18
12,5 gr 7200	H2(L)	GradientBoosting	0,99999784	8,70803E-08	7,58297E-15	3,74078E-08
12,5 gr 7200	O2(L)	RandomForest	1	8,969E-19	8,0443E-37	7,93726E-19

12,5 7200	gr	O2(L)	KNN	1	0	0	0
12,5 7200	gr	O2(L)	LinearRegression	1	1,47079E-19	2,16324E-38	1,27695E-19
12,5 7200	gr	O2(L)	DecisionTree	1	1,17931E-18	1,39077E-36	8,73686E-19
12,5 7200	gr	O2(L)	GradientBoostin g	0,9999975	4,66931E-08	2,18024E-15	1,96231E-08

12,5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.27. 12,5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.28. 12,5 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.5'te 15 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözeltiye ait model sonuçları, daha önceki çözelti oranlarında gözlenen yüksek tahmin doğruluğunun devam ettiğini göstermektedir. Hem hidrojen (H_2) hem de oksijen (O_2) tahminlerinde, Random Forest, KNN, Linear Regression ve Decision Tree modelleri yine neredeyse kusursuz performans sergilemiştir. Bu dört modelde de R^2 değeri 1,0 olarak elde edilmiş, hata metrikleri ise sıfıra çok yakın değerlerde kalmıştır. Özellikle KNN modeli, RMSE, MSE ve MAE değerlerinin sıfır çıkmasıyla teorik olarak mükemmel bir tahmin ortaya koymuştur. Gradient Boosting Regressor modeli ise diğer modellere kıyasla bir miktar daha yüksek hata değerlerine sahip olsa da performansı hala oldukça başarılı düzeydedir. H_2 için RMSE değeri yaklaşık 7.13×10^{-8} , O_2 için ise 3.68×10^{-8} olarak hesaplanmış ve R^2 değerleri 0.99999887–0.99999893 aralığında kalmıştır. Bu sonuçlar, 15 gr çözelti seviyesinde de sistem akımı ile gaz üretimi arasındaki ilişkinin yüksek doğrulukla modellenebildiğini ve kullanılan regresyon algoritmalarının tümünün bu yapıyı başarıyla öğrenebildiğini ortaya koymaktadır. Şekil 7.29'da 15 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli ile tahmin edilen hidrojen gazı hacmi (Volume H_2) sonuçlarının analizine yönelik dört grafik sunmaktadır. Üst sol grafikte,


tahmin edilen değerler gerçek değerlerle karşılaştırılmış ve verilerin büyük ölçüde kırmızı kesikli $y = x$ doğrusu üzerine hizalanmış olması, modelin yüksek doğrulukla çalıştığını göstermektedir. Üst sağdaki histogram, tahmin hatalarının dağılımını göstermekte olup hataların çoğunluğu ortalama hata civarında toplanmış ve dağılım $\pm 4 \times 10^{-18}$ aralığında seyretmiştir. Alt sol grafikte, hata değerlerinin örnek bazında zamanla değişimi gösterilmiş, hataların rastgele ve düşük genlikli olduğu gözlemlenmiştir. Alt sağ grafikte ise gerçek ve tahmin edilen hacimler zaman ekseninde üst üste çizilmiş ve iki eğrinin büyük ölçüde çakıştığı görülerek modelin zaman boyunca tutarlı ve güvenilir tahminler yaptığı net biçimde ortaya konmuştur. Şekil 7.30'da 15 gr KOH ve 7200 saniyelik deney süresi için Random Forest modeli kullanılarak tahmin edilen oksijen gazı hacmi (Volume O₂) verilerinin analizine ilişkin dört farklı grafik sunmaktadır. Üst sol grafikte, tahmin edilen değerler ile gerçek değerler karşılaştırılmış; verilerin büyük kısmının kırmızı kesikli $y = x$ doğrusu üzerinde konumlandığı görülmüş, bu da modelin yüksek tahmin doğruluğuna işaret etmektedir. Üst sağdaki histogram, hata dağılımını göstermekte olup hataların genellikle sıfıra yakın yoğunlaştığı ve simetrik bir yapı sergilediği anlaşılmaktadır. Alt sol grafikte, hata değerlerinin örnek sırasına göre dağılımı verilmiş; hatalar çoğunlukla $\pm 1.5 \times 10^{-18}$ aralığında, rastlantısal biçimde dağılmıştır. Alt sağ grafikte ise zaman eksenine göre tahmin edilen ve gerçek değerler karşılaştırılmış, iki eğrinin büyük ölçüde çakıştığı gözlemlenmiş ve bu durum modelin zaman boyunca son derece istikrarlı ve başarılı tahminler yaptığını göstermektedir.

Tablo 7.5. 15 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözeltili	Target	Model	R2	RMSE	MSE	MAE
15 gr 7200	H2(L)	RandomForest	1	1,87607E-18	3,51963E-36	1,53836E-18
15 gr 7200	H2(L)	KNN	1	0	0	0
15 gr 7200	H2(L)	LinearRegression	1	3,43758E-19	1,1817E-37	2,67888E-19
15 gr 7200	H2(L)	DecisionTree	1	2,34997E-18	5,52234E-36	1,83682E-18
15 gr 7200	H2(L)	GradientBoosting	0,99999893	7,13168E-08	5,08609E-15	3,09386E-08
15 gr 7200	O2(L)	RandomForest	1	9,11682E-19	8,31164E-37	7,45464E-19

15 gr 7200	O2(L)	KNN	1	0	0	0
15 gr 7200	O2(L)	LinearRegression	1	6,02711E-20	3,6326E-39	3,35049E-20
15 gr 7200	O2(L)	DecisionTree	1	1,1539E-18	1,33149E-36	9,08622E-19
15 gr 7200	O2(L)	GradientBoosting	0,9999987	3,67784E-08	1,35265E-15	1,5967E-08

15 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.29. 15 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.30. 15 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.6’da 17.5 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözelti için elde edilen regresyon sonuçları, önceki çözeltilerde gözlemlenen eğilimleri sürdürmektedir. Hem hidrojen (H₂) hem de oksijen (O₂) gazı hacim tahminlerinde, Random Forest, KNN, Linear Regression ve Decision Tree modelleri son derece yüksek başarı göstermiştir. Tüm bu modeller için R² değeri 1,0 olarak hesaplanmış ve hata metrikleri (RMSE, MSE, MAE) sıfıra çok yakın değerlerde kalmıştır. Özellikle KNN ve Linear Regression modellerinin hata değerleri istatistiksel olarak ihmal edilebilecek düzeydedir. Gradient Boosting modeli bu çözültide de diğer modellere göre daha yüksek hata üretmiş olmakla birlikte, elde edilen R² değerleri (H₂ için 0.99999853, O₂ için 0.99999845) modelin hala oldukça başarılı olduğunu göstermektedir. H₂ için RMSE değeri yaklaşık 1.13×10^{-7} , O₂ için ise 5.80×10^{-8} olarak ölçülmüştür. Bu düzeydeki farklılıklar, sistemin karmaşıklığını yansıtmaz; daha çok Gradient Boosting algoritmasının doğası gereği iteratif öğrenme yapısının etkilerini gösterir. Genel olarak, 17.5 gr çözelti koşulunda da sistem akımı ile gaz üretimi arasındaki güçlü doğrusal ilişki tüm modeller tarafından yüksek doğrulukla yakalanmıştır. Şekil 7.31’de 17,5 gram KOH içeren çözültide 7200 saniyelik deney süresi boyunca üretilen hidrojen gazı hacminin


(Volume H₂) Random Forest modeli ile tahmin sonuçlarının analizini sunmaktadır. Üst sol grafikte, tahmin edilen ve gerçek hacim değerleri karşılaştırılmış, verilerin büyük kısmının kırmızı kesikli $y = x$ doğrusuna çok yakın konumlandığı gözlemlenmiştir. Bu durum, modelin yüksek isabet oranıyla tahmin yaptığını göstermektedir. Üst sağdaki histogramda hata dağılımı verilmiş olup, hataların büyük bölümü $\pm 4 \times 10^{-18}$ aralığında yer almakta ve ortalama hata çevresinde simetrik bir şekilde dağılmaktadır. Alt sol grafik, her bir örnek için hata değerlerinin zamana göre değişimini göstermektedir; burada hataların belirgin bir örüntü taşımadan rastgele dağıldığı görülmektedir. Alt sağ grafikte ise zaman ekseninde gerçek ve tahmin edilen hacim değerleri birlikte sunulmuştur. Her iki eğrinin neredeyse tamamen üst üste binmesi, modelin zaman boyunca son derece kararlı ve başarılı tahminler yaptığını ortaya koymaktadır. Şekil 7.32’de, aynı deney koşullarında (17,5 gram KOH, 7200 saniye) elde edilen oksijen gazı hacmi (Volume O₂) verileri için Random Forest modelinin tahmin performansını göstermektedir. Üst sol grafikte, tahmin edilen ve gerçek değerler karşılaştırıldığında, verilerin büyük ölçüde kırmızı kesikli $y = x$ doğrusu üzerine hizalandığı görülmektedir. Bu sonuç, modelin oksijen tahminlerinde de oldukça yüksek bir doğrulukla çalıştığını göstermektedir. Üst sağdaki histogram, hata değerlerinin dağılımını sunmakta ve hataların çoğunun $\pm 2 \times 10^{-18}$ aralığında, ortalama hatanın etrafında toplandığı görülmektedir. Hataların bu denli küçük ve dengeli olması, modelin doğrusal yapıyı iyi öğrendiğini göstermektedir. Alt sol grafikte, hata değerlerinin zamana göre dağılımı verilmiş ve burada da rastgele, sistematik sapma içermeyen bir hata yapısı gözlemlenmiştir. Alt sağ grafikte gerçek ve tahmin edilen O₂ hacimleri zaman eksenini boyunca birlikte çizilmiş, iki eğrinin neredeyse tamamen çakışması modelin zaman boyu tutarlılığını ve güvenilirliğini teyit etmektedir. Genel olarak her iki grafik, Random Forest modelinin hem H₂ hem de O₂ üretim tahminlerinde son derece başarılı olduğunu ve bu çözültideki üretim sürecini güçlü bir şekilde modelleyebildiğini göstermektedir.

Tablo 7.6. 17,5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
17,5 gr 7200	H2(L)	RandomForest	1	2,07163E-18	4,29163E-36	1,65778E-18
17,5 gr 7200	H2(L)	KNN	1	7,1827E-20	5,15911E-39	2,37922E-20

17,5 7200	gr	H2(L)	LinearRegression	1	3,87348E-19	1,50039E-37	3,17882E-19
17,5 7200	gr	H2(L)	DecisionTree	1	1,95734E-18	3,8312E-36	1,51758E-18
17,5 7200	gr	H2(L)	GradientBoosting	0,99999853	1,13044E-07	1,27791E-14	5,3855E-08
17,5 7200	gr	O2(L)	RandomForest	1	1,11252E-18	1,2377E-36	8,9025E-19
17,5 7200	gr	O2(L)	KNN	1	3,46408E-20	1,19998E-39	1,10679E-20
17,5 7200	gr	O2(L)	LinearRegression	1	1,4168E-19	2,00732E-38	1,05484E-19
17,5 7200	gr	O2(L)	DecisionTree	1	1,06037E-18	1,12439E-36	8,10441E-19
17,5 7200	gr	O2(L)	GradientBoosting	0,99999845	5,80019E-08	3,36423E-15	2,72308E-08

17,5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.31. 17.5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.32. 17.5 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.7’de, 20 gr KOH ve 7200 saniyelik deney süresi ile elde edilen çözeltiye ait regresyon modelleme sonuçları, önceki örneklerde olduğu gibi oldukça yüksek tahmin doğruluğu göstermektedir. Random Forest, KNN, Linear Regression ve Decision Tree modelleri, hem hidrojen (H_2) hem de oksijen (O_2) gazı hacimlerini tahmin etmede neredeyse mükemmel sonuçlar üretmiştir. Bu dört modelde de R^2 değeri 1.0 olup, RMSE, MSE ve MAE değerleri sıfıra çok yakın seviyelerde kalmıştır. Özellikle KNN ve Linear Regression modelleri, çok küçük hata değerleriyle gerçek değerlere birebir yakın tahminler yapmıştır. Gradient Boosting Regressor modeli, bu çözültide de yüksek performans göstermiş olmakla birlikte, diğer modellere göre biraz daha yüksek hata değerleri üretmiştir. H_2 için $R^2 = 0.99999699$, O_2 için ise $R^2 = 0.99999712$ elde edilmiş ve buna karşılık RMSE değerleri sırasıyla 1.19×10^{-7} ve 5.83×10^{-8} olarak ölçülmüştür. Bu farklılıklar küçük olmakla birlikte, Gradient Boosting modelinin iteratif öğrenme doğasından kaynaklanabilir. Genel olarak, 20 gr KOH içeren çözelti için uygulanan tüm modeller, sistem akımı ile gaz üretim hacimleri arasındaki deterministik ilişkiyi başarıyla yakalamış ve oldukça düşük hata ile tahminler üretmiştir. Bu sonuçlar, kurulan modellerin genel geçer bir yapıya sahip olduğunu ve farklı çözeltik koşullarında da


kararlılıkla çalıştığını göstermektedir. Şekil 7.33'te 20 gram KOH içeren çözeltiyle yapılan ve 7200 saniye süren deneyde üretilen hidrojen gazı hacmi (Volume H₂) için Random Forest modelinin tahmin başarımını değerlendiren dört grafik sunmaktadır. Üst sol grafikte, tahmin edilen ve gerçek değerlerin karşılaştırması yer almakta olup verilerin büyük oranda kırmızı kesikli $y = x$ doğrusuna hizalandığı görülmektedir. Bu durum, modelin yüksek doğrulukta tahminler yaptığını göstermektedir. Üst sağda yer alan histogram, hata dağılımını (gerçek – tahmin) göstermektedir. Hataların büyük kısmı ortalama hatanın çevresinde toplanmış ve dağılım genellikle -6×10^{-18} ile $+4 \times 10^{-18}$ aralığında gerçekleşmiştir. Bu değerler modelin oldukça küçük ve dengeli hata ürettiğini göstermektedir. Alt sol grafik, hata değerlerinin örnek bazında zamana göre dağılımını göstermekte olup hataların rastgele dağıldığı, sistematik bir sapma içermediği anlaşılmaktadır. Alt sağ grafikte, tahmin edilen ve gerçek hacim değerleri zaman ekseninde üst üste çizilmiş ve iki eğrinin büyük ölçüde çakıştığı gözlemlenmiştir. Bu çakışma, modelin zaman boyunca kararlı ve güvenilir tahminler ürettiğini göstermektedir. Şekil 7.34'te, aynı deney koşullarında (20 gr KOH, 7200 sn) elde edilen oksijen gazı hacmi (Volume O₂) verileri için Random Forest modelinin tahmin performansını göstermektedir. Üst sol grafikte, tahmin edilen ve gerçek değerler karşılaştırıldığında verilerin kırmızı kesikli $y = x$ doğrusuna hizalı biçimde konumlandığı görülmektedir. Bu uyum, modelin tahmin doğruluğunun yüksek olduğunu göstermektedir. Üst sağdaki histogram, hata dağılımını sunmakta olup hataların büyük kısmı $\pm 2 \times 10^{-18}$ bandında ortalama hata etrafında yoğunlaşmıştır. Hataların simetrik ve dar aralıkta dağılması, modelin kararlı tahminler yaptığını desteklemektedir. Alt sol grafikte hata değerlerinin örnek bazında değişimi sunulmuş; burada da hatalar belirli bir örüntü göstermeden rastgele dağılmıştır. Alt sağdaki zaman eksenli grafik, gerçek ve tahmin edilen hacim değerlerinin birlikte çizildiği görseldir. Her iki eğri neredeyse tamamen çakışmakta olup, bu da Random Forest modelinin oksijen üretimini zaman içinde yüksek doğrulukla tahmin ettiğini kanıtlamaktadır. Genel olarak hem H₂ hem de O₂ için modelin güçlü bir genelleme başarısına sahip olduğu söylenebilir.

Tablo 7.7. 20 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
20 gr 7200	H2(L)	RandomForest	1	2,64044E-18	6,97192E-36	2,18979E-18

20 gr 7200	H2(L)	KNN	1	1,22557E-19	1,50202E-38	6,92685E-20
20 gr 7200	H2(L)	LinearRegression	1	3,8183E-19	1,45794E-37	2,94692E-19
20 gr 7200	H2(L)	DecisionTree	1	5,19204E-18	2,69573E-35	3,64382E-18
20 gr 7200	H2(L)	GradientBoosting	0,99999699	1,19433E-07	1,42642E-14	5,08564E-08
20 gr 7200	O2(L)	RandomForest	1	1,31288E-18	1,72364E-36	1,06335E-18
20 gr 7200	O2(L)	KNN	1	5,86929E-20	3,44485E-39	3,17731E-20
20 gr 7200	O2(L)	LinearRegression	1	1,3068E-19	1,70773E-38	1,08721E-19
20 gr 7200	O2(L)	DecisionTree	1	2,57061E-18	6,60806E-36	1,82025E-18
20 gr 7200	O2(L)	GradientBoosting	0,99999712	5,83499E-08	3,40471E-15	2,4924E-08

20 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.33. 20 gr için Random Forest ile O Tahmin ve hata değerleri



Şekil 7.34. 20 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.8’de, 22.5 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözeltiye ait modelleme sonuçları, önceki çözeltilerde elde edilen yüksek doğruluk eğilimini sürdürmektedir. Random Forest, KNN, Linear Regression ve Decision Tree modelleri, hem hidrojen (H₂) hem de oksijen (O₂) hacimlerinin tahmininde neredeyse kusursuz sonuçlar vermiştir. Tüm bu modellerde R² değeri 1,0 olarak gerçekleşmiş ve hata metrikleri (RMSE, MSE, MAE) istatistiksel olarak sıfıra yakın seviyelerde kalmıştır. Özellikle KNN modeli, hata metriklerinde sıfır değerleriyle eğitim verisine mutlak uyum sağlamıştır. Buna karşılık, Gradient Boosting Regressor modeli yüksek performansına rağmen diğer modellere göre daha yüksek hata değerleri üretmiştir. H₂ için RMSE yaklaşık 8.05×10^{-8} , O₂ içinse yaklaşık 4.40×10^{-8} olarak ölçülmüştür. R² değerleri ise sırasıyla 0.99999857 (H₂) ve 0.99999829 (O₂) seviyesindedir. Bu da Gradient Boosting’in güçlü ancak hassas ayarlara ihtiyaç duyan bir model olduğunu göstermektedir. Genel olarak, 22.5 gr çözelti içeren deney koşullarında tüm regresyon algoritmaları, sistem akımı ile gaz üretim hacimleri arasındaki doğrusal ilişkiyi başarılı bir şekilde öğrenmiş ve oldukça düşük hata oranlarıyla doğru tahminlerde bulunmuştur. Şekil 7.35’te 22,5 gram KOH ve 7200 saniye deney süresi ile üretilen hidrojen gazı hacminin (Volume H₂)


Random Forest modeliyle tahminine ilişkin dört temel grafik sunmaktadır. Üst sol grafikte tahmin edilen ve gerçek değerler karşılaştırılmış, noktaların büyük oranda kırmızı kesikli $y = x$ doğrusuna hizalandığı görülmüştür. Bu sonuç, modelin oldukça yüksek bir doğrulukla çalıştığını ve tahminlerinin gerçek değerlere çok yakın olduğunu göstermektedir. Üst sağdaki histogram, hata dağılımını (gerçek – tahmin) sunmakta olup hataların çoğu $\pm 1 \times 10^{-17}$ aralığında yoğunlaşmıştır. Hataların büyük ölçüde ortalama hataya yakın seyretmesi modelin dengeli tahminler yaptığını göstermektedir. Alt sol grafik, her bir örnek için hata değerlerinin zaman ekseninde gösterimini sunmaktadır. Burada hataların genellikle rastgele dağılmış olduğu ve sistematik bir örüntü taşımadığı gözlemlenmektedir. Alt sağ grafikte ise zaman ekseninde tahmin edilen ve gerçek hacim değerleri birlikte çizilmiş, iki eğrinin büyük ölçüde çakıştığı görülmüştür. Bu durum, modelin zaman boyunca oldukça kararlı ve doğru tahminler yaptığını doğrulamaktadır. Şekil 7.36’da aynı deney koşullarında elde edilen oksijen gazı hacmi (Volume O₂) için Random Forest modelinin tahmin başarımını değerlendirmektedir. Üst sol grafikte tahmin edilen ve gerçek değerler karşılaştırıldığında, verilerin kırmızı kesikli $y = x$ doğrusuna oldukça yakın konumlandığı gözlemlenmiştir. Bu durum, modelin oksijen üretimini yüksek doğrulukla tahmin ettiğini ortaya koymaktadır. Üst sağdaki histogramda, tahmin hatalarının büyük kısmı $\pm 3 \times 10^{-18}$ aralığında dağılmıştır. Ortalama hatanın sıfıra çok yakın olması, modelin dengeleme başarısının yüksek olduğunu göstermektedir. Alt sol grafikte hata değerlerinin zamana göre dağılımı verilmiş olup hatalar düzensiz biçimde dağılmış, herhangi bir zamansal örüntü göstermemiştir. Alt sağ grafikte, zaman eksenini boyunca gerçek ve tahmin edilen O₂ hacimleri birlikte sunulmuş ve eğrilerin büyük oranda çakıştığı görülmüştür. Bu grafik, Random Forest modelinin oksijen gazı tahmininde de zaman boyunca tutarlı ve başarılı sonuçlar verdiğini göstermektedir.

Tablo 7.8. 22.5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
22,5 gr 7200	H2(L)	RandomForest	1	3,82271E-18	1,46131E-35	3,20773E-18
22,5 gr 7200	H2(L)	KNN	1	0	0	0
22,5 gr 7200	H2(L)	LinearRegression	1	3,60315E-19	1,29827E-37	2,90928E-19

22,5 gr 7200	H2(L)	DecisionTree	1	4,90055E-18	2,40153E-35	3,45379E-18
22,5 gr 7200	H2(L)	GradientBoosting	0,99999857	8,04661E-08	6,47479E-15	3,00684E-08
22,5 gr 7200	O2(L)	RandomForest	1	1,79582E-18	3,22497E-36	1,54559E-18
22,5 gr 7200	O2(L)	KNN	1	0	0	0
22,5 gr 7200	O2(L)	LinearRegression	1	3,45275E-19	1,19215E-37	2,9921E-19
22,5 gr 7200	O2(L)	DecisionTree	1	2,50709E-18	6,2855E-36	1,77448E-18
22,5 gr 7200	O2(L)	GradientBoosting	0,99999829	4,40378E-08	1,93932E-15	1,6011E-08

22,5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.35. 22.5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.36. 22.5 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.9’da 25 gr KOH ve 7200 saniyelik deney süresi ile gerçekleştirilen çözeltiye ait regresyon analiz sonuçları, daha önceki derişimlerde elde edilen eğilimi devam ettirmektedir. Hem hidrojen (H_2) hem de oksijen (O_2) tahminlerinde, Random Forest, KNN, Linear Regression ve Decision Tree modelleri, $R^2 = 1.0$ değeri ile neredeyse mükemmel doğruluk sağlamış ve hata metrikleri (RMSE, MSE, MAE) sıfıra çok yakın değerlerde kalmıştır. Özellikle KNN modeli, tüm hata ölçütlerinde sıfır değer vererek teorik olarak mükemmel bir model başarımı ortaya koymuştur. Bunun yanında, Gradient Boosting modeli yine yüksek performans göstermiş olsa da diğer modellere kıyasla daha yüksek hata değerleri üretmiştir. H_2 için RMSE yaklaşık 9.14×10^{-8} , O_2 içinse 4.60×10^{-8} olarak hesaplanmış; R^2 değerleri ise H_2 için 0.99999857, O_2 için 0.99999855 seviyesinde kalmıştır. Bu veriler, Gradient Boosting’in doğruluk açısından güçlü olduğunu ancak mutlak hata bazında diğer yöntemlere göre biraz daha fazla sapma gösterdiğini ortaya koymaktadır. Genel değerlendirmede, 25 gr’lık çözelti ile gerçekleştirilen deney koşullarında da sistem akımı ile gaz üretimi arasındaki ilişki doğrusal ve güçlü bir şekilde modellenenilmiş, tüm regresyon algoritmaları yüksek isabetle sonuç üretmiştir. Şekil 7.37’de 25 gram KOH çözeltisi ve 7200 saniye deney süresiyle elde edilen hidrojen


gazı hacmi (Volume H₂) için Random Forest modeliyle yapılan tahminlerin başarımını göstermektedir. Üst sol grafikte, tahmin edilen ve gerçek hacim değerleri karşılaştırılmış ve noktaların büyük bir kısmının kırmızı kesikli $y = x$ doğrusuna yakın konumlandığı görülmüştür. Bu durum, modelin oldukça yüksek doğrulukla tahminler yaptığını ortaya koymaktadır. Üst sağdaki histogramda hata dağılımı verilmiş olup hatalar -0.75×10^{-17} ile $+1.25 \times 10^{-17}$ aralığında dağılmıştır. Dağılım genel olarak simetrik ve ortalama hata sifıra yakın seyretmektedir. Alt sol grafik, hata değerlerinin zaman eksenine göre örnek bazında dağılımını göstermektedir. Burada, hata değerlerinin rastgele dağılmış olması sistematik bir önyargı olmadığını işaret etmektedir. Alt sağ grafikte ise gerçek ve tahmin edilen hacim değerleri zaman ekseninde birlikte gösterilmiş ve iki eğrinin büyük ölçüde çakıştığı görülmüştür. Bu durum, modelin zaman boyunca tutarlı ve başarılı tahmin performansı sergilediğini kanıtlamaktadır. Şekil 7.38’de, aynı deney koşulları altında (25 gr KOH, 7200 sn) elde edilen oksijen gazı hacmi (Volume O₂) için Random Forest modelinin tahmin sonuçlarını göstermektedir. Üst sol grafikte, tahmin edilen değerler ile gerçek değerlerin karşılaştırması sunulmuş, verilerin tamamına yakınının kırmızı $y = x$ doğrusuna çok yakın konumlandığı gözlemlenmiştir. Bu, modelin oldukça hassas tahminler yaptığını göstermektedir. Üst sağdaki histogram, hata dağılımını içermekte olup hataların genellikle $\pm 4 \times 10^{-18}$ aralığında ve ortalama hata çevresinde toplandığı görülmektedir. Hataların dengeli ve simetrik yapıda olması, modelin genelleme başarısını desteklemektedir. Alt sol grafikte ise hata değerlerinin örnek bazlı zaman ekseninde dağılımı yer almakta ve bu dağılımda sistematik bir sapma gözlenmemektedir. Alt sağ grafikte, gerçek ve tahmin edilen O₂ hacimleri zaman içinde karşılaştırılmış ve her iki eğrinin büyük ölçüde üst üste bindiği görülmüştür. Bu da Random Forest modelinin oksijen üretimi için de zaman boyunca yüksek doğruluk ve istikrarla çalıştığını ortaya koymaktadır.

Tablo 7.9. 25 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
25 gr 7200	H2(L)	RandomForest	1	5,34337E-18	2,85516E-35	4,74308E-18
25 gr 7200	H2(L)	KNN	1	0	0	0
25 gr 7200	H2(L)	LinearRegression	1	4,70099E-19	2,20993E-37	3,43331E-19

25 gr 7200	H2(L)	DecisionTree	1	5,1513E-18	2,65359E-35	3,99468E-18
25 gr 7200	H2(L)	GradientBoosting	0,99999857	9,13739E-08	8,34918E-15	3,61164E-08
25 gr 7200	O2(L)	RandomForest	1	2,58216E-18	6,66753E-36	2,2693E-18
25 gr 7200	O2(L)	KNN	1	0	0	0
25 gr 7200	O2(L)	LinearRegression	1	3,03931E-19	9,23743E-38	2,46505E-19
25 gr 7200	O2(L)	DecisionTree	1	2,56814E-18	6,59534E-36	1,9984E-18
25 gr 7200	O2(L)	GradientBoosting	0,99999855	4,60313E-08	2,11888E-15	1,81294E-08

25 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.37. 25 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.38. 25 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.10'da 27.5 gr KOH ve 7200 saniyelik deney süresi ile oluşturulan çözelti için elde edilen regresyon sonuçları, tüm modellerin yüksek doğrulukta çalıştığını bir kez daha ortaya koymaktadır. Hem hidrojen (H₂) hem de oksijen (O₂) hacim tahminlerinde, Random Forest, KNN, Linear Regression ve Decision Tree modelleri, $R^2 = 1.0$ değeri ile neredeyse kusursuz tahmin performansı sergilemiştir. Bu modellerin RMSE, MSE ve MAE değerleri sıfıra çok yakın olup, özellikle KNN modeli hata metriklerinde sıfır değeriyle ideal uyumu yakalamıştır. Gradient Boosting Regressor bu çözültide diğer modellere göre biraz daha farklılık göstermiş olsa da R^2 değeri H₂ için 0.99999957, O₂ için 0.99999952 olarak oldukça yüksek seviyededir. RMSE değerleri sırasıyla 5.06×10^{-8} (H₂) ve 2.66×10^{-8} (O₂) düzeyindedir. Bu küçük sapmalar, modelin iteratif doğası ve tahmin hassasiyetinin sınırlarını yansıtmaktadır. Sonuç olarak, 27.5 gr çözelti koşulunda da tüm modeller sistem akımı ile gaz üretimi arasındaki ilişkiyi doğru şekilde modelleyebilmiş, özellikle doğrusal yapıya sahip modeller çok düşük hata ile yüksek performans göstermiştir. Şekil 7.39'da 27,5 gram KOH çözeltisi ve 7200 saniyelik deney süresi ile üretilen hidrojen gazı hacmi (Volume H₂) için Random Forest modelinin tahmin performansına ilişkin dört alt grafik sunmaktadır. Üst sol grafikte tahmin edilen ve gerçek


değerlerin karşılaştırması yer almakta; verilerin kırmızı kesikli $y = x$ doğrusuna oldukça yakın konumlanması modelin yüksek doğrulukta tahmin yaptığını göstermektedir. Üst sağdaki histogram, hata dağılımını sunmakta olup hataların çoğunun -8×10^{-18} ile $+6 \times 10^{-18}$ aralığında yoğunlaştığı ve ortalama hatanın sifıra oldukça yakın olduğu görülmektedir. Bu durum, modelin dengeleme başarısını ve önyargısız tahmin yeteneğini yansıtmaktadır. Alt sol grafik, hata değerlerinin zamana göre örnek bazlı dağılımını göstermekte; hatalar rastlantısal ve geniş bir spektrumda dağılmıştır. Alt sağ grafikte ise zaman ekseninde tahmin edilen ve gerçek hacimler birlikte çizilmiş, eğrilerin çakışması modelin tutarlılık ve zaman bağımsız başarı düzeyini açıkça ortaya koymuştur. Şekil 7.40'ta, aynı koşullarda gerçekleştirilen deneyde oksijen gazı hacmi (Volume O₂) tahminlerinin Random Forest modeliyle elde edilen sonuçlarını analiz etmektedir. Üst sol grafikte, tahmin edilen ve gerçek O₂ hacimlerinin karşılaştırılması yapılmış ve verilerin çoğunluğunun $y = x$ doğrusu üzerinde toplandığı gözlemlenmiştir. Bu durum, modelin tahmin gücünün oldukça yüksek olduğunu göstermektedir. Üst sağdaki histogram, tahmin hatalarının -4×10^{-18} ile $+3 \times 10^{-18}$ aralığında simetrik biçimde dağıldığını ve ortalama hatanın sifıra çok yakın olduğunu göstermektedir. Bu, modelin kararlı tahmin kabiliyetini desteklemektedir. Alt sol grafik, hata değerlerinin zaman ekseninde örnek bazlı dağılımını sunmakta ve hataların rastgele dalgalanma gösterdiğini ortaya koymaktadır. Alt sağ grafikte ise tahmin ve gerçek değerler zaman ekseninde üst üste çizilmiş olup, iki eğrinin neredeyse tamamen çakıştığı gözlemlenmektedir. Bu durum, Random Forest modelinin O₂ tahminlerinde de yüksek doğruluk ve zaman boyunca tutarlı performans sağladığını kanıtlamaktadır.

Tablo 7.10. 27,5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
27,5 gr 7200	H2(L)	RandomForest	1	3,52889E-18	1,24531E-35	2,77104E-18
27,5 gr 7200	H2(L)	KNN	1	0	0	0
27,5 gr 7200	H2(L)	LinearRegression	1	3,80931E-19	1,45108E-37	2,59305E-19
27,5 gr 7200	H2(L)	DecisionTree	1	4,86051E-18	2,36246E-35	3,71881E-18
27,5 gr 7200	H2(L)	GradientBoosting	0,99999957	5,06166E-08	2,56204E-15	2,3352E-08

27,5 gr 7200	O2(L)	RandomForest	1	1,74131E-18	3,03216E-36	1,39636E-18
27,5 gr 7200	O2(L)	KNN	1	0	0	0
27,5 gr 7200	O2(L)	LinearRegression	1	3,00148E-19	9,00886E-38	2,40482E-19
27,5 gr 7200	O2(L)	DecisionTree	1	2,47807E-18	6,14082E-36	1,91467E-18
27,5 gr 7200	O2(L)	GradientBoosting	0,99999952	2,65774E-08	7,0636E-16	1,24944E-08

27,5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.39. 27.5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.40. 27.5 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.11’de 30 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözeltide yapılan regresyon analizleri, önceki çözelti oranlarında gözlemlenen yüksek doğruluk eğilimini korumaktadır. Hem hidrojen (H₂) hem de oksijen (O₂) hacimlerinin tahmininde, Random Forest, KNN, Linear Regression ve Decision Tree modelleri son derece başarılı sonuçlar vermiştir. Bu dört modelin tamamında R² değeri 1.0 olup, tahmin hataları (RMSE, MSE, MAE) sıfıra çok yakın değerlere ulaşmıştır. Özellikle KNN modeli, H₂ ve O₂ için sıfıra çok yakın hata metrikleriyle eğitim verisine neredeyse eksiksiz bir şekilde uyum sağlamıştır. Bununla birlikte, Gradient Boosting Regressor modeli yine oldukça yüksek bir performans göstermiş ancak diğer modellere göre biraz daha yüksek hata değerleri üretmiştir. H₂ için R² = 0.99999804, O₂ için de yine 0.99999804 olarak gerçekleşmiş, RMSE değerleri sırasıyla 1.53×10⁻⁷ (H₂) ve 7.67×10⁻⁸ (O₂) olmuştur. Bu değerler, Gradient Boosting modelinin doğruluk seviyesinin hâlâ çok yüksek olduğunu göstermekte ancak diğer yöntemlerle karşılaştırıldığında daha küçük farklılıklar ortaya koymaktadır. Sonuç olarak, 30 gr çözelti altında da sistem akımı ile gaz üretim miktarları arasındaki güçlü doğrusal ilişki tüm modeller tarafından başarıyla öğrenilmiş ve tahmin edilmiştir. Şekil 7.41’de, 30 gram KOH çözeltisi kullanılarak 7200 saniye boyunca


gerçekleştirilen deneyde üretilen hidrojen gazı hacminin (Volume H₂) Random Forest modeli ile tahminine yönelik analiz sonuçlarını göstermektedir. Üst sol grafikte, tahmin edilen değerler ile gerçek değerler karşılaştırılmış; noktaların büyük çoğunluğu kırmızı kesikli $y = x$ doğrusuna hizalanmıştır. Bu durum, modelin yüksek doğrulukta tahminler yaptığını göstermektedir. Üst sağdaki histogram, hata dağılımını sunmaktadır. Hataların genellikle $-7,5 \times 10^{-18}$ ile $+7,5 \times 10^{-18}$ arasında yoğunlaştığı ve ortalama hatanın sıfıra oldukça yakın olduğu gözlemlenmiştir. Alt sol grafikte hata değerlerinin örnek bazlı dağılımı verilmiş; hataların düzensiz ve rastlantısal biçimde dağıldığı görülmektedir. Bu, modelin sistematik bir önyargı taşımadığını göstermektedir. Alt sağ grafikte ise zaman ekseninde gerçek ve tahmin edilen H₂ hacimleri karşılaştırılmış, iki eğrinin büyük ölçüde çakıştığı gözlemlenmiştir. Bu çakışma, Random Forest modelinin zaman boyunca tutarlı ve başarılı tahminler yaptığını ortaya koymaktadır. Şekil 7.42’de, aynı deneysel koşullar altında elde edilen oksijen gazı hacmi (Volume O₂) verilerinin Random Forest modeli ile tahmin sonuçlarını analiz etmektedir. Üst sol grafikte, tahmin edilen ve gerçek değerler karşılaştırılmış; verilerin tamamına yakınının kırmızı $y = x$ doğrusuna çok yakın konumlandığı görülmüştür. Bu da modelin yüksek doğrulukta oksijen tahmini yaptığını göstermektedir. Üst sağdaki histogramda, hata değerlerinin büyük kısmı -4×10^{-18} ile $+4 \times 10^{-18}$ aralığında yoğunlaşmıştır. Ortalama hatanın sıfıra yakın olması modelin önyargısız ve dengeli çalıştığını göstermektedir. Alt sol grafikte, hata değerlerinin zaman eksenine göre örnek bazlı dağılımı sunulmuş ve hataların rastgele dağılması sistematik hata bulunmadığını işaret etmiştir. Alt sağ grafikte, zaman eksenini boyunca gerçek ve tahmin edilen O₂ hacimlerinin karşılaştırılması yapılmış; çizgiler neredeyse tamamen üst üste binmiş, bu da modelin oksijen tahmininde de oldukça güvenilir ve kararlı sonuçlar ürettiğini ortaya koymuştur.

Tablo 7.11. 30 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözeltili	Target	Model	R2	RMSE	MSE	MAE
30 gr 7200	H2(L)	RandomForest	1	4,25286E-18	1,80868E-35	3,50589E-18
30 gr 7200	H2(L)	KNN	1	1,51185E-19	2,28568E-38	5,27043E-20
30 gr 7200	H2(L)	LinearRegression	1	5,94282E-19	3,53171E-37	4,51149E-19

30 gr 7200	H2(L)	DecisionTree	1	5,20521E-18	2,70942E-35	3,79742E-18
30 gr 7200	H2(L)	GradientBoosting	0,99999804	1,53242E-07	2,34831E-14	7,88296E-08
30 gr 7200	O2(L)	RandomForest	1	1,86145E-18	3,465E-36	1,55899E-18
30 gr 7200	O2(L)	KNN	1	8,77839E-20	7,70602E-39	3,55377E-20
30 gr 7200	O2(L)	LinearRegression	1	3,85193E-19	1,48374E-37	3,21345E-19
30 gr 7200	O2(L)	DecisionTree	1	4,07422E-18	1,65993E-35	2,71547E-18
30 gr 7200	O2(L)	GradientBoosting	0,99999804	7,66516E-08	5,87547E-15	3,94161E-08

30 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.41. 30 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.42. 30 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.12’de, 32.5 gr KOH ve 7200 saniyelik deney süresi ile hazırlanan çözelti için uygulanan regresyon analizleri, gaz üretimi tahmininde tüm modellerin oldukça yüksek doğruluk seviyelerine ulaştığını göstermektedir. Random Forest, KNN, Linear Regression ve Decision Tree modelleri hem hidrojen (H_2) hem de oksijen (O_2) gazlarının hacimlerini tahmin etmede $R^2 = 1.0$ değeri ile teorik olarak mükemmel bir uyum sağlamıştır. Bu modellerin hata metrikleri (RMSE, MSE, MAE) de sıfıra çok yakın olup, modelin tahmin performansının son derece başarılı olduğunu kanıtlamaktadır. Özellikle KNN ve Linear Regression modelleri, düşük hata oranlarıyla birlikte yüksek stabilite sunmaktadır. Gradient Boosting Regressor modeli ise H_2 için $R^2 = 0.99999926$ ve O_2 için $R^2 = 0.99999925$ ile yine çok yüksek bir başarı göstermiştir. Ancak, diğer modellere göre hata metrikleri daha yüksek seviyededir: H_2 için RMSE yaklaşık 8.69×10^{-8} , O_2 için ise 4.35×10^{-8} olarak hesaplanmıştır. Bu küçük farklara rağmen, Gradient Boosting modeli de tahmin görevini başarıyla yerine getirmiştir. Sonuç olarak, 32.5 gr çözelti altında da sistem akımı ile gaz üretimi arasındaki ilişki oldukça güçlüdür ve tüm regresyon modelleri bu ilişkiyi yüksek doğrulukla temsil etmektedir. Şekil 7.43’te 32,5 gram KOH çözeltisi ile 7200 saniye boyunca gerçekleştirilen deneyde üretilen hidrojen gazı hacminin


(Volume H₂) Random Forest modeliyle tahminine ilişkin dört grafiği göstermektedir. Üst sol grafikte yer alan tahmin vs gerçek karşılaştırması, verilerin kırmızı kesikli $y = x$ doğrusuna son derece yakın hizalandığını ortaya koymuştur; bu da modelin yüksek doğrulukta çalıştığını açıkça göstermektedir. Üst sağdaki histogram, hata dağılımını sunmakta olup hataların çoğu $-7,5 \times 10^{-18}$ ile $+7,5 \times 10^{-18}$ aralığında toplanmış ve ortalama hata sıfıra oldukça yakın çıkmıştır. Alt sol grafikte, örnek bazında hata dağılımı zamana göre gösterilmiş; hataların rastgele dağılması modelin sistematik sapma içermediğini ortaya koymaktadır. Alt sağdaki zaman serisi grafiğinde ise gerçek ve tahmin edilen değerler neredeyse tamamen üst üste binmiş, bu da Random Forest algoritmasının zaman boyutunda da kararlı ve güvenilir tahmin performansı sunduğunu göstermektedir. Şekil 7.44'te aynı deneysel koşullarda üretilen oksijen gazı hacmi (Volume O₂) tahminlerinin Random Forest modeli ile elde edilen sonuçlarını içermektedir. Üst sol grafikte, tahmin edilen ve gerçek değerler karşılaştırılmış ve verilerin büyük ölçüde kırmızı $y = x$ doğrusu üzerinde konumlandığı gözlemlenmiştir. Bu durum, modelin oldukça isabetli tahminler yaptığını göstermektedir. Üst sağdaki histogram, hata dağılımını göstermekte olup değerlerin çoğu $\pm 4 \times 10^{-18}$ aralığında yoğunlaşmıştır. Ortalama hatanın sıfıra yakınlığı modelin dengeli ve önyargısız çalıştığını göstermektedir. Alt sol grafikteki hata grafiği, hata değerlerinin zamana göre dağılımını sunmakta ve bu dağılımın düzensizliği sistematik hata olmadığını göstermektedir. Alt sağdaki zaman serisi grafiği ise tahmin ve gerçek değerlerin yüksek derecede çakıştığını göstererek, Random Forest modelinin zaman içinde O₂ hacmini yüksek doğrulukla tahmin ettiğini bir kez daha teyit etmektedir.

Tablo 7.12. 32.5 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
32,5 gr 7200	H2(L)	RandomForest	1	4,06511E-18	1,65251E-35	3,38151E-18
32,5 gr 7200	H2(L)	KNN	1	2,78537E-19	7,75826E-38	1,78893E-19
32,5 gr 7200	H2(L)	LinearRegression	1	6,41219E-19	4,11162E-37	4,70423E-19
32,5 gr 7200	H2(L)	DecisionTree	1	4,54765E-18	2,06811E-35	3,60497E-18
32,5 gr 7200	H2(L)	GradientBoosting	0,99999926	8,68798E-08	7,5481E-15	4,44689E-08

32,5 gr 7200	O2(L)	RandomForest	1	2,40791E-18	5,79803E-36	2,06827E-18
32,5 gr 7200	O2(L)	KNN	1	1,52796E-19	2,33466E-38	1,07667E-19
32,5 gr 7200	O2(L)	LinearRegression	1	3,82086E-19	1,4599E-37	3,06438E-19
32,5 gr 7200	O2(L)	DecisionTree	1	2,24712E-18	5,04956E-36	1,70927E-18
32,5 gr 7200	O2(L)	GradientBoosting	0,99999925	4,35263E-08	1,89454E-15	2,22737E-08

32,5 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.43. 32.5 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.44. 32.5 gr için Random Forest ile O Tahmin ve hata değerleri

Tablo 7.13'te 35 gr KOH ve 7200 saniyelik deney süresi ile elde edilen çözeltiye ait regresyon analizleri, tüm modellerin tahmin performanslarının oldukça yüksek seviyelerde olduğunu ortaya koymaktadır. Hem hidrojen (H_2) hem de oksijen (O_2) gazlarının hacimsel tahminlerinde, Random Forest, KNN, Linear Regression ve Decision Tree modelleri, $R^2 = 1.0$ değeri ile teorik olarak mükemmel doğruluk sergilemiş; buna paralel olarak RMSE, MSE ve MAE gibi hata metrikleri de sıfıra oldukça yakın değerlerde kalmıştır. Özellikle KNN ve Linear Regression modelleri çok düşük hata oranlarıyla dikkat çekmiş; Decision Tree modelinde ise hata değerleri nispeten daha yüksek olsa da genel doğruluk kaybı olmamıştır. Gradient Boosting Regressor modeli de bu çözümlerde üstün performans göstermeye devam etmiş, H_2 için $R^2 = 0.99999978$, O_2 için $R^2 = 0.99999974$ değerlerine ulaşmıştır. H_2 için RMSE yaklaşık 3.38×10^{-8} , O_2 için ise 1.85×10^{-8} olarak hesaplanmıştır. Bu düşük hata değerleri, Gradient Boosting'in yüksek tahmin doğruluğunu koruduğunu göstermektedir. Genel olarak, 35 gr çözelti oranında da sistem akımı ile gaz üretim hacimleri arasındaki ilişki regresyon modelleri tarafından başarılı bir şekilde öğrenilmiş ve tahmin edilmiştir. Tüm yöntemler yüksek doğruluk düzeyinde çalışmış, Gradient Boosting modeli ise küçük farklarla diğerlerinden biraz


ayrılmıştır. Şekil 7.45'te, 35 gramlık KOH çözeltisinin 7200 saniye boyunca elektroliz edilmesiyle elde edilen hidrojen gazı hacminin (Volume H₂) Random Forest modeliyle tahminine ilişkin analizleri göstermektedir. Üst sol kısımda yer alan "Gerçek vs Tahmin" grafiğinde veriler, kırmızı kesikli $y = x$ doğrusu üzerinde düzgün bir şekilde dizilmiş olup modelin oldukça yüksek doğrulukla çalıştığını göstermektedir. Üst sağdaki histogramda hataların dağılımı simetrik bir yapıya sahip olup -1×10^{-17} ile $+1 \times 10^{-17}$ arasında yoğunlaşmıştır. Ortalama hata sıfıra oldukça yakındır ve bu durum modelin önyargısız bir tahmin süreci gerçekleştirdiğini göstermektedir. Alt sol grafikte hata değerlerinin zamana bağlı olarak dağılımı rastgele bir örüntü sergilemektedir ve belirgin bir sistematik hata bulunmamaktadır. Alt sağ grafikte ise gerçek ve tahmin edilen hacimlerin zaman boyunca örtüştüğü görülmekte olup modelin zaman serisi bazlı tahminlerde de istikrarlı performans gösterdiği anlaşılmaktadır. Şekil 7.46'da aynı deneysel koşullarda oluşan oksijen gazı hacminin (Volume O₂) Random Forest algoritmasıyla tahmin sonuçlarını sunmaktadır. Üst sol grafikteki karşılaştırma, tahmin ve gerçek değerlerin neredeyse tamamen $y = x$ doğrusuyla çakıştığını ortaya koymaktadır. Bu, modelin oksijen tahminlerinde de yüksek isabet sağladığını göstermektedir. Hata dağılımını gösteren üst sağdaki histogram, hataların büyük çoğunluğunun -6×10^{-18} ile $+6 \times 10^{-18}$ arasında kaldığını göstermektedir. Ortalama hata çizgisi sıfıra çok yakın konumlanmıştır. Alt sol grafikteki hata grafiğinde de hataların örnekler boyunca rastgele dağılması, tahmin sürecinin dengeli ve sistematik bir sapma içermediğini göstermektedir. Alt sağ grafikte yer alan zaman serisi karşılaştırmasında ise tahmin edilen ve gerçek değerler çakışarak, modelin zaman boyunca doğruluğunu koruyarak O₂ hacmini başarılı bir şekilde tahmin ettiğini göstermektedir.

Tablo 7.13. 35 gr KOH ait H₂ ve O₂ Gazı Hacmi Tahmin Sonuçları


Çözelti	Target	Model	R2	RMSE	MSE	MAE
35 gr 7200	H2(L)	RandomForest	1	6,69945E-18	4,48826E-35	5,52672E-18
35 gr 7200	H2(L)	KNN	1	1,60813E-19	2,58609E-38	5,96311E-20
35 gr 7200	H2(L)	LinearRegression	1	4,60697E-19	2,12242E-37	2,61714E-19
35 gr 7200	H2(L)	DecisionTree	1	9,92774E-18	9,856E-35	7,51834E-18

35 gr 7200	H2(L)	GradientBoosting	0,99999978	3,38096E-08	1,14309E-15	8,94026E-09
35 gr 7200	O2(L)	RandomForest	1	3,61665E-18	1,30802E-35	3,09133E-18
35 gr 7200	O2(L)	KNN	1	5,93842E-20	3,52648E-39	1,6263E-20
35 gr 7200	O2(L)	LinearRegression	1	4,63348E-19	2,14691E-37	3,32639E-19
35 gr 7200	O2(L)	DecisionTree	1	7,9473E-18	6,31595E-35	6,30569E-18
35 gr 7200	O2(L)	GradientBoosting	0,99999974	1,85251E-08	3,43178E-16	4,8547E-09

35 gr 7200 - Volume H2(L) - RandomForest



Şekil 7.45. 35 gr için Random Forest ile H Tahmin ve hata değerleri



Şekil 7.46. 35 gr için Random Forest ile O Tahmin ve hata değerleri

Bu çalışmada, 5 gr ile 35 gr arasında değişen KOH (potasyum hidroksit) derişimleriyle hazırlanan çözeltiler için sistem akımı kullanılarak hidrojen (H_2) ve oksijen (O_2) gazı üretiminin tahmini, beş farklı regresyon modeli aracılığıyla gerçekleştirilmiştir. Her bir gr değerinde aynı deney süresi (7200 saniye) korunmuş ve tahmin doğrulukları R^2 , RMSE, MSE ve MAE metrikleriyle değerlendirilmiştir. Elde edilen sonuçlar, her çözelti oranı için model performanslarının tutarlı ve yüksek doğrulukta olduğunu göstermektedir. Tüm derişim aralıklarında, özellikle KNN, Random Forest, Linear Regression ve Decision Tree modelleri hem H_2 hem de O_2 tahminlerinde $R^2 = 1,0$ değerine ulaşmış ve hata metriklerinde sıfıra çok yakın (bazı durumlarda sıfır) sonuçlar üretmiştir. Bu durum, gaz üretimi ile sistem akımı arasında çok belirgin, doğrusal ve deterministik bir ilişkinin bulunduğunu, modellerin bu ilişkiyi başarıyla öğrendiğini göstermektedir. Gradient Boosting Regressor ise tüm çözeltilerde çok yüksek ancak diğer modellere kıyasla biraz daha düşük R^2 (genellikle 0.999996–0.999999 aralığında) ve daha yüksek hata değerleri (örneğin RMSE genellikle $10^{-8} - 10^{-7}$ aralığında) vermiştir. Bununla birlikte Gradient Boosting'in hata seviyeleri pratik olarak ihmal edilebilecek düzeyde olup, model genel anlamda istikrarlı bir başarı sergilemiştir. Sonuç olarak, farklı

gr değerlerine sahip çözeltiler için yapılan karşılaştırmada tüm regresyon modelleri yüksek doğrulukla çalışmış, özellikle KNN ve Random Forest modelleri en düşük hata düzeylerini sağlamıştır. Gradient Boosting ise doğrusal olmayan yapı ve genel genelleme kabiliyeti açısından önemli bir alternatif sunarken, çok küçük sapmalar dışında tüm gr seviyelerinde güvenilir sonuçlar vermiştir. Bu durum, sistemin modellemeye son derece uygun ve tahmine açık yapıda olduğunu, kullanılan algoritmaların ise bu yapıyı başarıyla temsil ettiğini ortaya koymaktadır.



8. TARTIŞMA VE SONUÇ

Bu çalışmada, farklı KOH (potasyum hidroksit) derişimlerine sahip çözeltilerde sistem akımı kullanılarak üretilen hidrojen (H_2) ve oksijen (O_2) gazlarının hacimsel tahminleri, çeşitli makine öğrenmesi algoritmalarıyla gerçekleştirilmiştir. Her bir çözelti oranı için deney süresi sabit tutulmuş (7200 saniye) ve modelleme sürecinde yalnızca sistem akımı girdisi ile H_2 ve O_2 üretim miktarları tahmin edilmiştir. Uygulanan modeller Random Forest, K-Nearest Neighbors (KNN), Linear Regression, Decision Tree ve Gradient Boosting Regressor'dur. Deneysel veriler üzerinden elde edilen sonuçlar, regresyon modellerinin tüm KOH derişim seviyelerinde oldukça başarılı tahminler gerçekleştirdiğini göstermiştir. Özellikle KNN, Random Forest, Linear Regression ve Decision Tree modelleri neredeyse tüm gr aralıklarında $R^2 \approx 1,0$ değerine ulaşmış, RMSE, MSE ve MAE hata metrikleri sıfıra çok yakın değerlerde hesaplanmıştır. Bu durum, sistem akımı ile gaz üretim hacimleri arasında doğrusal ve oldukça deterministik bir ilişkinin bulunduğunu ve söz konusu modellerin bu ilişkiyi çok yüksek doğrulukla öğrenebildiğini ortaya koymaktadır. Random Forest modeli hem doğruluk hem de kararlılık açısından en dengeli model olarak öne çıkmıştır. Tahmin edilen ve gerçek hacimlerin zaman ekseninde birlikte çizildiği grafiklerde, eğrilerin neredeyse birebir çakıştığı gözlemlenmiş; hata grafikleri ise rastgele ve sistematik önyargıdan uzak bir dağılım sergilemiştir. Histogram analizleri, hataların ortalama etrafında simetrik biçimde yoğunlaştığını ve modelin önyargısız tahminler gerçekleştirdiğini desteklemektedir. Gradient Boosting Regressor ise tüm derişim aralıklarında yüksek performans sergilemiş, ancak diğer modellere göre daha yüksek hata değerleriyle dikkat çekmiştir. R^2 değerleri genellikle 0.999996–0.999999 aralığında kalmış, RMSE değerleri ise 10^{-7} mertebesinde olmuştur. Bu küçük farklara rağmen Gradient Boosting, genelleme kabiliyeti ve kompleks veri yapılarıyla baş etme potansiyeli açısından önemli bir alternatif olarak değerlendirilebilir.

Çalışmada öne çıkan temel bulgulardan bazıları şu şekildedir:

- Tüm çözelti oranlarında sistem akımı, gaz üretim hacimlerinin güçlü bir belirleyicisi olarak doğrusal regresyon modelleri tarafından rahatlıkla öğrenilmiştir.

- KNN modeli, her çözültide sıfır hata ile mükemmel uyum göstermiş, ancak bu durum modelin aşırı öğrenme (overfitting) eğilimini de düşündürmektedir.
- Gradient Boosting gibi daha kompleks modellerin hata oranları biraz daha yüksek olmasına rağmen, sistemin genellenebilirliğine dair güçlü bulgular sunmuştur.
- Zaman serisi grafikleri, modellerin sadece noktasal doğruluk değil, aynı zamanda zamana yayılmış kararlı tahmin başarımına sahip olduğunu göstermiştir.

Bu kapsamlı modelleme çalışması, sistem akımının doğru ölçülmesi durumunda yalnızca bu tek değişkenle hidrojen ve oksijen üretim hacimlerinin tahmin edilebileceğini ve bunun yüksek doğrulukla başarılabileceğini göstermektedir. Bu sonuçlar, özellikle deneysel elektroliz süreçlerinin otomatik izlenmesi, kestirimci kontrol sistemlerinin geliştirilmesi ve üretim optimizasyonu açısından değerli uygulama alanları sunmaktadır.

KAYNAKLAR

- Agmon, N. (1995). “*The Grotthuss mechanism*,” Chemical Physics Letters, 244(5-6), 456–462.
- Aydın, Ö., (2021). PEM yakıt pillerinde genetik algoritmalar ile parametre optimizasyonu. Yüksek Lisans Tezi, Uludağ Üniversitesi, <http://acikerisim.uludag.edu.tr>
- Aydın, Ö., (2023). PEM yakıt pillerinde geometrik ve çalışma parametrelerinin performans üzerine etkisi. Yüksek Lisans Tezi, Uludağ Üniversitesi, <https://acikerisim.uludag.edu.tr/bitstreams/dfb340c6-60a7-4879-82cb-e4e40c0e2dc2/download>
- Bakangura, E., Wu, L., Ge, L., Yang, Z., Xu, T. (2016). “*Mixed Matrix Proton Exchange Membranes for Fuel Cells: State of the Art and Perspectives*,” Progress in Polymer Science, 57, 103–152
- Barbir, F., (2003). Review of Hydrogen Conversion Technologies. Available at: <http://www.iahe.org> Accessed
- Barbir, F., (2005). PEM Fuel Cells: *Theory and Practice*. Elsevier Academic Press, Burlington, MA, pp. 1-30.
- Baroutaji, A., Wilberforce, T., Ramadan, M., Olabi, A.G., (2021). *Comprehensive investigation on hydrogen and fuel cell technology in the aviation and aerospace sectors*. Renewable and Sustainable Energy Reviews, 106, pp. 31-40.
- C. Spiegel, PEM Fuel Cell Modeling and Simulation Using MATLAB, Elsevier, (2008).
- Cindrella, L., Kannan, A. M., Lin, J. F., Saminathan, K., Ho, Y., Lin, C. W., & Wertz, J. (2009). *Gas diffusion layer for proton exchange membrane fuel cells—A review*. Journal of Power Sources, 194(1), 146-160. DOI: 10.1016/j.jpowsour.2009.04.005
- Czajkowski, M., & Kretowski, M. (2016). The role of decision tree representation in regression problems—An evolutionary perspective. Applied soft computing, 48, 458-475.
- Çelik, M., & Bozkurt, A. (2020). PEM Yakıt Hücreleri için Sülfone Polieter Eter Keton (sPEEK) Elektrolitlerin Sentezi ve Karakterizasyonu: Sülfonasyon Derecesi Etkisi. ECJSE, 2020(2), 424-435.
- Çetinkaya, M., Karaosmanoğlu, F., (2003). Yakıt Pilleri. Tesisat Mühendisliği, 75, pp. 18-33.
- Dalğıç, B. F. (2019). PEM yakıt hücresinde hidrojen gazındaki nem oranına bağlı olarak elektrik üretimindeki değişimin incelenmesi. Batman Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.

- E.A. Mohamed Ali et al. (2011) "A survey of the relevance of control systems for PEM fuel cells." International Conference on Computer, Communication and Electrical Technology (ICCCET) (2011): 322-326.
<https://doi.org/10.1109/ICCCET.2011.5762494>.
- El Mrabet, Z., Sugunaraaj, N., Ranganathan, P., & Abhyankar, S. (2022). Random forest regressor-based approach for detecting fault location and duration in power systems. *Sensors*, 22(2), 458.
- Erdem, E. (2005). Sülfonlanmış Polistrenin Polimer Elektrolit Membran Yakıt Hücresinde Elektrolit Olarak Denenmesi. Thesis, DOI: 10.13140/RG.2.2.12345.67890.
- Erdener, H. ve ark., (2013), *Sürdürülebilir Enerji ve Hidrojen*, ODTÜ Yayıncılık, Ankara, 23-65.
- Erdoğan, S., (2003). Alternatif Enerji Kaynakları ve Türkiye'nin Enerji Potansiyeli. *Electrotech*, 32, pp. 55-59.
- Ewald, R., (1998). Requirements for Advanced Mobile Storage Systems. *International Journal of Hydrogen Energy*, 23(9), pp. 803-814
- Genç, Ö., & Kallioğlu, M. A. (2018). "Proton Elektrolit Membranlı (PEM) Elektrolizörün Sayısal İncelenmesi ve Deneysel Doğrulanması."
- Imandoust, S. B., & Bolandraftar, M. (2013). Application of k-nearest neighbor (knn) approach for predicting economic events: *Theoretical background*. *International journal of engineering research and applications*, 3(5), 605-610.
- Kahraman, Huseyin, and Mehmet F. Orhan (2017). "Flow field bipolar plates in a proton exchange membrane fuel cell: Analysis & modeling." *Energy Conversion and Management* 133: 363-384.
- Kapusuz, N. E. (2025). Polimer Elektrolit Membran (PEM) Elektrolizör için Membran Sentezi ve Karakterizasyonu. Ondokuz Mayıs Üniversitesi, Kimya Mühendisliği Anabilim Dalı.
- Karanfil, G. (2020). "Proton Exchange Membrane Fuel Cells: Thermodynamics, Components and Applications," *Engineer and Machinery*, 61(698), 57-76
- Keprate, A., & Ratnayake, R. C. (2017). Using gradient boosting regressor to predict stress intensity factor of a crack propagating in small bore piping. In 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM) (pp. 1331-1336). IEEE
- Khalyasmaa, A., Eroshenko, S. A., Chakravarthy, T. P., Gasi, V. G., Bollu, S. K. Y., Caire, R., ... & Karrolla, S. (2019). Prediction of solar power generation based on random forest regressor model. In 2019 International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON) (pp. 0780-0785). IEEE

- Kreuer, K. D. (1996). "Proton conductivity: Materials and mechanisms," Solid State Ionics, 97(1-4), 1–15
- Kılıç, M., (2023). Yakıt pillerinin tarihsel gelişimi, çalışma prensipleri ve sıcaklık etkileri. ResearchGate, <https://www.researchgate.net/publication/369089564YakitPillerininTarihselGelistirilmesi>
- Larminie, J., Dicks, A., (2003). Fuel Cell Systems Explained. John Wiley & Sons, West Sussex, UK, pp. 67-89.
- Lee, Ha Eun, Yong Sik Chung, and Seong Su Kim (2017). "Feasibility study on carbon-felt-reinforced thermoplastic composite materials for PEMFC bipolar plates." Composite Structures 180: 378-385.
- Li, H., Tang, Y., Wang, Z., Shi, Z., Wu, S., Song, D., Zhang, J., Fatih, K., Zhang, J., Wang, H., Liu, Z., Abouatallah, R., Mazza, A., (2008). A review of water management in polymer electrolyte membrane fuel cells. Journal of Power Sources, 178(1), pp. 103-117.
- Liu, Y., Wang, Z., Zhang, X., Zhang, L., & Zhang, J. (2019). Temperature and humidity effects on PEM fuel cell performance: A comprehensive study. Energy Conversion and Management, 196, 1343–1354.
- Marx, D., Tuckerman, M. E., Hutter, J., & Parrinello, M. (1999). "The nature of the hydrated excess proton in water," Nature, 397(6719), 601–604
- Ogungbemi, E., Ijaodola, O., & Wilberforce, T. (2024). Recent studies on proton exchange membrane fuel cell components: Membranes and bipolar plates. International Journal of Hydrogen Energy, 59, 123–134. <https://doi.org/10.1016/j.ijhydene.2024.01.123>
- Özden, A., (2019). PEM yakıt hücresi performansını etkileyen parametrelerin yapay sinir ağları ile modellenmesi. Naber Elektronik Kataloğu, İstanbul Üniversitesi, <http://nek.istanbul.edu.tr>.
- Özden, A., (2023). PEM yakıt hücresi performansını etkileyen fiziksel parametreler. Naber Elektronik Kataloğu, İstanbul Üniversitesi, <https://nek.istanbul.edu.tr/ekos/TEZ/48754.pdf>
- Park, S., Lee, J. W., & Popov, B. N. (2012). A review of gas diffusion layer in PEM fuel cells: Materials and designs. International Journal of Hydrogen Energy, 37(7), 5850-5865. DOI: 10.1016/j.ijhydene.2011.12.148
- Peter, S., Diego, F., Hamprecht, F. A., & Nadler, B. (2017). Cost efficient gradient boosting. Advances in neural information processing systems, 30.
- Sammes, N., Bove, R., & Stahl, K. (2004). Phosphoric acid fuel cells: Fundamentals and applications. Current Opinion in Solid State and Materials Science, 8(5), 372-378.

- Santos, D. M. F., & Sequeira, C. A. C. (2025). Advancements in PEM fuel cell technology: Evaluating the performance parameters. *Fuel Cells*, 25(1), 12-28. <https://doi.org/10.1002/fuce.202400123>
- Sethuraman, V. A., Weidner, J. W., Haug, A. T., Motupally, S., & Protsailo, L. V. (2020). Understanding hydrogen peroxide formation in PEM fuel cells: Effect of humidity and temperature. *Electrochimica Acta*, 362, 137225. [https://doi.org/10.1016/j.electacta.\(2020\).137225](https://doi.org/10.1016/j.electacta.(2020).137225).
- Sevim, D. (2016). Ozon jeneratörü tasarımı ve ozonlama koşullarının optimizasyonunun sağlanması (Doktora tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü). Gazi Üniversitesi Tez Merkezi.
- Şahinler, S. (2000). En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturma temel prensipleri. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 5(1-2), 57-73
- Taner, T., Eroğlu, L., (2008), Geleceğin Enerjisi Proton Değişimli Membran Yakıt Pili Su Yönetiminin Önemi, VII. Ulusal Temiz Enerji Sempozyumu, UTES' (2008), İstanbul, 735-741.
- Uyanık, G. K., & Güler, N. (2013). A study on multiple linear regression analysis. *Procedia-Social and Behavioral Sciences*, 106, 234-240.
- Veziroğlu, T., (1998). Hydrogen Energy Technologies. UNIDO, A 1400 Vienne, Austria, pp. 252-256.
- Victor, D., Müller, M., & Schneider, T. (2020). *Thermal management analysis of PEM fuel cells in confined spaces*. *Journal of Power Sources*, 450, 227626 [https://doi.org/10.1016/j.jpowsour.\(2019\).227626](https://doi.org/10.1016/j.jpowsour.(2019).227626)
- Wang, Y., Chen, K.S., Mishler, J., Cho, S.C., Adroher, X.C., (2011). A review of polymer electrolyte membrane fuel cells: Technology, applications, and needs on fundamental research. *Applied Energy*, 88(4), pp. 981-1007.
- Wang, Y., Zhang, J., Chen, K., (2020). *Machine learning-based thermal management optimization for PEM fuel cells*. *Journal of Power Sources*, 465, pp 228-239.
- Xu, M., Watanachaturaporn, P., Varshney, P. K., & Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322-336.
- Yıldız, B. İ., & Karabağ, K. (2025). Prediction of Beef Production Using Linear Regression, Random Forest and k-Nearest Neighbors Algorithms. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 28(1), 247-255.
- Yılmaz, S., (2024). Proton değişim membranı yakıt hücrelerinde termal yönetim ve enerji verimliliği. VI. Enerji Verimliliği Kongresi Bildiriler Kitabı, Makina Mühendisleri Odası, <http://www.mmo.org.tr>.