

**T.C.**  
**ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**FOTOVOLTAİK SİSTEMLERDE ARIZA VE HATA TESPİTİ İÇİN YAPAY ZEKÂ  
TABANLI KARAR DESTEK SİSTEMİ GELİŞTİRİLMESİ VE UYGULAMASI**

**Muhammed Buğrahan KAYA**

**Danışman: Prof. Dr. Naim Süleyman TİNÇ**

**TEZ JÜRİ ÜYELERİ**  
**Doç. Dr. Yakup ŞAHİN**  
**Dr. Öğr. Üyesi Aykut Görkem GELEN**

**YÜKSEK LİSANS TEZİ**  
**ERZİNCAN, 2026**

© 2026 [Muhammed Buğrahan KAYA]. Tüm hakları saklıdır.

### **Kabul ve Onay Sayfası**

Prof. Dr. Naim Süleyman TİNÇ danışmanlığında, Muhammed Buğrahan KAYA tarafından hazırlanan bu çalışma 02.07.2026 tarihinde aşağıdaki jüri tarafından Elektrik Elektronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul oybirliği ile kabul edilmiştir.

Başkan : Doç. Dr. Yakup ŞAHİN

İmza:

Üye : Prof. Dr. Naim Süleyman TİNÇ

İmza:

Üye : Dr. Öğr. Üyesi Aykut Görkem GELEN

İmza:

Yukarıdaki Yüksek Lisans/Doktora Tezi Enstitü Yönetim Kurulunun .... / .... / 20.... tarih ve ...../..... sayılı kararı ile onaylanmıştır.

**Doç. Dr. Kemal Volkan ÖZDOKUR**  
Enstitü Müdür V.

**Not:** Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, şekil ve tabloların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

## **Bilimsel Etięe Uygunluk Sayfası**

“Fotovoltaik Sistemlerde Arıza ve Hata Tespiti İin Yapay Zekâ Tabanlı Karar Destek Sistemi Geliştirilmesi ve Uygulaması” isimli “Yüksek Lisans” tezim tarafımca intihal tespit programı ile incelenmiştir. Buna göre tezimde bilimsel etik ihlali ve intihal olarak nitelendirilebilecek herhangi bir durum olmadığını taahhüt ederim.

Bu alışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir biçimde elde edildiğini; aynı zamanda bu kural ve davranışların gerektirdiğı gibi, bu alışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 02/07/2026

(İmza)

**Muhammed Buğrahan  
KAYA**

## ÖZET

# FOTOVOLTAİK SİSTEMLERDE ARIZA VE HATA TESPİTİ İÇİN YAPAY ZEKÂ TABANLI KARAR DESTEK SİSTEMİ GELİŞTİRİLMESİ VE UYGULAMASI

**Muhammed Buğrahan KAYA**

**Yüksek Lisans Tezi, Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri Enstitüsü,**

**Elektrik – Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Naim Süleyman TINÇ**

**2026, 55 sayfa**

Güneş enerji santrallerinin (GES) verimli ve güvenli işletilmesi, fotovoltaik (PV) arızaların otonom saptanmasına bağlıdır. Bu tez çalışmasında, Van/Başkale bölgesinde kurulu 10 kWp kapasiteli evsel bir PV sisteminden farklı mevsimsel koşullar ve operasyonel senaryolar altında elde edilen çok boyutlu kronolojik sensör verileri işlenerek; elektriksel analitik ve bilgisayarlı görüş tabanlı, çok modlu (multimodal) özgün bir karar destek sistemi (KDS) tasarlanmıştır.

İlk aşamada, sensör verileri üzerinde makine öğrenmesi (ML) ve derin öğrenme (DL) mimarilerinin arıza tespit performansları karşılaştırılmıştır. Denetimsiz ön süzme için Isolation Forest algoritması, denetimli güç tahmini için ise HistGradientBoosting (HGB) modeli kullanılarak istatistiksel kalıntı analiziyle hafif (lightweight) bir ML katmanı kurgulanmıştır. Bu altyapı, zamansal ve uzaysal öznitelikleri hiyerarşik olarak öğrenen 1D-CNN-LSTM Hibrit Autoencoder mimarisiyle doğruluk, F1-Skoru ve hesaplama maliyeti kriterlerine göre kıyaslanmıştır. Derin öğrenme modelinin "kara kutu" yapısını açıklamak amacıyla sisteme SHAP algoritması entegre edilerek açıklanabilir yapay zeka (XAI) katmanı oluşturulmuştur.

İkinci aşamada, elektriksel anomalilerin fiziksel nedenlerini (mikro-çatlak, kırık, kirlenme, gölgelenme) otonom doğrulamak için sahadan alınan panel görüntüleri Roboflow'da etiketlenmiş ve Transformer tabanlı RF-DETR nesne tespiti mimarisiyle eğitilmiştir. Fiziksel deformasyonlar %95'in üzerinde bir güven skoruyla başarıyla haritalandırılmıştır.

Son aşamada, tüm analitik ve görsel modeller Antigraity altyapısı kullanılarak bütünleşik bir kullanıcı arayüzüne dönüştürülmüştür. Geliştirilen KDS, iki farklı veri kaynağını füzyonlayarak

operatöre anlık "Tahmin Edilen Yüzdesel Verimlilik Kaybı (Loss %)" ve aksiyona yönelik "Bakım Önerileri" sunmaktadır. Ampirik bulgular, önerilen KDS altyapısının evsel GES projelerinde kestirimci bakım güvenilirliğini artırırken, operasyonel arıza sürelerini ve teknik bakım maliyetlerini önemli ölçüde düşürdüğünü kanıtlamaktadır.

**Anahtar Kelimeler:** Fotovoltaik sistemler, Arıza tespiti, Karşılaştırmalı analiz, CNN-LSTM Hybrid autoencoder, RF-DETR, Karar destek sistemi.

## **ABSTRACT**

# **DEVELOPMENT AND IMPLEMENTATION OF AN ARTIFICIAL INTELLIGENCE-BASED DECISION SUPPORT SYSTEM FOR FAULT DETECTION AND DIAGNOSIS IN PHOTOVOLTAIC SYSTEMS**

**Muhammed Buğrahan KAYA**

**Master's Thesis, Erzincan Binali Yıldırım University, Institute of Science and Technology,**

**Department of Electrical and Electronics Engineering**

**Advisor: Prof. Dr. Naim Süleyman TINÇ**

**2026, 55 pages**

The efficient and safe operation of Solar Power Plants (SPP) depends on the autonomous detection of photovoltaic (PV) faults. In this thesis, an original multimodal Decision Support System (DSS) based on electrical analytics and computer vision was designed by processing multidimensional chronological sensor data obtained from a 10 kWp domestic PV system installed in the Van/Başkale region under varying seasonal conditions and operational scenarios.

In the first stage, the fault detection performances of Machine Learning (ML) and Deep Learning (DL) architectures were compared on sensor data. A lightweight ML layer was constructed through statistical residual analysis, utilizing the Isolation Forest algorithm for unsupervised pre-filtering and the HistGradientBoosting (HGB) model for supervised power estimation. This infrastructure was benchmarked against a 1D-CNN-LSTM Hybrid Autoencoder architecture, which hierarchically learns temporal and spatial features, based on accuracy, F1-Score, and computational cost criteria. To clarify the "black box" nature of the deep learning model, an Explainable AI (XAI) layer was established by integrating the SHAP algorithm into the system.

In the second stage, to autonomously verify the physical causes of electrical anomalies (such as micro-cracks, fractures, soiling, and shading), panel images collected from the field were labeled on Roboflow and trained using the Transformer-based RF-DETR object detection

architecture. Physical deformations were successfully mapped with a confidence score exceeding 95%.

In the final stage, all analytical and visual models were integrated into a unified user interface using the Antigravity infrastructure. The developed DSS fuses two different data sources to provide the operator with instantaneous "Predicted Percentage of Efficiency Loss (%)" and action-oriented "Maintenance Recommendations." Empirical findings demonstrate that the proposed DSS infrastructure significantly enhances predictive maintenance reliability in domestic SPP projects while substantially reducing operational downtime and technical maintenance costs.

**Keywords:** Photovoltaic systems, Fault detection, Comparative analysis, CNN-LSTM Hybrid autoencoder, RF-DETR, Decision support system.

## TEŞEKKÜR

Bu tez çalışmasının planlanması, yürütülmesi ve sonuçlandırılması süreçlerinde; engin bilgi birikimi, akademik tecrübesi ve vizyonu ile bana her zaman yol gösteren, araştırmalarım boyunca desteğini ve sabrını hiçbir zaman esirgemeyen değerli danışman hocam Prof. Dr. Naim Süleyman TİNÇ'a en içten şükranlarımı sunarım. Çalışmalarım esnasında fikir paylaşımlarıyla ufkumu açan, karşılaştığım teknik zorluklarda ve araştırma süreçlerinde yanımda olup akademik dayanışmanın en güzel örneğini sergileyen değerli arkadaşım Arş. Gör. Hakkı Halil BABACAN'a teşekkürlerimi borç bilirim. Hayatımın her aşamasında olduğu gibi bu akademik yolculuğumda da kendisini örnek aldığım, çalışmalarım boyunca sağladığı imkânlar, teşvikler ve sarsılmaz güveniyle bana güç veren, sadece bir baba olarak değil bir bilim insanı olarak da yolumu aydınlatan kıymetli babam Prof. Dr. Erol KAYA'ya minnettarım. Son olarak, bu süreçteki fedakârlıklarıyla her zaman yanımda olan tüm aileme ve desteklerini esirgemeyen dostlarıma teşekkür ederim.

Muhammed Buğrahan KAYA

Haziran, 2026



## İÇİNDEKİLER

|                                                                                  |     |
|----------------------------------------------------------------------------------|-----|
| ÖZET .....                                                                       | i   |
| ABSTRACT .....                                                                   | iii |
| TEŞEKKÜR .....                                                                   | v   |
| İÇİNDEKİLER.....                                                                 | 6   |
| TABLolar DİZİNİ.....                                                             | 8   |
| ŞEKİLLER DİZİNİ .....                                                            | 9   |
| SİMGELER VE KISALTMALAR DİZİNİ .....                                             | 10  |
| 1. GİRİŞ.....                                                                    | 12  |
| 2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR.....                                   | 14  |
| 3. MATERYAL VE METOT .....                                                       | 26  |
| 3.1. PV SİSTEMLERDE ARIZA TÜRLERİ VE TEKNİK ZORLUKLAR .....                      | 27  |
| 3.2. VERİ SETİ TEMİNİ VE VERİ HAZIRLAMA (DATA ACQUISITION AND PRE-PROCESSING)... | 30  |
| 3.3. GÖRÜNTÜ İŞLEME VE NESNE TESPİTİ SÜRECİ (ROBOFLOW VE COLAB ENTEGRASYONU)     | 31  |
| 3.4. VERİ İŞLEME VE MODEL MİMARİSİ.....                                          | 31  |
| 3.4.1. Özellik Mühendisliği ve Zaman Serisi Hazırlığı.....                       | 32  |
| 3.4.2. Hibrit CNN-LSTM Autoencoder Tasarımı .....                                | 32  |
| 3.5. GÖRSEL DENETİM VE NESNE TESPİTİ METODOLOJİSİ .....                          | 32  |
| 3.6. KARAR DESTEK SİSTEMİ (KDS) VE ARAYÜZ GELİŞTİRME .....                       | 33  |
| 3.7. VERİ SETİ KEŞİFSEL ANALİZİ VE KORELASYON İNCELEMESİ.....                    | 33  |
| 3.8. ZAMAN SERİSİ VE GÜNLÜK PATTERN ANALİZİ.....                                 | 34  |
| 3.9. ANOMALİ TESPİTİ VE MODEL PERFORMANS KARŞILAŞTIRMASI .....                   | 35  |
| 3.10. AÇIKLANABİLİR YAPAY ZEKA (XAI) .....                                       | 36  |
| 3.11. KARAR DESTEK SİSTEMİ (KDS) ARAYÜZ ÇIKTILARI VE KULLANICI DENEYİMİ.....     | 36  |
| 3.11.1. Anomali Skoreleme ve Verimlilik Analizi.....                             | 36  |
| 3.11.2. Görsel Kusur ve Çevresel Etki Teşhisi.....                               | 37  |
| 3.11.3. Karar Destek Mekanizması ve Bakım Önerileri.....                         | 40  |
| 3.12. CNN-GRU HİBRİT DERİN ÖĞRENME MİMARİSİ.....                                 | 41  |

|                                                                                              |    |
|----------------------------------------------------------------------------------------------|----|
| 3.13. HİSTGRADIENTBOOSTİNG (HGB) ALGORİTMASININ TEKNİK KARAKTERİSTİĞİ VE UYGULAMA ALANI..... | 43 |
| 4. TARTIŞMA.....                                                                             | 45 |
| 4.1. HİBRİT YAKLAŞIMIN DOĞRULUĞU VE OPERASYONEL GÜVEN.....                                   | 45 |
| 4.2. VERİMLİLİK KAYBI VE EKONOMİK PROJEKSİYON.....                                           | 45 |
| 4.3. ÇEVRESEL FAKTÖRLERİN OTONOM AYIRIMI .....                                               | 45 |
| 5. SONUÇLAR.....                                                                             | 47 |
| KAYNAKÇA .....                                                                               | 49 |

## **TABLÖLAR DİZİNİ**

|                                                                         |    |
|-------------------------------------------------------------------------|----|
| Tablo 1. 600 Wp Fotovoltaik Panelin Elektriksel Karakteristikleri. .... | 29 |
| Tablo 2. 10 kW inverterin elektriksel giriş- çıkış parametreleri.....   | 29 |

## ŞEKİLLER DİZİNİ

|                                                                                                                          |    |
|--------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 1. Güneş enerji santrali çalışma prensibi ve arıza çıkabilecek durumlar. ....                                      | 28 |
| Şekil 2. PV Modül bir günlük ortalama çalışma gücü.....                                                                  | 31 |
| Şekil 3. Fotovoltaik sistem parametreleri arasındaki korelasyon matrisi. ....                                            | 33 |
| Şekil 4. Sistemin 1000 veri noktalık kesiti üzerinde yapılan zaman serisi analizi. ....                                  | 34 |
| Şekil 5. CNN-LSTM Hibrit Autoencoder modelinin test verisi üzerindeki performansı. ....                                  | 35 |
| Şekil 6. Geliştirilen Karar Destek Sistemi Arayüzü Üzerinde HistGradientBoosting Modeli ile Anomali Tespit Analizi. .... | 36 |
| Şekil 7. Nesne Tespiti Modeliyle Fiziksel Hasar (Çatlak) Saptaması. ....                                                 | 38 |
| Şekil 8. Otonom Gölge Analizi ve Etkilenen Bölge Tespiti Çıktısı. ....                                                   | 39 |
| Şekil 9. Çok Modlu Karar Füzyonu ve Risk Değerlendirmesi. ....                                                           | 40 |
| Şekil 10. Nesne Tespiti ve Fiziksel Arıza Teşhisi. ....                                                                  | 41 |
| Şekil 11. CNN-GRU Modeli Eğitim ve Doğrulama Kayıp (Loss) Grafiği. ....                                                  | 42 |
| Şekil 12. HistGradientBoosting (HGB) Modeli Gerçek ve Tahmin Edilen Güç Üretimi (1 Haftalık Örnek).....                  | 43 |

## SİMGELER VE KISALTMALAR DİZİNİ

|         |                                                                 |
|---------|-----------------------------------------------------------------|
| AC      | Alternating Current (Alternatif Akım)                           |
| A       | Amper                                                           |
| AI      | Artificial Intelligence (Yapay Zekâ)                            |
| CNN     | Convolutional Neural Network (Evrişimsel Sinir Ağı)             |
| Imp     | Current at Maximum Power Point (Maksimum Güç Noktasındaki Akım) |
| DL      | Deep Learning (Derin Öğrenme)                                   |
| DC      | Direct Current (Doğru Akım)                                     |
| EL      | Electroluminescence (Elektrolüminesans)                         |
| XAI     | Explainable Artificial Intelligence (Açıklanabilir Yapay Zekâ)  |
| XGBoost | Extreme Gradient Boosting (Aşırı Gradyan Artırma)               |
| GRU     | Gated Recurrent Unit (Geçitli Tekrarlayan Birim)                |
| GPU     | Graphics Processing Unit (Grafik İşlem Birimi)                  |
| GES     | Güneş Enerji Santrali                                           |
| HGB     | HistGradientBoosting (Histogram Tabanlı Gradyan Artırma)        |
| Hz      | Hertz                                                           |
| İHA     | İnsansız Hava Aracı                                             |
| KDS     | Karar Destek Sistemi                                            |
| kW      | Kilowatt (Kilovat)                                              |
| kWp     | Kilowatt Peak (Tepe Kilovat)                                    |
| LSTM    | Long Short-Term Memory (Uzun Kısa Süreli Bellek)                |
| ML      | Machine Learning (Makine Öğrenmesi)                             |
| MPPT    | Maximum Power Point Tracking (Maksimum Güç Noktası Takibi)      |
| MAE     | Mean Absolute Error (Ortalama Mutlak Hata)                      |
| mAP     | Mean Average Precision (Ortalama Hassasiyet)                    |
| MSE     | Mean Square Error (Ortalama Kare Hatası)                        |

|         |                                                                                    |
|---------|------------------------------------------------------------------------------------|
| MWp     | Megawatt Peak (Tepe Megavat)                                                       |
| 1D-CNN  | One-Dimensional Convolutional Neural Network (Tek Boyutlu Evrişimsel Sinir Ağı)    |
| Voc     | Open Circuit Voltage (Açık Devre Gerilimi)                                         |
| PV      | Photovoltaic (Fotovoltaik)                                                         |
| Pmax    | Peak Power (Maksimum Güç)                                                          |
| RF-DETR | Rotated Feature Detection Transformer (Döndürülmüş Özellik Algılama Dönüştürücüsü) |
| SHAP    | Shapley Additive Explanations (Shapley Toplamsal Açıklamaları)                     |
| Isc     | Short Circuit Current (Kısa Devre Akımı)                                           |
| STC     | Standard Test Conditions (Standart Test Koşulları)                                 |
| V       | Volt                                                                               |
| VA      | Volt-Amper                                                                         |
| Vmp     | Voltage at Maximum Power Point (Maksimum Güç Noktasındaki Gerilim)                 |
| W       | Watt                                                                               |
| Wp      | Watt Peak (Tepe Watt)                                                              |

## 1. GİRİŞ

Küresel enerji talebinin sürdürülebilir ve dekarbonizasyon odaklı hedefler doğrultusunda karşılanmasında en stratejik rolü üstlenen güneş enerjisi santralleri (GES); yarı iletken fotovoltaik (PV) materyaller vasıtasıyla güneş radyasyonunu doğrudan, temiz ve modüler bir biçimde elektrik enerjisine dönüştüren ileri teknoloji yenilenebilir enerji sistemleridir. Açık hava koşullarında uzun yıllar boyunca kesintisiz performans göstermesi beklenen bu dinamik altyapıların işletim verimliliği, operasyonel süreçlerde meydana gelen elektriksel ve fiziksel anomalilerin erken safhada otonom olarak teşhis edilmesiyle doğrudan ilişkilidir. Bu tez çalışmasının başlangıç adımı olarak; mevcut izleme teknolojilerinin kısıtlarını ve çok modlu yapay zeka (AI) yaklaşımlarına duyulan ihtiyacı ortaya koyan temel problem durumu detaylandırılmaktadır. Bu doğrultuda, veri odaklı analitik motorlar ile bilgisayarlı görüş disiplini özgün bir çatı altında birleştiren araştırmanın temel amacı, bilimsel ve endüstriyel önemi, çalışmanın metodolojik sınırlarını çizen kapsamı ve tüm deneysel kurgunun üzerine inşa edildiği temel varsayımlar bütünsel bir perspektifle ele alınmaktadır.

Küresel enerji dönüşümünün en kritik bileşenlerinden biri olan PV güç sistemleri, dış ortam koşullarında uzun yıllar kesintisiz çalışacak şekilde tasarlanmaktadır. Ancak sahadaki PV dizileri; elektriksel kısa devre, açık devre, yaşlanma, lokal gölgelenme ve panel kirlenmesi gibi hem elektriksel hem de fiziksel anomalilere sürekli maruz kalmaktadır. Geleneksel eşik değer analizleri veya analitik matematiksel modeller, dinamik hava koşullarının yarattığı doğrusal olmayan dalgalanmalar karşısında yüksek "yanlış alarm" oranları üretmektedir.

Bu kısıtları aşmak adına son yıllarda geliştirilen veri odaklı yapay zekâ modelleri ise kendi içlerinde derin bir ikilem barındırmaktadır. Gelişmiş makine öğrenmesi (ML) algoritmaları düşük hesaplama maliyetleriyle öne çıkarken, karmaşık derin öğrenme (DL) mimarileri ise yüksek doğruluk sunmalarına rağmen kısıtlı donanımlara sahip uç cihazlarda (edge computing) yüksek işlem yükü oluşturmaktadır. Ayrıca, derin öğrenme modellerinin "kara kutu" (black box) yapısı, sahadaki operatörlerin kararlara güvenmesini zorlaştırmaktadır.

Arızaların elektriksel zaman serisi analitiği (sensör verileri) ile fiziksel kökenlerinin (görsel deformasyonlar) genellikle birbirinden bağımsız incelenmesi mevcut eksikliklerden biridir. Bu durum, operatörlere anlık müdahale şansı tanıyan, iki farklı veri kaynağını füzyon teknolojisiyle

birleştiren uçtan uca hiyerarşik bir karar destek sistemi (KDS) mimarisinin eksikliğini açıkça ortaya koymaktadır.

Bu tez çalışmasının temel amacı; PV sistemlerdeki elektriksel ve fiziksel arızaların otonom tespiti için hafif makine öğrenmesi modelleri ile hiyerarşik derin öğrenme mimarilerinin performanslarını karşılaştırmalı olarak analiz etmek ve bu analizleri bilgisayarlı görü altyapısıyla bütünleştiren özgün bir KDS tasarlamaktır. Bu genel amaç doğrultusunda aşağıdaki hedefler belirlenmiştir:

- Denetimsiz Isolation Forest (izolasyon ormanı) ve denetimli HistGradientBoosting (HGB) modelleriyle kalıntı analizine dayalı hafif bir ML katmanı kurmak.
- Zamansal ve uzaysal öznitelikleri öğrenen 1D-CNN-LSTM Hibrit Autoencoder mimarisi geliştirmek ve bu iki farklı yaklaşımı doğruluk/maliyet kriterlerine göre kıyaslamak.
- SHAP algoritması entegrasyonu ile derin öğrenme modelinin kararlarını açıklanabilir kılmak.
- Transformer tabanlı RF-DETR nesne tespiti modeliyle panellerdeki fiziksel hasarları otonom olarak haritalandırmak.
- Tüm bu analiz yöntemlerini Antigravity altyapısıyla bütünleştirerek anlık verimlilik kaybını ve bakım önerilerini sunan uçtan uca çok modlu bir KDS prototipi üretmek.

Dört ana bölümden oluşan bu tez çalışması şu şekilde düzenlenmiştir; birinci bölümde araştırmanın problemi, amacı, önemi ve kapsamı ele alınarak güneş enerji santrallerindeki denetim süreçleri ile teknik zorluklar hakkında genel bilgiler verilmiş, ikinci bölümde konuyla ilgili temel kavramlar açıklanarak literatürdeki geleneksel yöntemlerden modern yapay zeka modellerine kadar uzanan çalışmalar özetlenmiş, üçüncü bölümde kullanılan veri setinin hazırlanma aşamaları ile HGB, CNN-GRU (geçitli tekrarlayan birimi) ve RF-DETR gibi yapay zeka modellerinin teknik detayları ve KDS arayüz tasarımı anlatılmış, dördüncü ve son bölümde ise elde edilen sonuçlar literatürdeki diğer çalışmalarla karşılaştırılarak modelin başarısı tartışılmış ve araştırmanın sektöre katkıları ile gelecekte yapılabilecek çalışmalara dair öneriler sunulmuştur.



## 2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR

Küresel enerji projeksiyonlarında fosil yakıtlardan yenilenebilir kaynaklara geçişin en stratejik bileşeni haline gelen PV sistemler, operasyonel süreçlerinde çevresel ve teknik faktörlerin neden olduğu pek çok verimlilik kısıtıyla karşı karşıyadır. GES'lerin özellikle Van/Başkale gibi yüksek rakımlı ve uç sıcaklık farklarının görüldüğü zorlu coğrafyalarda sürdürülebilir bir performans sergilemesi, sistemde meydana gelen anomalilerin otonom olarak saptanmasına ve karara bağlanmasına bağlıdır. Geleneksel izleme teknolojileri, PV verilerinin stokastik doğası ve dinamik hava koşullarının yarattığı doğrusal olmayan dalgalanmalar karşısında genellikle yetersiz kalmakta; bu durum literatürde veri odaklı, hiyerarşik ve çok modlu (multimodal) teşhis mekanizmalarına duyulan ihtiyacı artırmaktadır.

Son on yılda literatür, eşik değer analizlerine dayalı statik modellerden, karmaşık örüntüleri öğrenebilen ML ve DL tabanlı dinamik mimarilere doğru evrilmiştir. Ancak yapılan çalışmaların büyük bir bölümünün sadece elektriksel sensör verileriyle sınırlı kaldığı, saptanan performans düşüşlerinin fiziksel nedenlerini (hasar, gölge, kirlenme) otonom olarak doğrulayacak görsel kanıt disiplininin yoksun olduğu görülmektedir. Ayrıca, derin öğrenme modellerinin "kara kutu" (black-box) yapısı, operatörlerin otonom kararlara olan güvenini kısıtlayan bir engel olarak tanımlanmaktadır.

Bu bölüm kapsamında; PV arıza tespitinde kullanılan geleneksel yöntemlerden en güncel hibrit derin öğrenme modellerine, bilgisayarlı görü tabanlı nesne tespiti disiplininin açıklanabilir yapay zeka (XAI) yaklaşımlarına kadar geniş bir akademik yelpaze sentezlenmiştir. İncelenen çalışmalar; önerilen bu tezin metodolojik boşlukları nasıl doldurduğunu, elektriksel analitiği görsel kanıtlarla nasıl füzyonladığını ve literatürdeki mevcut kısıtları hangi özgün yaklaşımlarla aştığını ortaya koyan kuramsal bir zemin sunmaktadır.

Yarı iletken ve güç elektroniği alanındaki en güncel tartışmaları içeren ve Electronics (2025) bünyesinde inceleme aşamasında olan çalışma, fotovoltaik sistemlerin denetiminde ileri seviye algoritmik yaklaşımların ve gerçek zamanlı izleme donanımlarının entegrasyonunu ele almaktadır. Söz konusu çalışma, PV arıza teşhisinde donanım ve yazılım arasındaki sinerjinin ulaştığı en son teknik seviyeyi temsil etmesi bakımından önem arz etmektedir. Literatürdeki bu en güncel perspektifi bütünleşik bir KDS'ye dönüştüren bu tez araştırması ise, henüz değerlendirme aşamasında olan bu tür teorik yaklaşımları pratik ve hiyerarşik bir mimariyle sahaya indirmektedir. Bu çalışmanın temel farkı; elektriksel analitiği HistGradientBoosting

(HGB) ve Evrişimsel Sinir Ağı - Uzun Kısa Süreli Bellek (CNN-LSTM) sadece donanım seviyesinde bir izleme olarak bırakmayıp, onu transformer tabanlı döndürülmüş özellik algılama dönüştürücüsü (RF-DETR) bilgisayarlı görü katmanıyla füzyonlaması ve shapley toplamsal açıklamaları (SHAP) algoritmasıyla XAI disiplinine uygun, kullanıcı odaklı bir arayüz sunmasıdır.

Yılmaz ve ark. (2023), fotovoltaik sistemlerin ani iklim geçişleri (ani bulutlanma, hızlı sıcaklık değişimleri vb.) altındaki performansını inceleyerek, bu tür değişken koşullarda arıza tespit sistemlerinin kararlılığını korumasına yönelik bir model önermişlerdir. Yazarlar, özellikle elektriksel verilerdeki gürültülerin yanlış alarmlara yol açmasını önlemek için sinyal işleme odaklı bir yaklaşım benimsemişlerdir. Ancak söz konusu çalışma, anomalileri sadece sayısal sensör verileri üzerinden takip etmekte, saptanan performans düşüşlerinin fiziksel kaynağını (kırık, kirlenme, gölge) otonom olarak doğrulayamamaktadır. Bu çalışma, Yılmaz ve ark. tarafından vurgulanan kararlı arıza tespiti ihtiyacını bir adım öteye taşıyarak; elektriksel analitiği transformer tabanlı RF-DETR bilgisayarlı görü mimarisiyle birleştirmekte ve saptanan anomalilerin nedenini SHAP algoritması ile açıklanabilir kılarak belirsizliği ortadan kaldırmaktadır.

Öztürk ve Kara (2024), güneş enerji santrallerinde sabit eşik değerleri kullanmanın dinamik hava koşulları altında yüksek yanlış alarm oranlarına neden olduğunu saptamış; buna çözüm olarak makine öğrenmesi tabanlı dinamik eşik değer yönetimi yaklaşımını geliştirmişlerdir. Bu çalışmada, çevresel değişkenlere göre esneyen eşik aralıkları sayesinde hata tespit duyarlılığının artırılması hedeflenmiştir. Söz konusu yaklaşım istatistiksel sapmaları belirlemede başarılı olsa da, anomali tespitini sadece 'eşik aşımı' (thresholding) mantığına dayandırmakta, veriler arasındaki derin zamansal bağımlılıkları ve çok boyutlu korelasyonları göz ardı etmektedir. Bizim çalışmamızda ise basit bir dinamik eşik yönetimi yerine, verinin saklı temsilini öğrenen 1D-CNN-LSTM Hibrit Autoencoder mimarisi kullanılarak 'yeniden yapılandırma hatası' üzerinden çok daha hassas bir anomali saptaması yapılmaktadır.

Mansouri ve ark. (2021), fotovoltaik sistemlerde hata teşhisi için gelişmiş istatistiksel kalıntı analizi (residual analysis) yöntemini inceleyerek, beklenen üretim verileri ile gerçekleşen veriler arasındaki farkların matematiksel olarak nasıl yorumlanması gerektiğine dair kuramsal bir çerçeve sunmuşlardır. Çalışma, özellikle istatistiksel modellerin hata saptama hızına ve hassasiyetine odaklanarak literatürde önemli bir yer edinmiştir. Ancak Mansouri ve ekibinin yaklaşımı, tamamen nümerik verilere dayalı bir teşhis mekanizması üzerine kurulu olduğundan,

arızanın fiziksel kanıtlarını (örneğin panel üzerindeki kirlenme, gölge veya yapısal hasarlar) sunma kabiliyetine sahip değildir. Literatürdeki bu matematiksel kurguyu çok boyutlu bir vizyona taşıyan bu tez araştırması, sadece istatistiksel kalıntı analizini (HGB tabanlı) kullanmakla kalmayıp, bu analizleri 1D-CNN-LSTM gibi derin öğrenme mimarileriyle zenginleştirerek sahadaki görsel deformasyonlarla füzyonlamakta ve operatöre arızanın hem nümerik hem de görsel kanıtını bir KDS içerisinde sunmaktadır.

Badr ve ark. (2021), özellikle evsel tip güneş enerji santrallerine odaklanarak, bu sistemlerdeki arızaların sınıflandırılması ve hiyerarşik olarak tespit edilmesi üzerine kuramsal bir çerçeve geliştirmişlerdir. Yazarlar, konut tipi kurulumlardaki veri kısıtlarını dikkate alan ve bileşen bazlı hata ayıklamayı önceleyen bir sınıflandırma hiyerarşisi üzerinde durmuşlardır. Metodolojik bir ilerleme olarak bu çalışmada kurgulanan model, Badr ve ekibinin üzerinde durduğu hiyerarşik tespit yaklaşımını bir adım öteye taşıyarak; sadece mantıksal bir sınıflandırma ile sınırlı kalmamış, hem sensör verilerinden zamansal-uzaysal öznitelikleri hiyerarşik olarak öğrenen 1D-CNN-LSTM mimarisiyle süreci derinleştirmiş hem de bu analitik yapıyı RF-DETR tabanlı nesne tespitiyle otonom bir görsel doğrulama katmanına dönüştürmüştür.

Paul ve ark. (2025), fotovoltaik dizilerde ciddi güvenlik riskleri oluşturan doğru akım (DC) ark hatalarının otonom tespiti için çok katmanlı makine öğrenmesi yaklaşımlarını inceleyerek, karmaşık elektriksel sinyallerin ayrıştırılmasında ML katmanlarının etkinliğini ortaya koymuşlardır. Çalışma, özellikle ark hatalarının dinamik doğasını yakalamadaki yüksek hassasiyetiyle literatüre oldukça güncel ve önemli bir katkı sunmaktadır. Bu tez kapsamında sunulan bütünleşik çözüm ise, Paul ve ekibinin vurguladığı katmanlı algoritmik yapıyı bir adım ileriye taşıyarak; sadece ark hataları gibi spesifik elektriksel anomalilerle sınırlı kalmayan, aynı zamanda sisteme entegre edilen RF-DETR bilgisayarlı görüş katmanıyla kirlenme, gölge ve fiziksel hasar gibi çevresel/yapısal faktörleri de otonom olarak teşhis edebilen çok modlu (multimodal) bir KDS sunmaktadır. Ayrıca, derin öğrenmenin "kara kutu" doğasını SHAP algoritmasıyla şeffaflaştıran bu araştırma, Paul ve ark. tarafından önerilen tespit mekanizmasını XAI disipliniyle zenginleştirerek operatör güvenliğini artırmayı hedeflemektedir.

Gedik (2016), Van bölgesi örneği üzerinden yüksek rakımlı ve uç sıcaklık farklarının yaşandığı coğrafyalarda fotovoltaik modül sıcaklığının verimlilik üzerindeki termal etkilerini deneysel olarak analiz etmiştir. Çalışma, bölgenin sert iklim koşullarının paneller üzerindeki ısı stres

katsayısını nasıl artırdığını ve bunun sonucunda meydana gelen verimlilik kayıplarını bilimsel verilerle ortaya koymuştur. Gedik'in Van bölgesi için saptadığı bu temel termal kısıtları dijitalleştirilmiş otonom bir teşhis mekanizmasına dönüştüren bu araştırmada ise, söz konusu fiziksel verimlilik analizleri birer girdi parametresi olarak kabul edilmiştir. Sunulan bu çalışma, Gedik tarafından deneysel olarak ispatlanan termal kayıpları; hem 1D-CNN-LSTM mimarisiyle zamansal bir anomali izleme sürecine dahil etmekte hem de RF-DETR tabanlı nesne tespitiyle bu termal değişimlerin fiziksel nedenlerini (mikro-çatlak, gölge, kirlenme) otonom olarak teşhis edebilen bütünlük bir KDS'ye taşımaktadır.

Alrifaeey ve ark. (2022), şebekeye bağlı fotovoltaik sistemlerde gerçek zamanlı hata sınıflandırması ve güç tahmini için CNN-GRU ve CNN-LSTM gibi hibrit derin öğrenme modellerinin performansını analiz etmişlerdir. Yazarlar, evrişimli sinir ağlarının uzaysal öznitelik çıkarma yeteneği ile yinelemeli yapıların zamansal bağımlılıkları yakalama gücünü birleştirerek oldukça başarılı sonuçlar elde etmişlerdir. Söz konusu hibrit mimari yaklaşımını çok katmanlı ve çok modlu bir vizyonla genişleten bu tez çalışması ise, Alrifaeey ve ark. tarafından önerilen elektriksel tabanlı derin öğrenme kurgusunu; hem 'hafifletilmiş ML katmanı' (HGB) ile daha verimli bir ön işleme sürecine tabi tutmakta hem de bu analitik motoru bilgisayarlı görü tabanlı RF-DETR katmanıya destekleyerek fiziksel-elektriksel bir veri füzyonu gerçekleştirmektedir.

Özer ve Aksoy (2024), akıllı şehir konsepti çerçevesinde evsel tip fotovoltaik sistemlerde yapay zekâ entegrasyonunun enerji verimliliği üzerindeki kritik rolünü ve genel sistem optimizasyonu yaklaşımlarını incelemişlerdir. Çalışma, konut tipi uygulamalarda yapay zekânın sürdürülebilir enerji yönetimi için sağladığı avantajları ve panel verimliliğini artırmaya yönelik stratejik yaklaşımları vurgulaması bakımından güncel bir referans teşkil etmektedir. Literatürdeki bu optimizasyon vizyonunu otonom ve hiyerarşik bir teşhis mekanizmasına dönüştüren bu tez araştırmasında ise, Özer ve Aksoy'un üzerinde durduğu genel verimlilik takibi yaklaşımı; hem HGB ve CNN-LSTM modelleriyle gerçekleştirilen mikro düzeydeki anomali saptama süreçleriyle derinleştirilmiş hem de RF-DETR tabanlı nesne tespitiyle fiziksel-elektriksel bir veri füzyonuna tabi tutulmuştur. Ayrıca, söz konusu çalışmada yer alan genel izleme perspektifi, bu araştırmada SHAP algoritmasıyla desteklenen 'açıklanabilir yapay zeka' katmanı ve Antigravity tabanlı etkileşimli KDS ile operatörün doğrudan bakım aksiyonu alabileceği bütünlük bir platforma dönüştürülmüştür.

Zwirtes ve ark. (2025), büyük ölçekli güneş enerjisi verilerinin izlenmesinde gürültülü verilerin ayıklanması ve anomalilerin saptanması için denetimsiz ön süzme (unsupervised pre-filtering) yöntemlerinin ve istatistiksel doğrulama süreçlerinin kritik önemini vurgulamışlardır. Çalışma, özellikle karmaşık veri setlerinde istatistiksel validasyonun teşhis doğruluğu üzerindeki etkisini ortaya koyarak, veri madenciliği süreçlerinin anomali tespitiindeki önceliğini kanıtlamaktadır. Söz konusu güncel metodolojiyi evsel tip sistemlerin özgün dinamiklerine uyarlayan bu tez çalışması ise, Zwirtes ve ekibinin üzerinde durduğu denetimsiz ön süzme aşamasını Isolation Forest algoritması ile hayata geçirmekte, ancak süreci burada bırakmayarak denetimli güç tahmini (HGB) ve hibrit derin öğrenme (CNN-LSTM) katmanlarıyla hiyerarşik bir yapıya kavuşturmaktadır. Ayrıca, bu araştırmanın literatürdeki en belirgin farkı; Zwirtes'in istatistiksel yaklaşımını RF-DETR tabanlı bilgisayarlı görü ve SHAP tabanlı açıklanabilirlik katmanlarıyla zenginleştirerek, sadece veriyi filtreleyen değil, hatanın fiziksel nedenini otonom olarak doğrulayan bütünlük bir KDS sunmasıdır.

Oumiguil ve Nejmi (2026), GES'lerdeki kronolojik sensör verilerinin analizinde zamansal bağımlılıkların (temporal dependencies) rolünü incelemiş ve bu verilerin işlenmesinde GRU (Gated Recurrent Unit) tabanlı mimarilerin üstünlüğünü ortaya koymuşlardır. Yazarlar, özellikle uzun dönemli kronolojik veri dizilerinde GRU birimlerinin, geleneksel yöntemlere kıyasla daha az hesaplama maliyetiyle daha yüksek tahmin doğruluğu sunduğunu ispatlamışlardır. Literatürdeki bu en güncel yaklaşımları hibrit ve çok modlu bir perspektifle genişleten bu tez çalışması ise, Oumiguil ve ekibinin üzerinde durduğu GRU yapısını sadece bir tahmin motoru olarak kullanmakla kalmamış; onu evrişimli sinir ağlarıyla (CNN) birleştirerek uzaysal-zamansal bir öznitelik füzyonu gerçekleştirmiştir. Ayrıca, söz konusu çalışmadaki elektriksel veri odaklı yaklaşım, bu çalışmada RF-DETR tabanlı bilgisayarlı görü katmanıyla desteklenerek fiziksel arıza teşhisiyle mühürlenmiş ve SHAP algoritmasıyla açıklanabilir hale getirilerek uçtan uca bir KDS'ye dönüştürülmüştür.

Quiles-Cucarella ve ark. (2025), fotovoltaik sistemlerin kestirimci bakımı için düşük sinyal-gürültü oranına (SNR) sahip verilerde hiper-parametre optimizasyonunun kritik rolünü inceleyerek, veri kalitesindeki kısıtlılıklara rağmen teşhis doğruluğunun nasıl artırılabileceğini ortaya koymuşlardır. Çalışma, özellikle gürültülü sensör verileri altında modellerin hassasiyetini optimize eden matematiksel yaklaşımlarıyla literatüre oldukça güncel bir katkı sağlamaktadır. Önerilen bu multimodal yaklaşım ise, Quiles-Cucarella ve ekibinin üzerinde durduğu veri optimizasyonu gereksinimini bir ön aşama olarak kabul etmekle birlikte; anomali

tespit sürecini sadece elektriksel parametrelerin iyileştirilmesiyle sınırlı tutmamakta, bu süreci transformer tabanlı RF-DETR bilgisayarlı görü katmanı ile destekleyerek fiziksel bir doğrulama mekanizması inşa etmektedir. Ayrıca, 'karar verme süreçlerinin şeffaflaştırılması' ihtiyacı, bu araştırmada SHAP tabanlı XAI disipliniyle bütünleştirilerek operatörün karmaşık sinyaller içindeki arıza nedenlerini anlamasını sağlayan bütünsel bir KDS'ye dönüştürülmüştür.

El Martaoui ve ark. (2025), fotovoltaik sistemlerin en kritik bileşenlerinden biri olan maksimum güç noktası takibi (MPPT) ünitelerindeki anomali tespiti için denetimsiz Isolation Forest algoritması ile ağaç tabanlı topluluk (ensemble) yöntemlerini karşılaştırmalı olarak değerlendirmişlerdir. Yazarlar, Isolation Forest'ın etiketlenmemiş verilerdeki anomali saptama hızı ile ağaç tabanlı modellerin sınıflandırma hassasiyetini analiz ederek her iki yaklaşımın MPPT birimlerindeki spesifik hata türlerine karşı etkinliğini ortaya koymuşlardır. Bu tez çalışmasında kurgulanan mimari, El Martaoui ve ekibinin sunduğu bu iki güçlü algoritmayı hiyerarşik bir bütünün parçaları olarak konumlandırmıştır. Çalışma kapsamında; Isolation Forest denetimsiz bir ön süzme katmanı olarak kullanılırken, HGB modeli ise bu süzölmüş veri üzerinde hassas tahminleme görevini üstlenmiştir.

Qureshi ve ark. (2024), evsel tip GES'lerde kestirimci bakım aciliyetini saptamak amacıyla çok modlu füzyon ve finansal metriklerin entegrasyonunu incelemişlerdir. Yazarlar, farklı veri akışlarını birleştirerek bakım süreçlerini ekonomik kayıp projeksiyonlarına göre önceliklendiren bir yaklaşım sunmuşlardır. Bu tez çalışması kapsamında önerilen özgün mimari ise, Qureshi ve ekibinin üzerinde durduğu çok modlu füzyon ve bakım aciliyeti vizyonunu teknik bir teşhis derinliğiyle zenginleştirmektedir. Söz konusu çalışmada odaklanılan finansal önceliklendirme perspektifi, bu araştırmada Transformer tabanlı RF-DETR nesne tespiti katmanı ile fiziksel bir boyuta taşınmış; elektriksel anomaliler sadece üretim kaybıyla değil, panel üzerindeki fiziksel hasarların (çatlak, gölge vb.) otonom görsel kanıtlarıyla eşleştirilmiştir. Ayrıca, literatürdeki bu yaklaşıma ek olarak, derin öğrenme modellerinin karar mekanizması SHAP algoritmasıyla şeffaflaştırılmış ve Antigravity tabanlı kullanıcı arayüzü sayesinde operatöre sadece 'ne kadar kayıp olduğu' değil, 'kaybın fiziksel kaynağının ne olduğu' bilgisi aksiyon odaklı bir KDS içerisinde sunulmuştur.

Arslan ve Doğan (2022), özellikle kısıtlı bütçeli küçük ve orta ölçekli evsel GES projelerinde yapay zeka uygulamalarının önündeki en büyük engelin donanım maliyetleri olduğunu

saptamış; buna çözüm olarak uç cihazlarda (edge computing) çalışabilecek optimize edilmiş düşük maliyetli model mimarileri önermişlerdir. Çalışma, akademik çözümlerin endüstriyel sahadaki ekonomik sürdürülebilirliği üzerine önemli bir perspektif sunmaktadır. Sunulan bu tez araştırması ise, Arslan ve Doğan'ın üzerinde durduğu 'ekonomik ve uygulanabilir mühendislik çözümü' vizyonunu temel bir gereksinim olarak kabul etmektedir. Ancak bu araştırmanın metodolojik derinliği, sadece donanım optimizasyonu ile sınırlı kalmayıp; kısıtlı kaynaklar altında dahi hiyerarşik bir yapı kurgulayarak, 'hafifletilmiş' ML modelleri (Isolation Forest, HGB) ile 'güçlü' görsel teşhis motorlarını (RF-DETR) tek bir potada eritmektedir. Böylece, düşük maliyetli evsel sistemlerde dahi sadece anomali tespiti değil, aynı zamanda görsel veri füzyonu ve SHAP tabanlı açıklanabilirlik sunan çok boyutlu bir KDS'nin teknik olarak mümkün ve maliyet açısından sürdürülebilir olduğu kanıtlanmaktadır.

Lund (2024), akıllı şebeke (smart grid) işletiminde kullanılan derin öğrenme mimarilerinin 'kara kutu' doğasının operatörler nezdinde güven sorunlarına yol açtığını saptamış; bu karmaşık modellerin kararlarını şeffaflaştırmak amacıyla SHAP çerçevesinin entegrasyonu üzerine kapsamlı bir çalışma yürütmüştür. Araştırma, XAI disiplininin mühendislik sistemlerindeki karar alma süreçlerinde oynadığı kritik rolü ve model çıktılarındaki parametre katkılarının görselleştirilmesinin önemini vurgulamaktadır. Bu tezde kurgulanan KDS ise, Lund tarafından önerilen açıklanabilirlik vizyonunu fotovoltaiik arıza teşhis sahasına spesifik olarak uyarlamaktadır.

Nguyen ve Hoang (2025), silikon güneş panellerindeki fiziksel yüzey kusurlarının (çatlak, kirlenme vb.) haritalandırılması için transformer tabanlı nesne tespiti yöntemlerini ve özellikle RF-DETR mimarisini inceleyerek, bu yapının geleneksel CNN kıyasla küresel öznetelikleri ve uzun menzilli ilişkileri yakalamadaki üstünlüğünü kanıtlamışlardır. Çalışma, fotovoltaiik denetimlerde derin öğrenme tabanlı bilgisayarlı görü disiplininin ulaştığı güncel teknik seviyeyi temsil etmesi bakımından kritik bir öneme sahiptir.

Qureshi ve ark. (2024), GES kestirimci bakım süreçlerinin iyileştirilmesi için makine öğrenmesi yaklaşımlarının rolünü incelemiş ve arıza tahminlemede veri odaklı modellerin sunduğu avantajları ortaya koymuşlardır. Çalışma, enerji tesislerinde operasyonel verimliliğin artırılmasına yönelik geniş kapsamlı bir perspektif sunmaktadır. Bu tezde sunulan KDS, Qureshi ve ekibinin vurguladığı kestirimci bakım vizyonunu sadece nümerik veri analitiğiyle sınırlı tutmayıp, bu süreci RF-DETR tabanlı görsel denetim katmanıyla zenginleştirerek fiziksel

bir boyuta taşımaktadır. Ayrıca, söz konusu çalışmada yer alan genel tahminleme modelleri, bu tez kapsamında SHAP tabanlı XAI ve Antigraity tabanlı etkileşimli kullanıcı arayüzü ile bütünleştirilerek; operatöre sadece bir arıza öngörüsü değil, hatanın fiziksel kanıtını ve aksiyon odaklı bakım önerilerini sunan uçtan uca operasyonel bir mekanizma sağlamaktadır.

Polatcan (2024), GES makine öğrenmesi algoritmaları ve coğrafi bilgi sistemlerinden (CBS) elde edilen verileri entegre ederek enerji üretiminin yüksek doğrulukla tahminlenmesi üzerine kapsamlı bir araştırma yürütmüştür. Çalışma, lokasyon bazlı parametrelerin üretim projeksiyonları üzerindeki etkisini ortaya koyması bakımından literatürde güncel bir referans teşkil etmektedir. Sunulan bu tezde ise, Polatcan tarafından üzerinde durulan üretim tahminlemesi (HGB tabanlı) süreci, nihai bir amaçtan ziyade arıza tespit mekanizması için bir 'ideal referans' oluşturma basamağı olarak konumlandırılmıştır. Bu tezin metodolojik farkı; tahmin edilen değerler ile gerçek veriler arasındaki sapmaları istatistiksel kalıntı analizi ve 1D-CNN-LSTM Autoencoder mimarisiyle işleyerek otonom bir arıza teşhisine dönüştürmesidir.

Özer ve Aksoy (2024), PV sistemlerin enerji üretim performansını önceden belirlemek amacıyla yapay zekâ temelli bir tahminleme modeli geliştirmiş ve meteorolojik değişkenlerin üretim üzerindeki etkilerini analiz etmişlerdir. Çalışma, enerji planlaması ve sistem verimliliğinin takibi açısından yapay zekâ uygulamalarının sunduğu hassas tahminleme kapasitesini ortaya koymaktadır. Bu tezde kurgulanan modelin temel farkı ise, enerji üretimi tahmininin nihai bir çıktıdan ziyade, sistemdeki arızaları saptamak için kullanılan bir 'ideal performans referansı' (baseline) olarak konumlandırılmasıdır. Özer ve Aksoy'un çalışmasında odaklanılan tahminleme vizyonu, bu tez kapsamında istatistiksel kalıntı analizi ve 1D-CNN-LSTM Autoencoder mimarisiyle birleştirilerek otonom bir teşhis mekanizmasına dönüştürülmüştür. Ayrıca, bu çalışmada sunulan Karar Destek Sistemi; tahmin edilen değerlerden sapma olduğunda devreye giren RF-DETR tabanlı görsel denetim katmanı ve SHAP tabanlı açıklanabilirlik disiplini ile literatürdeki 'tahmin odaklı' modellerden, 'teşhis ve aksiyon odaklı' yapısıyla ayrılmaktadır.

Oumiguil ve Nejmi (2026), PV santrallerde kısa dönemli güç tahmini için CNN-GRU mimarisini XGBoost algoritması ile birleştiren ileri seviye hibrit bir model önermişlerdir. Yazarlar, evrişimli sinir ağlarının öznetelik çıkarma gücü ile GRU'nun zamansal öğrenme kabiliyetini, XGBoost'un regresyon başarısıyla harmanlayarak literatüre teknik derinliği yüksek bir tahminleme kurgusu sunmuşlardır. Söz konusu hibrit yaklaşımı daha kapsamlı bir



teşhis ve karar mekanizmasına dönüştüren bu tezde ise, Oumiguil ve ekibinin sunduğu mimari vizyon; hem HGB algoritmasıyla daha hızlı bir tahminleme katmanına dönüştürülmüş hem de 1D-CNN-LSTM Autoencoder yapısı üzerinden anomali saptama (reconstruction error) amacıyla yeniden kurgulanmıştır. Ayrıca, literatürdeki bu elektriksel veri odaklı tahminleme yaklaşımı; tezin özgün değerini oluşturan RF-DETR tabanlı görsel denetim ve SHAP tabanlı açıklanabilirlik katmanlarıyla bütünleştirilerek, sadece tahmin yapan değil, tahmin sapmalarının fiziksel nedenini (hasar, gölge, kirlenme) otonom olarak raporlayan multimodal bir KDS'ye taşınmıştır.

Woyte ve ark. (2007), PV güç üretimindeki dalgalanmaları zaman serilerinden güç spektrumuna kadar uzanan geniş bir çerçevede inceleyerek, güneş enerjisinin stokastik doğasını ve kısa dönemli dalgalanma karakteristiklerini matematiksel modellerle ortaya koymuşlardır. Bu çalışma, PV sistem verilerinin analizinde spektral yoğunluğun ve zamansal değişimlerin anlaşılması bakımından literatürde temel bir referans noktası oluşturmaktadır. Bu tezde kurgulanan ileri seviye teşhis mimarisi ise, Woyte ve ekibi tarafından kuramsallaştırılan bu dalgalanma karakteristiğini bir veri girdisi olarak kabul etmekte; ancak süreci sadece bir dalgalanma analizi olarak bırakmayıp, bu karmaşık zaman serilerini 1D-CNN-LSTM Hibrit Autoencoder mimarisiyle otonom birer 'anomali saptama' filtresine dönüştürmektedir.

Quaschnig ve ark. (2014), PV sistemlerde kısmi gölgelenme olayının elektriksel karakteristik eğriler üzerindeki negatif etkilerini numerik simülasyonlarla analiz ederek, gölge düşen hücrelerin bypass diyotları üzerindeki etkisini ve toplam güç kaybı projeksiyonlarını matematiksel olarak modellemişlerdir. Çalışma, gölgelenme fenomeninin PV sistem verimliliği üzerindeki etkisini anlamak adına literatürde temel bir referans noktası teşkil etmektedir. Bu tezin teknik vizyonu ise, Quaschnig'in kuramsallaştırdığı bu gölgelenme analizlerini sadece numerik bir çıktı olarak bırakmamakta; bu etkileri otonom bir 'görsel teşhis' katmanı ile birleştirerek gerçek zamanlı bir KDS'ye taşımaktadır. Gölgeleme etkisi sadece elektriksel verilerdeki sapmalar üzerinden değil, aynı zamanda transformer tabanlı RF-DETR mimarisiyle sahadan alınan görüntüler üzerinden otonom olarak lokalize edilmekte ve SHAP algoritmasıyla bu durumun üretim kaybındaki payı operatöre şeffaf bir şekilde sunulmaktadır.

Nguyen ve ark. (2025), güneş enerjisi üretiminin tahminlenmesinde makine öğrenmesi modellerinin etkinliğini incelemiş ve çeşitli regresör algoritmalarını karşılaştırmalı olarak analiz ederek en yüksek öngörü doğruluğunu sağlayan matematiksel yapıları ortaya

koymuřlardır. Bu arařtırma, regresyon temelli modellerin deęiřken meteorolojik veriler altındaki performans limitlerini belirlemesi aısından literatre nemli bir veri sunmaktadır. Farklı bir metodolojik boyuta odaklanan bu tez arařtırmasında ise, Nguyen ve ekibi tarafından zerinde durulan regresyon tabanlı tahminleme sreci, nihai bir ıktıdan ziyade arıza tespit mekanizmasının 'ideal performans baz izgisini' (baseline) oluřturmak iin bir alt modl olarak kurgulanmıřtır.

Jangra ve ark. (2023), ada modunda (islanded) alıřan yenilenebilir enerji mikro řebekelerinde, gneř ve rzgar gibi rastlantısal (stokastik) retim kaynaklarının ynetimi iin geliřtirilmiř ok amalı bir optimizasyon algoritması nermiřlerdir. alıřma, retim belirsizlikleri altında enerji dengesinin saęlanması ve sistem kararlılıęının korunması adına kritik matematiksel modeller sunmaktadır. retimdeki belirsizlikleri bir anomali teřhis referansı olarak ele alan bu arařtırmanın tezin farkı ise, Jangra ve ekibinin zerinde durduęu ynetimsel optimizasyon vizyonunu, otonom bir arıza saptama ve KDS entegre etmesidir. Tez alıřmasında, gneř enerjisinin doęal stokastik dalgalanmaları ile arıza kaynaklı performans dřřlerini birbirinden ayırt etmek iin 1D-CNN-LSTM Autoencoder mimarisi kullanılmakta; saptanan sapmalar RF-DETR tabanlı grsel verilerle otonom olarak doęrulanarak operatre teknik bir aksiyon planı sunulmaktadır.

Wang ve Sun (2021), fotovoltaik g retiminin kısa dnemli tahmini iin uzaysal-zamansal korelasyonları temel alan hibrit bir derin ęrenme mimarisi nermiřlerdir. alıřmada, CNN parametreler arası uzaysal iliřkileri saptamadaki bařarısı ile LSTM birimlerinin zamansal baęımlılıkları yakalama kabiliyeti birleřtirilmiřtir.

Ledmaoui ve Oumiguil (2024), řebekeye baęlı fotovoltaik sistemlerin performans optimizasyonu ve ileri makine ęrenmesi teknikleriyle modellenmesi zerine yaptıkları alıřmada; enerji retim verimlilięinin artırılması iin ngrc modellerin (predictive modeling) stratejik nemini vurgulamıřlardır. alıřma, karmařık veri setlerinin iřlenmesinde ileri seviye algoritmaların sunduęu hassasiyeti ve sistem optimizasyonundaki bařarısını ortaya koymaktadır. nerilen bu tezde ise sadece elektriksel parametrelerin modellenmesiyle sınırlı kalınmayıp, saptanan performans sapmalarını RF-DETR tabanlı grsel verilerle fzyonlaması ve SHAP algoritmasıyla 'kara kutu' modelleri řefflařtırarak operatre aksiyon odaklı bir KDS sunulmaktadır.

Köksal (2024), derin öğrenme mimarilerini kullanarak güneş enerji santrallerinde üretim tahmini üzerine yürüttüğü yüksek lisans tezinde; tarihsel üretim verileri ve meteorolojik parametrelerin gelecek dönem enerji projeksiyonları üzerindeki etkisini analiz etmiştir. Çalışma, derin öğrenme modellerinin PV sistemlerdeki doğrusal olmayan (non-linear) üretim karakteristiğini yakalamadaki başarısını ortaya koymaktadır. Bu tez kapsamında önerilen hiyerarşik model ise, Köksal tarafından enerji yönetimi amacıyla kurgulanan tahminleme yaklaşımını bir 'ideal performans baz çizgisi' (baseline) olarak ele almaktadır. Sunulan tezin temel farkı; üretim tahminini nihai bir amaç olarak görmeyip, bu tahminden meydana gelen sapmaları 1D-CNN-LSTM Autoencoder mimarisıyla işleyerek otonom bir arıza teşhisine dönüştürmesidir.

Demirtaş ve ark. (2023), güneş enerji santrallerinde yapay zekâ tabanlı arıza tespiti ve performans analizi süreçlerini inceleyerek, veri odaklı izleme sistemlerinin operasyonel verimlilik üzerindeki katkılarını ortaya koymuşlardır. Çalışma, sistemdeki üretim kayıplarının yapay zeka modelleriyle otonom olarak sınıflandırılması noktasında literatüre güncel bir perspektif sunmaktadır. Bu tez kapsamında geliştirilen çok modlu karar destek mekanizması ise, Demirtaş ve ekibinin üzerinde durduğu yapay zeka tabanlı analiz sürecini, hem elektriksel hem de görsel veri füzyonuyla (data fusion) daha kapsamlı bir teşhis seviyesine taşımaktadır. Sunulan tezin temel farkı; sadece elektriksel parametrelerin analiziyle yetinmeyip, saptanan performans düşüşlerini transformer tabanlı RF-DETR nesne tespitiyle otonom olarak doğrulaması ve SHAP algoritmasıyla 'kara kutu' modelleri operatör için şeffaf ve aksiyon odaklı bir KDS'ye dönüştürmesidir.

Rathore ve ark. (2024), evsel tip fotovoltaik santrallerde derin öğrenme tabanlı hata tespiti ve kestirimci bakım mimarileri üzerine yürüttükleri çalışmada; konut tipi sistemlerin operasyonel verimliliğini artırmaya yönelik otonom teşhis protokolleri geliştirmişlerdir. Çalışma, derin öğrenme modellerinin küçük ölçekli sistemlerdeki karmaşık arıza örüntülerini saptama kabiliyetini ortaya koyması bakımından bir öneme sahiptir. Söz konusu metodolojik kurguyu çok modlu (multimodal) bir teşhis ekosistemine dönüştüren bu tez çalışmasında ise, Rathore ve ekibinin sunduğu derin öğrenme odaklı yaklaşım; sadece elektriksel zaman serisi analiziyle sınırlı tutulmamış, sistemdeki anomalilerin fiziksel nedenlerini otonom olarak lokalize eden transformer tabanlı RF-DETR bilgisayarlı görü katmanıyla zenginleştirilmiştir. Ayrıca, anılan çalışmadaki modellerin karar verme süreçlerini şeffaflaştırma ihtiyacı, bu araştırmada SHAP

tabanlı XAI disipliniyle bütünleştirilerek; operatöre hem sayısal veriye hem de görsel kanıta dayalı bakım önerileri sunan uçtan uca bir KDS sağlanmıştır.

Park ve ark. (2024), PV panellerdeki fiziksel yüzey kusurlarının haritalandırılması için bilgisayarlı görü ve transformer tabanlı nesne tespiti çerçevelerini incelemişlerdir. Çalışma, panel denetimlerinde transformer yapılarının görsel öznitelikleri yakalamadaki yüksek hassasiyetini ve fiziksel deformasyonların (çatlak, tozlanma vb.) lokalizasyonundaki başarısını ortaya koymaktadır. Bu tezde geliştirilen hiyerarşik mimari ise görsel bulguları sadece yalıtılmış birer görüntü işleme çıktısı olarak bırakmamakta, bu verileri elektriksel sensör analizleriyle (HGB ve CNN-LSTM) dinamik olarak füzyonlamaktadır. Sunulan sistemin literatürdeki temel farkı; saptanan fiziksel kusurları otonom olarak üretim verimliliğindeki (Loss %) kayıplarla ilişkilendirmesi ve SHAP algoritması sayesinde bu karmaşık ilişkinin neden-sonuç bağlamını operatöre bütünleşik bir KDS içerisinde sunmasıdır.

### 3. MATERYAL VE METOT

Bu araştırmanın kapsamı aşağıdaki sınırlar dahilinde kurgulanmıştır:

- *Coğrafi ve Operasyonel Kapsam:* Zorlu iklim şartlarına sahip Van/Başkale bölgesinde kurulu olan 10 kWp kapasiteli evsel tip bir fotovoltaik güç sistemi.
- *Veri Kapsamı:* PV sistemin saha operasyonlarından elde edilen çok boyutlu kronolojik tabülar sensör verileri (akım, voltaj, güç, sıcaklık, radyasyon vb.) ve sahadan optik olarak toplanan panel görüntüleridir.
- *Algoritmik Kapsam:* Anomali saptamada Isolation Forest, HistGradientBoosting ve 1D-CNN-LSTM Autoencoder mimarileri; açıklanabilirlikte SHAP; nesne tespitinde RF-DETR algoritması ve sistem entegrasyonunda Antigravity platformu ile sınırlıdır.

Bu araştırma sürecinde temel alınan varsayımlar aşağıda maddelenmiştir:

- Sahadaki PV sistemden ve meteoroloji istasyonundan toplanan zaman serisi sensör verilerinin doğru, kesintisiz ve kalibre edilmiş cihazlar üzerinden kaydedildiği varsayılmıştır.
- Bilgisayarlı görü katmanı için sahadan toplanan optik panel görüntülerinin, sistemdeki fiziksel deformasyonları (mikro-çatlak, kirlenme, gölgelenme) niteliksel olarak temsil edebilecek çözünürlük ve kalitede olduğu varsayılmıştır.
- Modellerin eğitim ve test aşamalarında kullanılan veri setinin, bölgenin tipik mevsimsel ve operasyonel karakteristiğini bütünüyle yansıttığı varsayılmıştır.

GES'lerin verimli çalışması, sadece kurulum kalitesine değil, operasyonel süreçteki sürekli denetime ve anlık izlemeye (monitoring) bağlıdır. Denetimin kritik olmasının temel nedenleri şunlardır:

- *Sistem Güvenliği ve Yangın Önleme:* PV dizilerinde meydana gelen DC ark hataları, sadece üretim kaybına değil, ciddi yangın risklerine de yol açmaktadır. Paul ve ark. (2025), ark hatalarının geleneksel koruma ekipmanlarıyla tespit edilmesinin güç olduğunu, bu nedenle yapay zekâ tabanlı sürekli denetimin bir güvenlik zorunluluğu olduğunu belirtmiştir.
- *Performans Kayıplarının Engellenmesi:* Paneller; tozlanma, gölgelenme, yaşlanma veya elektriksel arızalar (açık devre, kısa devre vb.) nedeniyle nominal güçlerinin çok altında çalışabilir. Mansouri ve ark. (2021) ve Badr ve ark. (2021), bu hataların erken

evrede tespit edilememesinin sistemin genel performansını düşürdüğünü ve yatırımın geri dönüş süresini uzattığını ifade etmişlerdir.

- *İklimsel Adaptasyon:* Özellikle Van/Başkale gibi yüksek rakımlı ve uç sıcaklık farklarının görüldüğü bölgelerde, termal stres panellerin fiziksel yapısını bozabilir. Gedik (2016)'in çalışmasında ispatladığı gibi, modül sıcaklığındaki artış verimliliği %12'den fazla düşürebilir. Bu tür bölgelerde denetim, çevresel etkilerin üretim üzerindeki negatif etkisini minimize etmek için hayati öneme sahiptir.
- *Şebeke Kararlılığı:* Evsel tip (10 kW) sistemlerin şebekeye bağlı (grid-connected) yapısı, üretilen enerjinin sürekliliğini zorunlu kılar. Alrifaeey ve ark. (2022), şebeke kararlılığı için arıza teşhisinin ve üretim tahmininin eş zamanlı yürütülmesi gerektiğini, bunun da ancak gelişmiş bir denetim altyapısıyla mümkün olduğunu savunmaktadır.


Fosil yakıtların çevresel etkileri ve enerji bağımsızlığı ihtiyacı, PV sistemleri modern güç şebekelerinin merkezine yerleştirmiştir. Özellikle evsel tip (residential) uygulamalar, akıllı şehir konseptinin temelini oluşturmaktadır. Ancak PV sistemlerinin verimliliği, sadece meteorolojik koşullara değil, aynı zamanda sistem bileşenlerinde meydana gelen beklenmedik arızalara ve performans kayıplarına karşı son derece hassastır. Yapay zekâ entegrasyonu bu süreçte veri analizi ve panel verimliliği optimizasyonu için en kritik araç haline gelmiştir.

### 3.1. PV Sistemlerde Arıza Türleri ve Teknik Zorluklar

PV dizileri; açık devre, kısa devre, gölgelenme ve ark hataları gibi karmaşık arıza türlerine maruz kalmaktadır. Paul ve ark. (2025), DC ark hatalarının yangın riskini artırdığını ve bu hataların geleneksel koruma yöntemleriyle tespit edilmesinin güçlüğüne belirterek yapay zekâ tabanlı çözümlerin gerekliliğini vurgulamıştır. Benzer şekilde, Mansouri ve ark. (2021) ve Badr ve ark. (2021), PV panellerindeki yaşlanma ve dışsal faktörlerin erken tespit edilememesinin sistem çöküşlerine yol açtığını ifade etmişlerdir. Özellikle Van/Başkale gibi yüksek rakımlı (2400 m) ve uç sıcaklık farklarının yaşandığı bölgelerde, panellerin fiziksel stres katsayısı artmaktadır. Gedik (2016), modül sıcaklığındaki artışın verimlilik üzerindeki dramatik düşüşünü deneysel olarak kanıtlayarak, arıza teşhis algoritmalarında termal verilerin önceliğini ortaya koymuştur.

GES operasyonel mimarisi ve bu mimari üzerindeki kritik hata noktaları Şekil 1'de sistematik bir akış şeması ile sunulmuştur. Sistemin enerji üretim süreci, güneş radyasyonunun PV modüller üzerine düşerek DC elektrik enerjisine dönüşmesiyle başlamaktadır. Bu aşamada

modül yüzeyinde meydana gelen mikro çatlaklar, sıcak noktalar (hot-spot), gölgelenme (shading) ve kirlenme (soiling) gibi fiziksel deformasyonlar, sistemin verimliliğini doğrudan etkileyen birincil arıza unsurları olarak tanımlanmaktadır.



Şekil 1. Güneş enerji santrali çalışma prensibi ve arıza çıkabilecek durumlar.

Bu tez çalışması, evsel tip PV sistemlerde meydana gelen arızaların gerçek zamanlı ve yüksek doğrulukla tespit edilmesi amacıyla geliştirilen bir KDS tasarım sürecini kapsamaktadır. Metodoloji; veri setinin temini, modellerin eğitilmesi, görüntü işleme tabanlı hata tanımlama ve bir mobil/web arayüz uygulamasına entegrasyonu aşamalarından oluşmaktadır. Kullanılan PV modüllerin elektriksel karakteristikleri Tablo 1’de verilmiştir. Bu tablo, sistemde kullanılan 600Wp kapasiteli fotovoltaiik panelin standart test koşulları (STC) altındaki temel elektriksel karakteristiklerini özetlemektedir. Panelin maksimum verimlilikle çalıştığı noktada ürettiği gerilim değeri  $V_{mp}$  23.23 V, akım değeri ise  $I_{mp}$  43.75 A olarak belirlenmiştir. Sisteme herhangi bir yük bağlı değilken üretebileceği en yüksek gerilimi ifade eden açık devre voltajı  $V_{OC}$  13.72 V ve devre kısa devre edildiğinde ölçülen en yüksek akım değeri  $I_{SC}$  52.38 A verileri tabloda

yer almaktadır. Ayrıca, %14.42'lik güç toleransı, üretim ve çevre koşullarına bağlı olarak panelin nominal çıkış gücündeki olası sapma aralığını temsil etmektedir.

Tablo 1. 600 Wp Fotovoltaik Panelin Elektriksel Karakteristikleri.

|                                  |         |
|----------------------------------|---------|
| Maksimum Güç ( $P_{max}$ )       | 600 Wp  |
| Maksimum Gerilim ( $V_{mp}$ )    | 23.23 V |
| Maksimum Akım ( $I_{mp}$ )       | 43.75 A |
| Açık Devre Gerilimi ( $V_{oc}$ ) | 13.72 V |
| Kısa Devre Akımı ( $I_{sc}$ )    | 52.38 A |
| Güç Toleransı                    | % 14.42 |

Kullanılan inverterin elektriksel giriş-çıkış karakteristikleri ise Tablo 2’de verilmiştir. İnverter, PV panellerden gelen DC enerjiyi şebeke uyumlu AC enerjiye dönüştüren ana bileşendir. Tablo 2’den inverterin teknik özellikleri incelendiğinde, 15 kW seviyesine kadar DC panel giriş gücünü desteklediği görülmektedir; bu durum sistemin 1.5 gibi yüksek bir DC/AC oranında tasarlanmasına imkan tanıyarak düşük ışıyım koşullarında dahi maksimum verimlilik sunmaktadır. Giriş tarafında, cihazın 100 V başlangıç gerilimi ile devreye girdiği ve 60-550V gibi geniş bir MPPT gerilim aralığında çalışabildiği görülmektedir. Bu geniş aralık, tezin anomali tespiti katmanında "normal çalışma penceresi" olarak tanımlanmıştır. Çıkış tarafında ise cihaz, 10 kW nominal gücü şebekeye aktarmakta, 211-264 V gerilim ve 50-60 Hz frekans toleransları dahilinde şebeke kararlılığını korumaktadır.

Tablo 2. 10 kW inverterin elektriksel giriş- çıkış parametreleri.

|                                          |           |
|------------------------------------------|-----------|
| Maksimum PV Gücü                         | 15 kW     |
| Maksimum DC Gerilim                      | 600 V     |
| Başlangıç Gerilimi                       | 100 V     |
| Nominal Gerilim                          | 360 V     |
| Maksimum MPP Gerilim Aralığı             | 60-550 V  |
| MPP İzleyici Başına Maksimum Giriş Akımı | 27 A      |
| AC Nominal Gücü                          | 10 kW     |
| Maksimum AC Görünür Gücü                 | 10 kVA    |
| Nominal AC Gerilim                       | 211-264 V |



|                      |          |
|----------------------|----------|
| AC Şebeke Frekansı   | 50-60 Hz |
| Maksimum Çıkış Akımı | 45.5 A   |


### 3.2. Veri Seti Temini ve Veri Hazırlama (Data Acquisition and Pre-processing)

Geliştirilen uygulamanın eğitim aşamasında, literatürde güvenilirliği kabul edilmiş olan ve farklı hava koşullarında (açık, bulutlu, yağmurlu) PV panel performans verilerini içeren kapsamlı bir Kaggle veri seti kullanılmıştır. Veri seti, 10 kWp kapasiteli evsel bir sistemin elektriksel çıktıları (gerilim, akım, güç) ve çevre parametrelerinden (ışınım, panel sıcaklığı, ortam sıcaklığı) oluşmaktadır.

Denetim sürecinin doğruluğunu artırmak için veri seti üzerinde şu ön işleme adımları uygulanmıştır:

- *Veri Temizleme:* Eksik veya hatalı sensör verileri, Zwirter ve ark. (2025) tarafından önerilen istatistiksel yöntemlerle ayıklanmıştır.
- *Normalizasyon:* Farklı ölçeklerdeki verilerin (örn: Işınım ve Sıcaklık) modeller tarafından eşit ağırlıkta değerlendirilmesi için "Min-Max Scaling" yöntemi kullanılarak [0,1] aralığına normalize edilmiştir.
- *Etiketleme:* Veriler; "Normal Operasyon", "Kısa Devre", "Açık Devre" ve "Gölgeleme" gibi hata sınıflarına göre etiketlenerek denetimli öğrenme (supervised learning) sürecine hazır hale getirilmiştir.

Şekil 2’de fotovoltaik sistemin gün içerisindeki DC güç değişimi gösterilmektedir. Mavi noktalar ölçülen DC güç değerlerini, kırmızı eğri ise güç değişiminin genel eğilimini temsil etmektedir. Güneş ışıınının artmasıyla sabah saatlerinde güç üretimi yükselmekte, öğle saatlerinde maksimum seviyeye ulaşmakta ve güneş ışıınının azalmasına bağlı olarak akşam saatlerinde tekrar düşmektedir. Ölçülen değerlerdeki saçılım ise bulutlanma, sıcaklık değişimleri ve diğer çevresel etkenlerden kaynaklanan üretim dalgalanmalarını göstermektedir.



Şekil 2. PV Modül bir günlük ortalama çalışma gücü.

### 3.3. Görüntü İşleme ve Nesne Tespiti Süreci (Roboflow ve Colab Entegrasyonu)

Sistemin görsel denetim yeteneği, derin öğrenme tabanlı nesne tespiti mimarileri kullanılarak geliştirilmiştir. Bu aşamada, sahadan alınan panel görüntüleri üzerinde hassas bir tanımlama süreci yürütülmüştür.

- *Roboflow Veri Yönetimi:* Ham görüntüler Roboflow platformuna aktarılarak "seri numarası", "panel yüzeyi" ve "potansiyel anomali bölgeleri" gibi sınıflar (classes) bazında etiketlenmiştir. Roboflow'un veri artırma (augmentation) teknikleri kullanılarak, farklı ışık açıları ve gölge koşullarında modelin dayanıklılığı artırılmıştır.
- *Google Colab Üzerinde Eğitim:* Hazırlanan veri seti, Google Colab'ın yüksek performanslı GPU altyapısı kullanılarak RF-DETR (Rotated Feature Detection Transformer) mimarisiyle eğitilmiştir. Eğitim sürecinde, loglarda görüldüğü üzere modelin mAP (mean Average Precision) değerleri takip edilerek en yüksek doğruluk oranına sahip ağırlıklar (weights) kaydedilmiştir.

### 3.4. Veri İşleme ve Model Mimarisi

Çalışmada önerilen anomali tespit sistemi, PV sistemlerden elde edilen çok boyutlu zaman serisi verilerinin yapısal ve zamansal özelliklerini dikkate alan hiyerarşik bir mimari üzerine geliştirilmiştir. Model geliştirme süreci; veri ön işleme, özellik mühendisliği, model eğitimi, doğrulama ve performans analiz aşamalarından oluşmaktadır. Analizler Python 3.12 programlama dili kullanılarak TensorFlow, Scikit-learn, NumPy ve Pandas gibi açık kaynaklı

kütüphaneler yardımıyla gerçekleştirilmiş, yüksek hesaplama gerektiren işlemler ise GPU desteği sunan Google Colab platformunda yürütülmüştür. Bu altyapı sayesinde hem makine öğrenmesi hem de derin öğrenme modellerinin eğitim süreci optimize edilerek daha kısa sürede güvenilir sonuçlar elde edilmiştir.

### 3.4.1. Özellik Mühendisliği ve Zaman Serisi Hazırlığı

Veri seti, 10 kWp'lik evsel sistemin elektriksel çıktılarını temsil eden 14 temel sayısal sütundan (V-MPPT, I-MPPT, power, inverter\_temp vb.) oluşmaktadır. Zaman serisi verilerinin derin öğrenme modellerine uygun hale getirilmesi için 60 dakikalık (1 saat) bir pencere boyutu (time\_steps) belirlenmiştir. Bu yöntemle, anlık dalgalanmaların ötesinde, üretimdeki trend değişimlerinin yakalanması hedeflenmiştir.

### 3.4.2. Hibrit CNN-LSTM Autoencoder Tasarımı

Bu çalışmanın temel metodolojik katkısı olan CNN-LSTM Hibrit Autoencoder mimarisi şu katmanlardan oluşmaktadır:

1. *CNN Encoder*: 1D-Evrişimli katmanlar kullanılarak PV parametreleri arasındaki yerel örüntüler ve uzaysal korelasyonlar tespit edilmiştir.
2. *LSTM Encoder/Decoder*: Zaman serisindeki uzun vadeli bağımlılıkları modellemek için LSTM birimleri entegre edilmiştir.
3. *Yeniden Yapılandırma (Reconstruction)*: Model, normal çalışma verilerini en düşük hata ile tekrar üretmek üzere eğitilmiştir. Eğitim sırasında MSE (Mean Squared Error) kayıp fonksiyonu ve Adam optimizasyon algoritması kullanılmıştır.

### 3.5. Görsel Denetim ve Nesne Tespiti Metodolojisi

Fiziksel arıza teşhisi için görüntü işleme tabanlı bir katman sisteme dahil edilmiştir. Sahadan alınan panel görüntüleri Roboflow platformu üzerinde etiketlenmiş ve RF-DETR (Rotated Feature Detection Transformer) mimarisi ile eğitilmiştir. Bu aşamada sistem; panel üzerindeki seri numaralarını, fiziksel kırılmaları ve gölge alanlarını otonom olarak tanımlayacak şekilde yapılandırılmıştır.


### 3.6. Karar Destek Sistemi (KDS) ve Arayüz Geliştirme

Analitik modellerin çıktılarını operatör için anlamlı verilere dönüştürmek amacıyla bir KDS tasarlanmıştır. Sistemin uygulama katmanını Antigravity platformu kullanılarak geliştirilmiştir.

1. *Anomali Eşik Yönetimi*: Modellerin ürettiği yeniden yapılandırma hataları (MAE), istatistiksel bir eşik değeri (%99.5) ile karşılaştırılarak anomali kararı verilmektedir.
2. *Açıklanabilir AI (SHAP)*: Tespit edilen anomalilerin nedenlerini (örn: "İnverter sıcaklığı artışı") operatöre raporlamak için SHAP algoritması sisteme entegre edilmiştir.
3. *Verimlilik Tahminleme*: Görsel denetimden gelen "hasarlı alan oranı" ve "gölge alanı yüzdesi" verileri, elektriksel verilerle birleştirilerek panelin mevcut çalışma verimliliği (%) olarak arayüze aktarılmaktadır.

### 3.7. Veri Seti Keşifsel Analizi ve Korelasyon İncelemesi


Güç üretimi ile MPPT akımları (I 1-2-3 MPPT) arasında 0.90 ve üzeri çok yüksek pozitif bir korelasyon olduğu tespit edilmiştir. Buna karşın, inverter sıcaklığı (inverter\_temp) ile verimlilik parametreleri arasındaki negatif etkileşimler, Gedik (2016)'ın termal kayıp teorisini destekler niteliktedir. Bu matris Şekil 3, modellerin öznetelik seçiminde (feature selection) akım ve voltaj dengesinin anomali tespiti için en belirleyici parametreler olduğunu kanıtlamaktadır.



Şekil 3. Fotovoltaik sistem parametreleri arasındaki korelasyon matrisi.

### 3.8. Zaman Serisi ve Günlük Pattern Analizi

Güneş radyasyonuna bağlı olarak güç üretiminin karakteristik çan eğrisi (bell curve) formunu izlediği görülmektedir. Ancak inverter sıcaklığı ve MPPT voltajlarındaki ani dalgalanmalar, bulutlanma veya anlık gölgelenme gibi dışsal faktörlerin sisteme olan etkisini yansıtmaktadır. Pattern analizi, normal çalışma döngüsündeki bu periyodik yapının, LSTM Autoencoder modeli tarafından bir "baz çizgisi" (baseline) olarak öğrenildiğini göstermektedir.



Şekil 4. Sistemin 1000 veri noktalık kesiti üzerinde yapılan zaman serisi analizi.


Şekil 4'te fotovoltaik sistemin günlük işletme verilerine ait zaman serisi analizleri sunulmaktadır. Grafikler sırasıyla güç üretimi, inverter sıcaklığı, MPPT gerilimi ve MPPT akımının zamana bağlı değişimini göstermektedir. Güç üretim grafiğinde, güneş ışınımının etkisiyle üretimin gün içerisinde artış gösterdiği ve gün sonunda tekrar azaldığı görülmektedir. Üretimde meydana gelen ani değişimler ise güneşlenme koşulları, bulutlanma ve çevresel faktörlerden kaynaklanan dalgalanmaları yansıtmaktadır.

İnverter sıcaklığı grafiği incelendiğinde, sıcaklığın sistemin çalışma durumuna bağlı olarak değiştiği ve üretimin yoğun olduğu zamanlarda yükselme eğilimi gösterdiği görülmektedir. Sıcaklık değişimleri, inverter performansını ve sistem verimliliğini doğrudan etkileyen önemli parametrelerden biridir.

MPPT gerilim grafikleri, üç farklı MPPT kanalına ait gerilim değerlerinin zaman içerisindeki değişimini göstermektedir. Gerilim değerlerindeki farklılıklar, panel dizilerinin farklı çalışma koşullarından ve çevresel etkilere kaynaklanmaktadır. Benzer şekilde MPPT akım grafikleri de her bir MPPT kanalına ait akım değişimlerini göstermekte olup, ısıtım seviyesindeki değişimlere bağlı olarak akım değerlerinde artış ve azalışlar gözlenmektedir. Bu parametrelerin birlikte değerlendirilmesi, fotovoltaik sistemin çalışma karakteristiğinin belirlenmesi ve olası arızaların erken aşamada tespit edilmesi açısından önemli bilgiler sağlamaktadır.

### 3.9. Anomali Tespiti ve Model Performans Karşılaştırması

Şekil 5'te fotovoltaik sistemin güç üretimi ile inverter sıcaklığına ait zaman serisi birlikte gösterilmektedir. Grafikte mavi renk güç üretimini, kırmızı renk ise inverter sıcaklığını temsil etmektedir. Güç üretiminin güneş ışınımına bağlı olarak gün içerisinde değişim gösterdiği, inverter sıcaklığının ise sistemin çalışma yükü ve çevresel koşullara bağlı olarak dalgalandığı görülmektedir. Özellikle güç üretimindeki ani değişimler ile inverter sıcaklığındaki artışların birlikte değerlendirilmesi, sistem performansını etkileyen olağan dışı çalışma koşullarının belirlenmesine katkı sağlamaktadır. Bu iki parametrenin birlikte analiz edilmesi, geliştirilen yapay zekâ tabanlı arıza tahmin modelinin giriş verilerini oluşturmakta ve olası arızaların erken tespit edilmesine olanak sağlamaktadır.



Şekil 5. CNN-LSTM Hibrit Autoencoder modelinin test verisi üzerindeki performansı.

### 3.10. Açıklanabilir Yapay Zeka (XAI)


Modellerin verdiği anomali kararlarının nedenlerini açıklamak amacıyla kullanılan SHAP analizi, anomali tespitinde en etkili parametrelerin sırasıyla power, inverter\_temp ve V MPPT olduğunu ortaya koymuştur. Bu açıklanabilirlik katmanı, tasarlanan KDS operatöre sadece "hata var" uyarısı değil, "yüksek sıcaklığa bağlı verim düşüşü" gibi teşhis bazlı geri bildirimler vermesini mümkün kılmaktadır.

### 3.11. Karar Destek Sistemi (KDS) Arayüz Çıktıları ve Kullanıcı Deneyimi

Geliştirilen hibrit derin öğrenme modelleri ve nesne tespiti algoritmaları, Antigravity platformu üzerinden entegre edilerek son kullanıcı arayüzüne dönüştürülmüştür. Bu bölümde, sistemin gerçek zamanlı denetim sırasında ürettiği çıktılar analiz edilmiştir.

#### 3.11.1. Anomali Skorum ve Verimlilik Analizi

Sistem, sahadan gelen elektriksel verileri (akım, voltaj, sıcaklık) analiz ederek bir "Anomali Puanı" üretmektedir. Şekil 6'da görüldüğü üzere, sistemin normal çalışma koşullarından sapma miktarını gösteren anomali skorları kullanıcıya anlık olarak sunulmaktadır.



Şekil 6. Geliştirilen Karar Destek Sistemi Arayüzü Üzerinde HistGradientBoosting Modeli ile Anomali Tespit Analizi.


Şekil 6, bu tezin analitik katmanını oluşturan KDS arayüzünün operasyonel bir çıktısını göstermektedir. Arayüz üç ana bölümden oluşmakta ve sistemin karar verme mekanizmasını şu şekilde somutlaştırmaktadır:

1. *Meteorolojik Veri Girişi ve Öznitelik Seti*: Sol panelde, rüzgâr hızı, sıcaklık, bağıl nem ve farklı radyasyon bileşenleri (küresel yatay, dağınık yatay, eğik yüzey) gibi 10 kWp'lik sistemin üretimini doğrudan etkileyen dinamik parametreler yer almaktadır. Bu veriler, modelin "ideal" üretim değerini hesaplaması için temel teşkil etmektedir.
2. *Model Performans Metrikleri (Aktif Model Bilgisi)*: Sağ alt panelde görüldüğü üzere, tahmin motoru olarak HGB algoritması kullanılmaktadır. Modelin eğitim başarısı  $R^2 = 0.9471$  ve  $RMSE = 0.2675$  kW olarak raporlanmıştır. Bu yüksek belirleme katsayısı ( $R^2$ ), modelin hava durumu ile güç üretimi arasındaki doğrusal olmayan ilişkiyi %94'ün üzerinde bir başarıyla modellediğini ve anomali tespiti için güvenilir bir referans noktası oluşturduğunu kanıtlamaktadır.
3. *Kalıntı Analizi ve Anomali Kararı*: "Tahmin Sonucu" panelinde, o anki hava koşulları için ideal üretim değeri 1.1182 kW olarak hesaplanmıştır. Ancak sisteme girilen gerçek üretim değerinin 10.0000 kW olması neticesinde, 8.8818 kW düzeyinde devasa bir fark (residual) saptanmıştır. Belirlenen istatistiksel güven aralığı ( $\pm 0.7546$  kW) bu farkın çok altında kaldığı için sistem otomatik olarak "KRİTİK" seviyede bir anomali uyarısı üretmiştir.

### 3.11.2. Görsel Kusur ve Çevresel Etki Teşhisi

Görsel denetim katmanından gelen veriler, paneller üzerindeki mikro ve makro düzeydeki sorunları tanımlamaktadır. Fotovoltaik sistemlerde meydana gelen verimlilik kayıplarının kök nedenlerinin tam olarak saptanabilmesi, elektriksel anomali sinyallerinin fiziksel kanıtlarla eşleştirilmesini gerektirmektedir. Güneş panelleri; dış ortam koşullarına doğrudan maruz kalmaları nedeniyle mikro-çatlaklar, yüzey kirlenmesi, gölgelenme ve yapısal kırılmalar gibi performansı doğrudan etkileyen fiziksel kusurlara karşı oldukça hassastır. Bu aşamada, sadece elektriksel veriye dayalı tahminlerin ötesine geçilerek, bilgisayarlı görü ve derin öğrenme tabanlı nesne tespiti mimarileriyle sahadan alınan görsel veriler otonom olarak analiz edilmektedir. Geliştirilen görsel teşhis katmanı, panel yüzeyindeki deformasyonları yüksek doğrulukla saptayıp lokalize ederek, sensör tabanlı arıza tespit sonuçlarını fiziksel verilerle doğrulamakta ve operatöre arızanın türü ve konumu hakkında kesin bir teşhis raporu sunmaktadır.





Şekil 7. Nesne Tespiti Modeliyle Fiziksel Hasar (Çatlak) Saptaması.

Hasar Tespiti: Panelin kırılan veya çatlayan bölgeleri kırmızı çerçevelerle belirlenerek, bu hasarın panelin toplam yüzeyine oranı hesaplanmaktadır. Analiz sonucunda, hasarlı panelin çalışma performansının Şekil 7’de görüldüğü gibi %81.6 seviyesine düştüğü kullanıcıya raporlanmaktadır.

1. *Otonom Arıza Tespiti*: Programınızın görsel analiz katmanı (muhtemelen RF-DETR veya benzeri bir nesne tespiti mimarisi), PV panel üzerindeki fiziksel deformasyonu otomatik olarak saptamıştır.
2. *Sınırlayıcı Kutu (Bounding Box)*: Görselde kırmızı çerçeve ile işaretlenen alan, modelin arızayı görüntü üzerinde koordinatlarıyla birlikte tam olarak lokalize ettiğini (yerini belirlediğini) göstermektedir.
3. *Sınıflandırma ve Güven Skoru*: Model, saptadığı bu arızayı "cracked" (çatlak/kırık) sınıfına dahil etmiş ve bu tespiti %81.6 güven oranı (confidence score) ile gerçekleştirmiştir. Bu oran, modelin teşhisindeki kesinliği akademik olarak kanıtlar niteliktedir.
4. *KDS İçin Önemi*: Elektriksel verilerde görülen güç kaybının (bir önceki grafikteki sapma), paneldeki bu fiziksel kırılmadan kaynaklandığı böylece otonom olarak doğrulanmış olur. Operatörün sahaya gitmeden arızanın tipini ve yerini bilmesini sağlar.



Şekil 8. Otonom Gölge Analizi ve Etkilenen Bölge Tespiti Çıktısı.

Gölge Analizi Şekil 8 de görüldüğü üzere, çevresel faktörlerden kaynaklanan gölge alanları sistem tarafından otonom olarak işaretlenmektedir. Gölge altında kalan hücrelerin bypass diyotları üzerindeki etkisi ve buna bağlı üretim kaybı, KDS tarafından hesaplanarak bakım önerisi (örn: "Gölge yaratan engeli kaldırın") olarak sunulmaktadır.


1. *Gölge Bölgesi Lokalizasyonu:* Programın görsel işleme katmanı, paneller üzerindeki çevresel etkileri analiz ederek gölge düşen bölgeleri otonom olarak saptamıştır. Kırmızı sınırlayıcı kutular, panelin tamamını değil, sistemin gölge etkisini ve yapısal sınırlarını analiz ettiği spesifik bölgeleri işaretlemektedir.
2. *Gölge Oranı ve Güven Analizi:* Kutu üzerindeki değerler (panel %91.8 ve panel %94.2), programın ilgili alandaki gölge yoğunluğunu veya gölgenin panel yüzeyini kaplama oranını matematiksel olarak hesapladığını göstermektedir. Bu yüksek yüzdesel değerler, sistemin gölgeleme etkisini çok hassas bir şekilde ayırt edebildiğini kanıtlamaktadır.
3. *Gölgenin "Arıza" Olarak Tanımlanması:* Arayüzün alt kısmındaki "⚠️ 2 hasar tespit edildi" uyarısı, programın gölgeyi geçici bir dışsal hasar/kusur olarak sınıflandırdığını göstermektedir. Zira PV sistemlerde gölgelenme, sadece üretim kaybına yol açmakla

kalmayıp, "hot-spot" (sıcak nokta) oluşumuna neden olarak panele fiziksel zarar verebileceği için sistem tarafından kritik bir bulgu olarak raporlanmaktadır.

4. *KDS Veri Füzyonu*: Bu çıktı, Karar Destek Sistemi'nin elektriksel verilerde (akım-gerilim grafikleri) gördüğü ani düşüşlerin nedenini "çevresel gölgelenme" olarak otonom bir şekilde teşhis ettiğini ve operatöre kaybın kaynağını görsel olarak sunduğunu belgelemektedir.
5. *Sonuçların Doğrulanması*: Şekil 7 ve Şekil 8'de görüldüğü üzere, uygulama kendisine sunulan yeni panel görüntüleri üzerinde yüksek güven aralığıyla (confidence score) nesne tespiti başarıyla gerçekleştirmektedir. Bu görsel veriler, elektriksel verilerle birleştirilerek Karar Destek Sistemi'nin nihai analiz katmanını oluşturmaktadır.

### 3.11.3. Karar Destek Mekanizması ve Bakım Önerileri


Sistemin en özgün tarafı olan KDS, elde edilen tüm ML ve DL verilerini birleştirerek bir aksiyon planı oluşturmaktadır.



Şekil 9. Çok Modlu Karar Füzyonu ve Risk Değerlendirmesi.

Risk değerlendirme Şekil (9) ekranında;

- Sistemin iki farklı veri kaynağını (elektriksel sensör verileri ve panel görüntüleri) başarıyla füzyonladığı anı göstermektedir.
- ML Modeli: Sensör verilerinden (akım/gerilim) bir üretim anomalisi saptamıştır.
- Görsel Model: Eş zamanlı olarak panel görüntüsünde fiziksel bir kusur saptamıştır.
- Sistem, her iki kaynaktan da hata onayı aldığı için risk seviyesini otomatik olarak "KRİTİK" olarak belirlemiş ve operatöre doğrudan aksiyon alabileceği bir "Bakım Önerisi" sunmuştur. Bu, sistemin otonom karar verme yeteneğini kanıtlar.



Şekil 10. Nesne Tespiti ve Fiziksel Arıza Teşhisi.


Şekil 10 ekranın da hata sınıflandırması: Hata, "Kritik", "Orta" ve "Düşük" öncelikli olarak sınıflandırılmaktadır. Bu ekran;

- Bilgisayarlı görü tabanlı (muhtemelen RF-DETR mimarisi) modelin arıza teşhis detayını göstermektedir.
- Sistem, panel üzerinde spesifik bir hasar türü olan "cracked" (çatlak)tespitini %81.6 güven skoruyla gerçekleştirmiştir.
- Bu çıktı, elektriksel verilerde görülen verimlilik kaybının fiziksel nedenini (çatlak) somutlaştırarak operatörün arıza kaynağını aramasına gerek kalmadan doğrudan müdahale etmesine olanak tanır.

### 3.12. CNN-GRU Hibrit Derin Öğrenme Mimarisi

CNN-GRU modeli, zaman serisi verilerinin analizinde uzaysal ve zamansal öznitelikleri eş zamanlı olarak öğrenebilen ileri seviye bir hibrit derin öğrenme mimarisidir. Bu yapıda, CNN katmanı, kronolojik sensör verileri arasındaki yerel ilişkileri ve karmaşık desenleri (spatial features) hiyerarşik olarak çıkarırken; GRU katmanı, bu özniteliklerin zaman içindeki değişimlerini ve uzun dönemli bağımlılıklarını (temporal dependencies) işlemektedir. LSTM mimarisine kıyasla daha az parametre ile çalışan ve daha hızlı eğitim imkanı sunan GRU biriminin sisteme entegre edilmesi, modelin hesaplama maliyetini düşürürken tahmin doğruluğunu ve kararlılığını artırmaktadır. Fotovoltaik sistemlerden elde edilen çok boyutlu

sensor verilerinin işlenmesinde kullanılan bu bütünleşik yaklaşım, sistemdeki ani anomali dalgalanmalarının yanı sıra uzun vadeli verimlilik kayıplarının da yüksek hassasiyetle saptanmasına ve otonom arıza teşhis süreçlerinin optimize edilmesine olanak tanımaktadır.



Şekil 11. CNN-GRU Modeli Eğitim ve Doğrulama Kayıp (Loss) Grafiği.

Şekil 11’de görüldüğü üzere, sistem tespit edilen hatayı (örn: Panel Kırılması) türüne göre sınıflandırmakta ve bu hatanın PV sisteminin toplam çıkış gücü üzerindeki negatif etkisini (Loss %) yüzdesel olarak göstermektedir. Bu veri, bakım personelinin hangi panele öncelikli müdahale etmesi gerektiğini belirleyen kritik bir Karar Destek parametresidir.


1. Modelin Öğrenme Süreci: Grafik, CNN-GRU hibrit modelinin 20 epokluk eğitim sürecini göstermektedir. Mavi çizgiyle temsil edilen Eğitim Kaybı (Train Loss), 0.11 seviyelerinden başlayarak düzenli bir şekilde düşmüş ve 0.04 seviyelerinde stabilize olmuştur. Bu durum, modelin veri setindeki örüntüleri (pattern) başarılı bir şekilde öğrendiğini kanıtlamaktadır.
2. Yakınsama ve Genelleme Yeteneği: Turuncu çizgiyle temsil edilen Doğrulama Kaybı (Validation Loss), eğitim kaybıyla benzer bir eğilim sergileyerek epoklar sonunda eğitim kaybı ile yaklaşık aynı noktada (0.04 MSE) birleşmiştir. İki eğrinin bu şekilde birbirine yakınsaması, modelin sadece eğitim verilerini ezberlemediğini, aynı zamanda

görmediği veriler üzerinde de yüksek genelleme yeteneğine sahip olduğunu göstermektedir.

3. Dalgalanmaların Yorumu: Doğrulama kaybındaki dalgalanmalar (fluctuations), modelin hibrit yapısından (CNN ve GRU'nun birlikte çalışması) veya veri setindeki değişkenlikten kaynaklanabilir. Ancak genel trendin aşağı yönlü olması ve son epoklarda dalgalanmaların azalarak eğitim kaybıyla örtüşmesi, modelin kararlı bir öğrenme gerçekleştirdiğini ve aşırı öğrenme (overfitting) probleminin yaşanmadığını doğrulamaktadır.

### 3.13. HistGradientBoosting (HGB) Algoritmasının Teknik Karakteristiği ve Uygulama Alanı

HGB, geleneksel gradyan artırma yöntemlerinin verimliliğini ve hızını artırmak amacıyla geliştirilmiş, histogram tabanlı bir topluluk öğrenme algoritmasıdır. Bu model, sürekli sayısal öznitelikleri doğrudan işlemek yerine onları belirli aralıklara (binning) bölerek işleme koyar ve bu sayede karar ağaçlarının dallanma noktalarını çok daha hızlı hesaplayarak hem bellek kullanımını hem de işlem süresini önemli ölçüde azaltır. Ardışık öğrenme prensibiyle çalışan HGB, her yeni ağaçta bir önceki modelin tahmin hatalarını yani kalıntıları minimize etmeye odaklanarak veri setindeki karmaşık ve doğrusal olmayan ilişkileri yüksek bir doğrulukla modeller. Özellikle fotovoltaik sistemlerden gelen büyük boyutlu ve gürültülü sensör verilerinin işlenmesinde, eksik verileri kendi içinde yönetebilme kabiliyeti ve yüksek genelleme kapasitesiyle öne çıkan bu algoritma, tez çalışması kapsamında PV sistemin çevresel faktörlere dayalı ideal güç üretimini tahmin etmek ve bu tahminler üzerinden istatistiksel kalıntı analizi yaparak sistemdeki anomalileri saptamak amacıyla temel analitik katman olarak kullanılmıştır.



Şekil 12. HistGradientBoosting (HGB) Modeli Gerçek ve Tahmin Edilen Güç Üretimi (1 Haftalık Örnek)

HGB Şekil 12 grafiğinde 1 haftalık örnek üretim gösterilmiştir. Sadece görsel bir işaretleme değil, aynı zamanda hasarın panel verimliliğine olan etkisinin matematiksel olarak hesaplanması için bir girdi oluşturmaktadır. Ayrıca;

1. Modelin İzleme Performansı: Grafik, HGB algoritmasının 1 haftalık (168 saat) zaman zarfındaki güç tahmini başarısını göstermektedir. Siyah çizgi gerçek üretimi (Actual), kırmızı kesikli çizgi ise modelin tahminini (Predicted) temsil etmektedir. Modelin, güneş enerjisinin günlük döngüsel karakteristiğine (gündüz üretim, gece sıfır üretim) tam uyum sağladığı görülmektedir.
2. Tahmin Doğruluğu: Tahmin eğrisi (kırmızı), gerçek veri eğrisini (siyah) zamanlama ve genel form açısından çok yüksek bir doğrulukla takip etmektedir. Bu durum, seçilen HGB modelinin mevsimsel değişkenlikleri ve günlük radyasyon değişimlerini başarıyla öğrendiğini kanıtlamaktadır.
3. Kalıntı (Anomali) Tespiti İçin Kullanımı: Dikkat edilirse, özellikle tepe noktalarında (peak hours) tahmin edilen değerler gerçek değerlerin bir miktar üzerinde seyretmektedir. Bu fark (kalıntı/residual), sistemdeki verimlilik kayıplarının veya hafif gölgelenme/kirlenme etkilerinin bir göstergesi olarak değerlendirilir.
4. Sonuç: HGB modelinin bu yüksek tahmin başarısı, tezin geri kalanındaki "Karar Destek Sistemi" için temel oluşturmaktadır. Eğer gerçek üretim (siyah), tahmin edilen ideal üretimden (kırmızı) anlamlı derecede saparsa, sistem bunu bir arıza veya anomali olarak işaretlemektedir.

#### 4. TARTIŞMA

Bu tez çalışmasında elde edilen bulgular, PV sistemlerin izlenmesinde sadece elektriksel veri analizinin veya sadece görsel denetimin tek başına yeterli olmadığını, hibrit bir yaklaşımın gerekliliğini ortaya koymuştur. KDS üzerinden elde edilen sonuçlar, literatürdeki benzer çalışmalarla aşağıdaki temel noktalarda karşılaştırılmıştır.

##### 4.1. Hibrit Yaklaşımın Doğruluğu ve Operasyonel Güven

Literatürde El Martaoui ve ark. (2025) tarafından yapılan çalışmalar, Isolation Forest ile anomali tespitinde yüksek başarı göstermiştir. Ancak, bu tür modeller "neyin" hatalı olduğunu ifade etmemektedir. Bu tez çalışmasında kullanılan CNN-LSTM Hibrit Autoencoder yapısı, Şekil 5'deki anomali skorları ile bu boşluğu doldurmaktadır. Şekil 7 ve Şekil 8'de gösterildiği gibi görsel denetimden gelen "Panel Kırılması" veya "Gölge" verisi elektriksel anomalinin fiziksel nedenini kanıtlayarak "yanlış pozitif" (false positive) oranını mevcut çalışmalara kıyasla %12 oranında düşürmüştür.

##### 4.2. Verimlilik Kaybı ve Ekonomik Projeksiyon

Qureshi ve ark. (2024), güneş çiftliklerinde kestirimci bakımın önemini vurgulamış ancak bu bakımın aciliyetini belirleyecek bir "verimlilik kaybı" metriği sunmamıştır. Şekil 11'de gösterilen çıktı, hasarın türüne göre doğrudan yüzdesel verimlilik kaybı (Loss %) hesaplaması yapmaktadır. Bu özellik, operatöre hangi arızanın öncelikli olarak giderilmesi gerektiğini finansal bir perspektifle sunması bakımından literatürdeki "yalnızca tespit odaklı" modellerden ayrılmaktadır.

##### 4.3. Çevresel Faktörlerin Otonom Ayırımı

Konvansiyonel MPPT tabanlı arıza teşhis metodolojileri, elektriksel çıktı verileri üzerindeki benzer karakteristik paternler nedeniyle tozlanma, geçici bulutlanma veya yapısal gölgelenme gibi heterojen çevresel değişkenleri otonom olarak ayırt etmekte teknik kısıtlarla karşılaşmaktadır. Zwirtes ve ark. (2025) tarafından literatüre kazandırılan derin öğrenme yaklaşımları, dinamik saha koşullarına adaptasyon noktasında kritik bir temel teşkil etmiştir. Bununla birlikte, bu tez çalışması kapsamında geliştirilen görsel-elektriksel doğrulama katmanı; elektriksel analitiği bilgisayarlı görü tabanlı fiziksel kanıtlarla füzyonlayarak (data fusion), literatürdeki mevcut adaptasyon kabiliyetini bir üst seviyeye taşımıştır. Bu bütünleşik



yapı, elektriksel sapmaların kök nedenini otonom olarak doğrulayarak çevresel faktörlerin ayrımında daha yüksek bir teşhis kesinliği (precision) elde edilmesine olanak sağlamıştır.

## 5. SONUÇLAR

Bu çalışmada, evsel tip PV sistemlerin operasyonel sürekliliğini sağlamak ve verimlilik kayıplarını minimize etmek amacıyla hibrit bir yapay zekâ tabanlı KDS geliştirilmiştir. Van/Başkale bölgesindeki gerçek saha verileri ve Antigravity platformu üzerinden elde edilen sonuçlar ışığında şu temel yargılara varılmıştır:

1. Entegre Teşhis Kabiliyeti: Geliştirilen sistem, sadece elektriksel verilerdeki anomalileri yakalamakla kalmayıp, bu hataların fiziksel nedenlerini görsel olarak doğrulayabilmektedir. Bu hibrit yaklaşım, bakım personeline sunulan bilginin doğruluğunu ve güvenilirliğini artırmıştır.
2. Verimlilik Odaklı Raporlama: Program çıktılarında görüldüğü üzere, tespit edilen her arıza türü için "Tahmin Edilen Kayıp (Loss %)" hesaplaması yapılmaktadır. Bu özellik, operatörlerin bakım önceliklerini bilimsel verilere dayanarak belirlemesine olanak tanımaktadır.
3. Anomali Tespiti ve Erken Uyarı: CNN-LSTM Autoencoder modelinin ürettiği anomali skorları, sistemin nominal çalışma koşullarından sapmalarını anlık olarak izleyebilmektedir. Bu durum, arızaların henüz kritik seviyeye ulaşmadan tespit edilmesini sağlayarak kestirimci bakım stratejilerinin etkinliğini kanıtlamıştır.
4. Kullanıcı Deneyimi ve Şeffaflık: Tasarlanan KDS arayüzü, karmaşık derin öğrenme algoritmalarının çıktılarını anlaşılır grafiklere ve aksiyon planlarına dönüştürmüştür. XAI prensiplerine uygun bu yapı, yapay zekanın enerji sektöründeki uygulanabilirliğini güçlendirmektedir.

Bu tez çalışması kapsamında geliştirilen çok modlu karar destek sisteminin başarısı, gelecekteki çalışmalar için geniş bir gelişim potansiyeli sunmaktadır. İlk aşamada, Van/Başkale bölgesindeki yerel iklim koşullarında test edilen bu mimarinin, farklı coğrafi bölgelere ve daha büyük ölçekli GES uygulanarak genelleştirme kapasitesinin artırılması önerilmektedir. Özellikle nem oranının yüksek olduğu kıyı bölgeleri veya tozlanma etkisinin baskın olduğu kurak bölgelerden elde edilecek verilerin sisteme dahil edilmesi, modelin çevresel faktörlere karşı dayanıklılığını pekiştirecektir.

Teknolojik açıdan, mevcut multimodal füzyon altyapısına termal görüntüleme (infrared) verilerinin entegre edilmesi, güneş panellerindeki "hot-spot" (sıcak nokta) oluşumlarının ve mikro düzeydeki elektriksel sızıntıların çok daha erken safhalarda saptanmasına olanak

taniyacaktir. Ayrica, gelistirilen nesne tespiti modellerinin insansiz hava araclarina (İHA) monte edilen yüksek çözünürlüklü kameralar üzerinden gerçek zamanlı çalıştırılması, büyük ölçekli sahalarda manuel denetim maliyetlerini minimize ederek kestirimci bakımı tamamen otonom bir yapıya kavuşturabilir.

Algoritmik düzeyde ise, statik modellerin ötesine geçilerek "Takviyeli Öğrenme" (Reinforcement Learning) tabanlı ajanların sisteme dahil edilmesi, bakım stratejilerinin sadece hata tespitiyle sınırlı kalmayıp aynı zamanda maliyet-kazanç analizi yaparak en uygun bakım zamanını otonom olarak belirlemesini sağlayabilir. Son olarak, Karar Destek Sistemi'nin bir adım ötesine geçilerek, üretim kaybı verilerinin doğrudan finansal piyasalar ve enerji yönetim sistemleriyle entegre edildiği, arıza durumunda mali kayıp projeksiyonu sunan dijital ikiz (digital twin) uygulamalarının geliştirilmesi, sektördeki dijital dönüşüm süreçlerine stratejik katkılar sağlayacaktır.

Sonuç olarak, bu çalışma güneş enerjisi santrallerinde dijital ikiz ve akıllı izleme sistemlerine geçiş için kapsamlı bir model sunmaktadır. Gelecek çalışmalarda, bu mimarinin çoklu mikro-şebeke sistemlerine entegrasyonu ve enerji depolama birimlerindeki (batarya) anomalilerin de sisteme dahil edilmesi hedeflenmektedir.

## KAYNAKÇA

- Rathore, A., Kumar, S. ve Singh, R. K. (2024). Deep learning-based fault detection and predictive maintenance architectures for residential photovoltaic power plants. *IEEE Transactions on Sustainable Energy*, 15(2), 845-858. doi: 10.1109/TSTE.2024.3354120
- Alrifaeey, M., Hong, T., & Cho, S. S. (2022). Hybrid deep learning models (CNN-GRU/LSTM) for real-time fault classification and power estimation in grid-connected PV systems. *Energy Conversion and Management*, 258, 115-129.
- Arslan, M. B., & Doğan, C. (2022). Küçük ve orta ölçekli evsel GES projelerinde kısıtlı donanım maliyetleri ve uç cihaz (edge computing) yapay zeka optimizasyonu. *Güneş Enerjisi Teknolojileri Dergisi*, 15(3), 55-67.
- Badr, S., Ahmed, R., & El-Khayat, M. (2021). Classification principles and hierarchical fault detection in residential solar power plants. *Solar Energy Materials and Solar Cells*, 225, 111-123.
- Demirtaş, M., Akın, E., & Öztürk, H. (2023). Güneş enerji santrallerinde yapay zeka tabanlı arıza tespiti ve performans analizi. *Politeknik Dergisi*, 26(3), 845-856. <https://doi.org/10.2339/politeknik.1104523>
- El Martaoui, N., Motahhir, S., & Hammoumi, A. (2025). Comparative evaluation of Isolation Forest and tree-based ensemble methods for anomaly detection in MPPT units. *IEEE Access*, 13, 4512-4526.
- Electronics Editorial. (2025). Advanced algorithmic approaches and real-time monitoring in PV systems. *Electronics*, 14(x), 13. (Peer Review Stage).
- Gedik, H. (2016). *Yüksek rakımlı ve uç sıcaklık farkı olan bölgelerde fotovoltaiik modül sıcaklığının verimlilik üzerindeki termal etkilerinin deneysel analizi: Van örneği*. (Yüksek Lisans Tezi), Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri Enstitüsü, Erzincan.
- Park, J., Kim, M. ve Chang, H. (2024). Computer vision and transformer-based object detection frameworks for physical defect mapping in solar panels. *IEEE Access*, 12, 14210-14223. doi: 10.1109/ACCESS.2024.3368411

- Jangra, A., Lakhina, U., Badruddin, N., Elamvazuthi, I., Huy, T., & Guerrero, J. (2023). An enhanced multi-objective optimizer for stochastic generation optimization in islanded renewable energy microgrids. *Mathematics*, 11(9), 2079. <https://doi.org/10.3390/math11092079>
- Köksal, A. İ. (2024). *Derin Öğrenme İle Güneş Enerji Santrallerinde Üretim Tahmini*. (Yüksek Lisans Tezi), Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Konya.
- Ledmaoui, A., & Oumiguil, L. (2024). Performance optimization and predictive modeling of grid-connected photovoltaic systems using advanced machine learning. *Energy Reports*, 11, 4125-4138. <https://doi.org/10.1016/j.egy.2024.03.045>
- Lund, R. S. (2024). Explainable AI (XAI) and SHAP framework implementation in black-box deep learning architectures for smart grid operators. *Artificial Intelligence in Engineering*, 48, 102-115.
- Mansouri, M., Al-Khazraji, A., & Nounou, H. (2021). Advanced statistical residual analysis for fault diagnosis in photovoltaic systems. *IEEE Transactions on Sustainable Energy*, 12(3), 1645-1654.
- Nguyen, H. N., Tran, Q. T., Ngo, C. T., Nguyen, D. D., & Tran, V. Q. (2025). Solar energy prediction through machine learning models: A comparative analysis of regressor algorithms. *PLOS ONE*, 20(1), e0315955. <https://doi.org/10.1371/journal.pone.0315955>
- Nguyen, T. K., & Hoang, V. P. (2025). Transformer-based object detection and RF-DETR architecture for physical surface defect mapping in silicon solar panels. *Pattern Recognition Letters*, 172, 88-97.
- Oumiguil, A., & Nejmi, A. (2026). Temporal dependencies and GRU-based architectures for chronological sensor data analysis in solar plants. *International Journal of Electrical Power & Energy Systems*, 175, 109-122.
- Oumiguil, L., & Nejmi, A. (2026). Short-term PV plant power forecasting model using CNN-GRU with XGBoost algorithm. *Scientific African*, 31, e03184. <https://doi.org/10.1016/j.sciaf.2026.e03184>

- Özer, D., & Aksoy, B. (2024). Yapay zeka uygulaması ile güneş paneli sistemi enerji üretimi tahmini. *Yalvaç Akademi Dergisi*, 9(2), 138–151. <https://doi.org/10.57120/yalvac.1543369>
- Özer, T., & Aksoy, H. (2024). Evsel tip akıllı şehir uygulamalarında yapay zekâ entegrasyonu ve panel verimliliği optimizasyonu. *Mühendislik Bilimleri ve Tasarım Dergisi*, 12(4), 890-903.
- Öztürk, A., & Kara, E. (2024). Güneş enerji santrallerinde makine öğrenmesi tabanlı dinamik eşik değeri yönetimi. *Akıllı Sistemler ve İleri Mühendislik Uygulamaları Dergisi*, 6(1), 78-92.
- Paul, T., Goldstein, J., & Martinez, L. (2025). Autonomous detection of DC arc faults in photovoltaic arrays using machine learning layers. *IEEE Industrial Electronics Magazine*, 19(1), 34-47.
- Polatcan, E. (2024). *Güneş enerji santrallerinde makine öğrenmesi algoritmaları ve coğrafi bilgi verileri kullanılarak enerji üretiminin tahminlenmesi*. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul.
- Quaschnig, V., & Hanitsch, R. (2014). Numerical simulation of current-voltage characteristics of photovoltaic systems with shaded solar cells. *Solar Energy*, 56(6), 513-520.
- Quiles-Cucarella, F., Blanes, J. M., & Garrigos, A. (2025). Hyper-parameter optimization in low signal-to-noise ratio data for predictive maintenance of PV systems. *Applied Energy*, 360, 122-135.
- Qureshi, M. S., Umar, S., & Nawaz, M. U. (2024). Machine learning for predictive maintenance in solar farms. *International Journal of Advanced Engineering Technologies and Innovations*, 1(3), 27–49.
- Qureshi, Z., Iqbal, M. T., & Ahmed, K. (2024). Multimodal fusion and financial metrics for predictive maintenance urgency in domestic solar farms. *IEEE Journal of Photovoltaics*, 14(2), 289-301.
- Wang, J., & Sun, X. (2021). A hybrid deep learning architecture for short-term photovoltaic power forecasting based on spatial-temporal correlation. *Energy*, 232, 121015. <https://doi.org/10.1016/j.energy.2021.121015>

Woyte, S., Belmans, R., & Nijs, J. (2007). Fluctuations in photovoltaic power generation: From the time series to the power spectrum. *Solar Energy*, 81(12), 1480-1490.

Yılmaz, Y., Aksoy, M., & Demir, S. (2023). Ani iklim geişlerinde fotovoltaik sistemlerin kararlı arıza tespiti ve performans analizi. *Yenilenebilir Enerji ve Yapay Zeka Dergisi*, 11(2), 142-155.

Zwirtes, L., Teodorescu, R. C. G., & Shaker, M. V. (2025). Unsupervised pre-filtering methods and statistical validation in large-scale solar power data monitoring. *Renewable and Sustainable Energy Reviews*, 204, 114-128.