



YEKARUM

JOURNAL OF YEKARUM

e - DERGİ



e-ISSN: 1309-9388



<https://dergipark.org.tr/tr/pub/yekarum>

Cilt:9 Sayı:2

2024

Volume:9 Number:2

DergiPark
AKADEMİK



YEKARUM e-DERGİ

Cilt: 9 Sayı: 2 Yıl: 2024

Journal of YEKARUM

Volume: 9 Number: 2 Year: 2024

E - ISSN:1309-9388

Yazıların tüm bilimsel sorumluluğu yazara veya yazarlara aittir. Dergide yayınlanan yazılardan editör, editör yardımcısı ve yayıncı sorumlu tutulamaz..Bu dergi, aşağıda listelenen veri tabanları tarafından taranmaktadır. All the scientific responsibilities of the manuscripts belong to the authors (s). The editor, assistant editor and publisher accept no responsibility for the articles published in the journal.

<https://dergipark.org.tr/tr/pub/vekarum>

İndeksler

<https://scholar.google.com/>, <https://www.base-search.net/>, <https://atif.sobiad.com/>





Süleyman Demirel Üniversitesi
YEKARUM e-DERGİ
(Journal of YEKARUM)



Cilt 9, Sayı 1, 2024
E - ISSN: 1309-9388

Bas Editör / Editor in Chief

Prof. Dr. İbrahim ÜÇGÜL

Editörler / Editors

Dr. Öğr. Üyesi Mehmet Erhan ŞAHİN

Öğr. Gör. Dr. Ahmet ELBİR

Doç. Dr. Bekir AKSOY

Prof. Dr. Ramazan ŞENOL

Yayın Danışma Kurulu

Prof. Dr. Serhii YEVSEİEV

Kharkiv Politeknik Enstitüsü, Ukrayna

Prof. Dr. Salah LARBİ

Politeknik Üniversitesi, Cezayir

Dr. N. Nnamdi Ekere

Wolverhampton Üniversitesi, İngiltere

Dr. Khaoula IKHLEF

Politeknik Üniversitesi, Cezayir

Prof. Dr. Reşat SELBAŞ

Isparta Uygulamalı Bilimler Üniversitesi, Isparta

Doç. Dr. Onur SEVLİ

Burdur Mehmet Akif Ersoy Üniversitesi, Burdur

Doç. Dr. Utku KÖSE

Süleyman Demirel Üniversitesi, Isparta

Dr. Öğr. Üyesi Özdemir DENİZ

Isparta Uygulamalı Bilimler Üniversitesi, Isparta

İÇİNDEKİLER / CONTENTS

Arastırma Makalesi / Research Articles

Makine Öğrenmesi İle 3 Boyutlu Yazıcı Plastik Filamentlerinin Ergime Noktası Ve Esneklik Özelliklerine Dayalı Çekme Dayanımının Tahmini Muzaffer EYLENCE, Bekir AKSOY , Koray ÖZSOY	91-107
Makine Öğrenimi Algoritmaları Kullanılarak Bina Enerji Verimliliğinin Doğrusal Regresyon Analizi Hakan Yüksel	108-127
Machine Learning-Based Energy Forecasting for PV Power Plants Muhammed TAMAY, Gül Fatma TURKER	128-146
Güneş Işınım Verilerine Entropi Yaklaşımıyla Fotovoltaik Sistem Çıkış Gücü Değişiminin İncelenmesi Ahmet KABUL	147-163

Derleme Makalesi / Compilation Articles

Yeni Nesil Savaş Uçaklarında Silah Sistemi Tasarım Yaklaşım Yöntemleri Gürel BUR, Mustafa İZGÜDEN	164-189
---	---------



Süleyman Demirel Üniversitesi

YEKARUM e-DERGI

(Journal of YEKARUM)



Cilt 9 , Sayı 2 , 91-107 , 2024
E - ISSN:1309-9388

Makine Öğrenmesi ile 3 Boyutlu Yazıcı Plastik Filamentlerinin Ergime Noktası ve Esneklik Özelliklerine Dayalı Çekme Dayanımının Tahmini

Muzaffer EYLENCE^{1*} , Bekir AKSOY² , Koray ÖZSOY³

^{1*} Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Isparta, Türkiye, (ORCID: 0000-0001-7299-8525), meylence@yandex.com

² Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Isparta, Türkiye (ORCID: 0000-0001-6016-4590), bekiraksoy@isparta.edu.tr

² Isparta Uygulamalı Bilimler Üniversitesi, Isparta OSB MYO, Makine ve Metal Teknolojileri Bölümü, Isparta, Türkiye (ORCID: 0000-0001-8663-4466), korayozsoy@isparta.edu.tr

(İlk Geliş Tarihi 22/10/2024 ve Kabul Tarihi 18/12/2024)

ÖZET:

Eklemeli imalat, malzemeyi katmanlar halinde biriktirerek nesnelere üreten ve genellikle 3D baskı olarak bilinen yenilikçi bir teknolojidir. Bu yöntem, geleneksel imalatın aksine malzemeyi çıkarmak yerine katman ekleyerek üretim sağlarken, Ergiyik Biriktirme Modelleme (EBM) gibi popüler formlarının yaygın kullanımına yol açmıştır. Bu çalışmada, EBM tabanlı 3D baskı uygulamalarında farklı markalara ait termoplastik filamentlerin dayanım değerlerinin belirlenmesine yönelik makine öğrenimi tekniklerinin geliştirilmesi hedeflenmiştir. Bu amaç doğrultusunda, yaygın termoplastik filamentlerin dayanım değerlerinin tahmin edilmesi için Pruned Decision Trees, Destek Vektör Makineleri ve Naive Bayes gibi makine öğrenimi algoritmalarından yararlanılmıştır. Bu çalışmada kullanılan veri seti; plastik türü, erime noktası, esneklik, dayanıklılık, kullanım alanları ve marka gibi bilgileri içeren 800 veri örneğinden oluşmaktadır. Makine öğrenme algoritmalarının performansı, modelin dayanım değerini tahmin yeteneği hakkında bilgi sağlayan doğruluk ve F1-skoru gibi standart değerlendirme metrikleri kullanılarak değerlendirilmiştir. Dikkate değer bir şekilde, model tüm metriklerde yüksek bir performans sergileyerek, 3D baskı için kullanılan termoplastik filamentlerin dayanım değerlerinin tahmininde Pruned Decision Trees algoritması ile %96'lık bir başarı oranı elde etmiştir. Bu sonuçlar, makine öğreniminin eklemeli imalat yöntemlerinden EBM süreçlerindeki filamentlerin dayanım değerlerinin otomatik tespiti konusunda etkinliğini ortaya koymaktadır.

Anahtar Kelimeler: Eklemeli imalat, EBM, Filament, Makine Öğrenme

Prediction of Tensile Strength Based on Melting Point and Flexibility Properties of 3D Printer Plastic Filaments Using Machine Learning

ABSTRACT

Additive manufacturing is an innovative technology that produces objects by depositing material in layers, commonly known as 3D printing. This method allows for production by adding layers instead of removing material, in contrast to traditional manufacturing, and has led to the widespread use of popular forms such as Fused Deposition Modeling (FDM). In this study, the aim was to develop machine learning techniques for determining the strength values of thermoplastic filaments from different brands in FDM-based 3D printing applications. To achieve this, machine learning algorithms such as Pruned Decision Trees, Support Vector Machines, and Naive Bayes were employed to estimate the strength values of common thermoplastic filaments. The dataset used in this study consists of 800 samples containing information such as plastic type, melting point, flexibility, durability, areas of use, and brand. The performance of the machine learning algorithms was evaluated using standard metrics such as accuracy and F1-score, which provide insights into the model's ability to predict strength values. Notably, the model demonstrated strong performance across all metrics, achieving a 96% success rate with the Pruned Decision Trees algorithm in predicting the strength values of thermoplastic filaments used for 3D printing. These results underscore the effectiveness of machine learning in automatically determining the strength values of filaments in EBM processes, one of the additive manufacturing methods.

Keywords: *Additive Manufacturing, FDM, Filament, Machine Learning*


1. GİRİŞ

Eklemeli imalat (Eİ) teknolojisi, basit ve çeşitlendirilmiş teknolojisi nedeniyle son zamanlarda büyük önem kazanmıştır. Eİ kullanımı, geleneksel imalat yöntemlerine göre eğitim, prototip oluşturma, inşaat, tıp ve havacılık endüstrisini kapsayan birçok bilgi alanına yayılmıştır [1]. Eklemeli imalat süreci, malzemelerin belirli koşullar altında ve bilgisayar kontrollü bir ortamda biriktirildiği, birleştirildiği veya katılaştırıldığı sistematik bir yöntemle gerçekleştirilir. Eklemeli imalat yöntemleri, üç boyutlu nesnelerin katmanlar halinde inşa edilerek üretildiği bir imalat sürecidir [2].

ISO/ASTM 52900:2021 [3], eklemeli imalat teknolojisinde kullanılan terimleri belirler ve tanımlar vardır. Kullanılan malzeme türü ve basılı parçaların nihai uygulaması dikkate alınarak genel olarak malzemelerin ekstrüzyonu, vat polimerizasyonu, toz yatak füzyonu, malzeme jeti, bağlayıcı Püskürtme, Yönlendirilmiş Enerji Biriktirme (Metal Alaşımları), Haddeme levhası gibi eklemeli imalat teknolojilerini yedi türe ayrılır. Malzeme Ekstrüzyonu, tel formundaki filamentin silindirler vasıtasıyla nozullara iletiildiği bir başka eklemeli imalat teknolojisidir. Bu yöntemde, yarı erimiş malzeme bir nozul aracılığıyla imalat

platformuna ekstrüde edilmektedir. Malzeme ekstrüzyonu, kalıp ve model üretimi, takım imalatı ve son kullanım parçalarının üretimi gibi çeşitli uygulamalarda kullanılmaktadır [4,5]. Malzeme ekstrüzyonu ise 2,85 mm veya 1,75 mm çapında filament boyutlarını kullanır. Bu teknik, polimerler, kompozitler ve biyomalzemeler gibi geniş bir malzeme yelpazesinin işlenmesine olanak tanır [6]. Malzeme ekstrüzyonu tabanlı ergiyik biriktirme modelleme (EBM), kullanım kolaylığı ve diğer teknolojilere göre daha az masraflı olması nedeniyle yaygın olarak kullanılan bir tekniktir [7].

Ergiyik biriktirme modelleme, hızlı üretim süreci, maliyet etkinliği, kolay erişilebilirliği, geniş malzeme uyumluluğu ve karmaşık bileşenler üretme yeteneği ile popüler bir eklemeli imalat teknolojisidir [8]. Şekil 1’de gösterildiği gibi EBM sürecinde, termoplastik filament kullanılarak CAD tasarımına uygun şekilde imalat tablasının üzerine üç boyutlu katmanlar oluşturulur. İlk katman basıldıktan sonra, imalat tablası platformu aşağı indirilir ve bir sonraki katman, önceki katmanın üzerine basılarak süreç, parça tamamlanana kadar tekrarlanmaktadır.



Şekil 1. EBM parça işleme sürecinin gösterimi [9].

EBM baskısında günümüzde çeşitli malzemeler kullanılmaktadır. Akrilonitril bütadien stiren (ABS) ve polilaktik asit (PLA) en yaygın malzemelerdir. ABS, çok yönlü yapısı ve mekanik özellikleri nedeniyle en sık tercih edilen 3D baskı termoplastiğidir. Filament, toz

veya sıvı halde kullanılabilmesi bu çok yönlülüğünü artırmaktadır [10]. PLA ise, mısır nişastasası gibi yenilenebilir kaynaklardan üretilen biyolojik olarak parçalanabilir bir plastiktir. Büzülme eğilimi olmasına rağmen, en popüler 3D baskı filamentlerinden biridir [11]. FDM tekniklerinde, ABS gibi mühendislik polimerleri ve PLA gibi biyolojik olarak parçalanabilir plastikler yaygın kullanılır. Bunun yanı sıra, geleneksel ve geri dönüştürülebilir polimerlerle de 3D baskı yapılabilmektedir. Örneğin, polietilen tereftalat (PET), etilen glikol (PETG) ile sentezlenerek sünekliği artırılabilir [12].

Polikarbonat (PC), şeffaflığı, üstün mekanik ve termal direnci nedeniyle mühendislik uygulamalarında tercih edilen bir malzemedir ve 3B baskıda boyut kararlılığı ile mekanik özellikleri nedeniyle kullanılmaya başlanmıştır. PC, ABS ve PET gibi malzemelerle birleştirilerek basılı parçaların performansını iyileştirmek amacıyla diğer termoplastik polimerler veya inorganik parçacıklarla bir araya getirilebilir. Araştırmaların çoğu esas olarak PC'yi ABS ve PET ile birleştirmeye dayanmaktadır [13, 14]. Naylon, yüksek dayanıklılık, esneklik ve mekanik özellikleri nedeniyle sentetik poliamid ailesinden bir mühendislik plastiğidir. İyi kimyasal ve ısı direnci sunmasıyla, FDM gibi 3D baskı teknolojilerinde işlevsel parçalar ve prototipler için ideal bir malzemedir. Poliamidler ayrıca yapılarındaki karbon sayısına göre bir alt sınıflandırma sunar ve bu nedenle Poliamid 6, Poliamid 66, Poliamid 11 ve Poliamid 12 olarak bilinen bunlar arasında farklı özellikler bulunur. Bu şekilde, naylonun 3D baskıda kullanımı kullanılan poliamid türüne bağlı olacaktır. Naylon 618 gibi bazı poliamidler, kristalinitedeki farklılıklar ve FDM işleminin benzersizliği nedeniyle daha iyi aşınma performansı sağlar [15].

Yapay Zeka (YZ), insan benzeri zeka sergileyen sistemlerin geliştirilmesi üzerine odaklanan bir bilim dalıdır. Bu teknoloji, karmaşık görevleri yerine getirmek için veri analizini, öğrenme süreçlerini ve problem çözmeyi kullanır. YZ'nin temel amacı, insan müdahalesine ihtiyaç duymadan, çevresel değişimlere uyum sağlayabilen ve kararlar alabilen sistemler yaratmaktır [16]. YZ, insan zekasına özgü işlevleri simüle etmek için bilgisayar bilimi, matematik, psikoloji ve nörobilim gibi disiplinlerin bir araya geldiği çok yönlü bir alandır. Günümüzde YZ; doğal dil işleme, görsel algılama, ses tanıma ve öneri sistemleri gibi birçok uygulama alanına sahiptir [17]. YZ, genellikle üç ana kategoriye ayrılır: Dar (Zayıf) Yapay Zeka, Genel (Güçlü) Yapay Zeka ve Süper Yapay Zeka. Dar yapay zeka, spesifik görevlerde performans gösteren, günümüzde en yaygın olan yz türüdür. Örneğin, bir dil

modeli veya bir öneri sistemi yalnızca belirli bir amaç için optimize edilmiştir [18]. Genel yapay zeka, insanlarla benzer bilişsel yeteneklere sahip, farklı görevler arasında geçiş yapabilen bir yapay zeka türüdür. Bu seviyedeki yz halen geliştirilme aşamasındadır. Süper yapay zeka, insan zekasının çok ötesinde bilişsel yeteneklere sahip olacağı varsayılan yz seviyesidir [19].

Makine öğrenmesi (MO), yz'nin bir alt dalı olarak kabul edilir ve makinelerin deneyim yoluyla öğrenmesini sağlar. MO algoritmaları, verilerdeki desenleri ve ilişkileri öğrenir, ardından bu öğrenmeleri kullanarak yeni verilere dayalı tahminlerde bulunur [20]. Makine öğrenmesi; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç temel kategoriye ayrılır: Denetimli öğrenme, giriş verileri ile bunlara karşılık gelen sonuçların (etiketlerin) kullanıldığı bir öğrenme yöntemidir. Algoritmalar, etiketli veriler aracılığıyla belirli bir görevi yerine getirmeyi öğrenir [21]. Denetimsiz öğrenme, etiketli verilerin olmadığı durumlarda kullanılır. Algoritmalar, verilerdeki gizli desenleri ve yapıları keşfetmeyi amaçlar [22]. Pekiştirmeli öğrenme, bir ajanın, çevresiyle etkileşime geçerek ödülleri veya cezaları yoluyla öğrenme sürecidir [23]. Makine öğrenmesi, büyük veri setlerinin analiz edilmesi, tahminler yapılması ve karmaşık karar verme süreçlerinin otomatikleştirilmesinde kritik bir rol oynar. Günümüzde endüstriden tıp alanına kadar geniş bir yelpazede uygulanmaktadır.

Son yıllarda 3 boyutlu yazıcı teknolojisi ile üretilen malzemelerin çekme dayanımını tahmin etme üzerine birçok çalışma gerçekleştirilmiştir. Bu çalışmaların temel amacı, mekanik özellikleri anlamak ve bu süreçte zaman ve maliyet tasarrufu sağlamaktır. Makine öğrenmesi algoritmaları, büyük veri kümelerini analiz etme ve tahminler yapma kapasitesi sayesinde bu alanda yaygın olarak kullanılmaktadır. Çınar ve arkadaşları [24], polimer bazlı 3 boyutlu yazıcılarla üretilen malzemelerin çekme dayanımını tahmin etmek amacıyla makine öğrenmesi tekniklerini kullanmışlardır. Çalışmada denetimli öğrenme algoritmaları kullanılarak, deneysel verilerden öğrenen modeller geliştirilmiş ve bu modellerin yüksek doğruluk oranlarıyla tahmin yapabildikleri gösterilmiştir. Çekme dayanımını etkileyen parametreler arasında baskı sıcaklığı, malzeme türü ve katman kalınlığı gibi faktörlerin yer aldığı belirtilmiştir. Bu çalışma, makine öğrenmesinin üretim parametreleri ile mekanik performans arasında ilişki kurma kapasitesini gözler önüne sermektedir [24].

Benzer bir şekilde, Yılmaz ve Demir [25], yapay sinir ağları ve karar ağaçları gibi makine öğrenmesi algoritmalarını kullanarak, 3 boyutlu yazıcılarla üretilen parçaların çekme dayanımını tahmin etmeyi amaçlamışlardır. Bu çalışmada, farklı yazıcı ayarları ve malzeme özellikleri kullanılarak oluşturulan veriler, modellerin eğitilmesinde kullanılmıştır. Yapay sinir ağları ile yapılan tahminlerin, geleneksel yöntemlere göre daha doğru sonuçlar verdiği ve üretim sürecinde zaman kazandırdığı belirtilmiştir. Karar ağaçlarının ise, parametreler arasındaki karmaşık ilişkileri daha anlaşılır bir şekilde görselleştirebildiği vurgulanmıştır [25].

Huang ve arkadaşları [26] ise, 3 boyutlu yazıcılarla üretilen metal parçaların çekme dayanımını tahmin etmek için çeşitli makine öğrenmesi algoritmalarını karşılaştırmışlardır. Çalışmada, destek vektör makineleri (SVM) ve rastgele ormanlar (RF) gibi algoritmaların performansları incelenmiştir. Metal bazlı üretimlerde çekme dayanımını tahmin etmede rastgele ormanlar algoritmasının en başarılı yöntem olduğu belirtilmiş, bu algoritmanın karmaşık verilerle başa çıkma yeteneği öne çıkarılmıştır. Ayrıca bu çalışma, 3 boyutlu yazıcı ile üretimde farklı malzemelerin mekanik özelliklerinin tahmin edilmesine yönelik önemli bir katkı sağlamıştır [26].

Yapılan çalışmalar, 3 boyutlu yazıcı teknolojisinin çekme dayanımı gibi kritik mekanik özelliklerin makine öğrenmesi ile tahmin edilebileceğini ve bu sayede üretim süreçlerinin optimize edilebileceğini göstermektedir. Makine öğrenmesi algoritmaları, geleneksel deneysel yöntemlere kıyasla daha hızlı, daha maliyet etkin ve daha esnek tahminler sunarak üretimde büyük avantaj sağlamaktadır.

Çalışmada, 3B baskı teknolojilerinden EBM yöntemine makine öğrenme yaklaşımı uygulanmıştır. Veri seti, plastik türü, erime noktası, esneklik, dayanıklılık, kullanım alanları ve marka gibi bilgileri içeren 800 veri örneğinden oluşmaktadır. Dayanıklılık tahmini, makine öğrenmesi algoritmaları kullanılarak gerçekleştirilmiştir. Veri seti, Karar Ağaçları, Destek Vektör Makineleri (SVM) ve Naive Bayes makine öğrenme algoritmaları kullanılmıştır. Makine öğrenme algoritma mimarisıyla eğitildikten sonra performansı doğruluk ve F1 puanı metrikleri kullanılarak değerlendirilmiştir. Son aşamada, sonuçlar bir karmaşıklık matrisleri ile analiz edilmiştir.

2. MATERYAL ve METOT

2.1. Materyal

2.1.1. 3B Yazıcı

Tüm parçalar 3D yazıcı kullanılarak basılmıştır. Ergime noktası, esneklik giriş parametreleri çekme mukavemeti gibi çeşitli özellikler hakkında veri içerir [27].

2.1.2. Makine Öğrenmesi Algoritmalar

2.1.3.1. Pruned Decision Tree

Pruned Decision Trees, makine öğrenmesinde sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan karar ağaçlarının daha genellenebilir ve etkili hale getirilmesi için uygulanan bir tekniktir. Karar ağaçları, veriyi farklı dallara ayırarak tahminlerde bulunan sezgisel bir modeldir. Ancak, karar ağaçlarının en büyük sorunlarından biri aşırı öğrenme (overfitting) problemidir. Aşırı öğrenme, modelin eğitim verisine aşırı derecede uyum sağlaması sonucu yeni verilerle yapılan testlerde düşük performans göstermesi durumudur. Bu sorunu önlemek için budama (pruning) işlemi uygulanır [28]. Budama, ağaçtaki gereksiz dalları kaldırarak ağacın karmaşıklığını azaltmayı amaçlar. Budamanın iki temel yöntemi vardır: ön budama (pre-pruning) ve sonradan budama (post-pruning). Ön budama, ağacın büyüme sürecinde aşırı dallanmayı engellerken, sonradan budama, tam bir karar ağacı oluşturulduktan sonra gereksiz dalların kesilmesini içerir [29]. Budamanın temel amacı, modelin genellenebilirliğini artırmak ve aşırı öğrenme riskini en aza indirmektir. Bununla birlikte, yanlış budama işlemi, modelin öğrenme kapasitesini sınırlayarak performans kayıplarına yol açabilir [30].

2.1.3.2. Destek Vektör Makineleri

Destek Vektör Makineleri (Support Vector Machines - SVM), özellikle sınıflandırma problemlerinde yüksek doğruluk oranları sunan bir diğer makine öğrenmesi yöntemidir. SVM, sınıflandırma işlemlerinde veri noktalarını ayıran en iyi hiperdüzlemi bulmayı hedefler ve bu hiperdüzlem, iki sınıf arasındaki marjı maksimize eder [31]. Bu yöntem, özellikle yüksek boyutlu veri kümeleriyle çalışırken etkili sonuçlar verir. SVM'nin başarısındaki temel faktörlerden biri çekirdek (kernel) fonksiyonlarıdır. Çekirdek fonksiyonları, doğrusal olmayan veri kümelerinde SVM'nin doğrusal sınıflandırıcılar kullanarak çözüm üretmesini sağlar [32]. Bu fonksiyonlar arasında lineer, polinomsal ve radyal bazlı fonksiyonlar (RBF) sıklıkla

kullanılmaktadır. SVM’in en büyük avantajı, özellikle yüksek boyutlu ve karmaşık veri kümelerinde iyi genellenebilirlik sağlamasıdır [33]. Ancak, büyük veri kümelerinde eğitim süresi uzayabilir ve hiperparametre seçimi modelin performansını büyük ölçüde etkileyebilir [34].

2.1.3.3. Naive Bayes

Naive Bayes sınıflandırıcıları, olasılık temelli ve basit yapısına rağmen birçok sınıflandırma probleminde etkili sonuçlar veren bir makine öğrenmesi yöntemidir. Model, her bir özelliğin diğerlerinden bağımsız olduğunu varsayar ve bu varsayım doğrultusunda Bayes teoremi kullanılarak sınıflandırma işlemi gerçekleştirilir. Naive Bayes, bir sınıfın olasılığını gözlemlenen verilere dayalı olarak hesaplar ve denklem 1’deki gibi hesaplanmaktadır [35].

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)} \quad (1)$$

Modelin "naive" olarak adlandırılmasının nedeni, özellikler arasındaki bağımsızlık varsayımıdır. Gerçek dünyada bu varsayım genellikle geçerli olmasa da, Naive Bayes sınıflandırıcıları birçok veri kümesinde başarılı sonuçlar vermektedir [36]. Algoritmanın en önemli avantajlarından biri, hızlı ve hesaplama açısından verimli olmasıdır. Büyük veri kümelerinde bile hızlı bir şekilde çalışabilir ve genellikle daha karmaşık modellerle karşılaştırıldığında rekabetçi sonuçlar sunar [37]. Bununla birlikte, özellikler arasındaki bağımsızlık varsayımı geçerli olmadığında, modelin performansı olumsuz etkilenebilir. Ancak bu durum, her veri kümesinde performansı ciddi şekilde düşürmeyebilir.

2.1.3.4. Performans değerlendirme metriği

Makine öğrenmesi modellerinin performansını değerlendirmek için doğruluk ve F1-skoru gibi metrikler yaygın olarak kullanılmaktadır. Bu metrikler, modelin tahmin kapasitesini ve sınıflandırma doğruluğunu ölçmede kritik rol oynar. Doğruluk, modelin doğru tahminlerinin toplam tahminler içindeki oranını ifade eder. Matematiksel olarak denklem 2’deki gibi hesaplanır [38].

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Toplam Gözlem}} \quad (2)$$

Denklem 2’deki metrik, özellikle sınıflar arasında dengeli bir dağılım olduğunda modelin genel performansını ölçmede etkili bir göstergedir. Ancak, sınıf dengesizliği olan durumlarda yanıltıcı sonuçlar verebilir, çünkü azınlık sınıflarına ilişkin yanlış tahminleri göz ardı edebilir.

F1-skoru, kesinlik (precision) ve duyarlılık (recall) arasında bir denge sağlayan bir metriktir. Özellikle sınıf dengesizliği olan veri setlerinde daha anlamlı sonuçlar sunar [38]. F1-skoru denklem 3’deki gibi hesaplanmaktadır.

$$F1 - Skor = 2 \times \frac{Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (3)$$

F1-skoru, duyarlılık ve kesinlik arasındaki dengenin sağlanması gereken durumlarda öne çıkan bir metriktir. Modelin hem azınlık sınıflarını doğru bir şekilde tahmin etmesi hem de yanlış pozitif tahmin oranını düşük tutması gereken uygulamalarda tercih edilir. Kesinlik, Modelin doğru pozitif tahminlerinin toplam pozitif tahminlere oranıdır. Yanlış alarmların önlenmesinde önemli bir ölçüttür. Duyarlılık, Modelin doğru pozitif tahminlerinin toplam gerçek pozitiflere oranıdır. Bu metrik, modelin bir sınıfı ne kadar iyi yakaladığını gösterir.

2.2. Metot

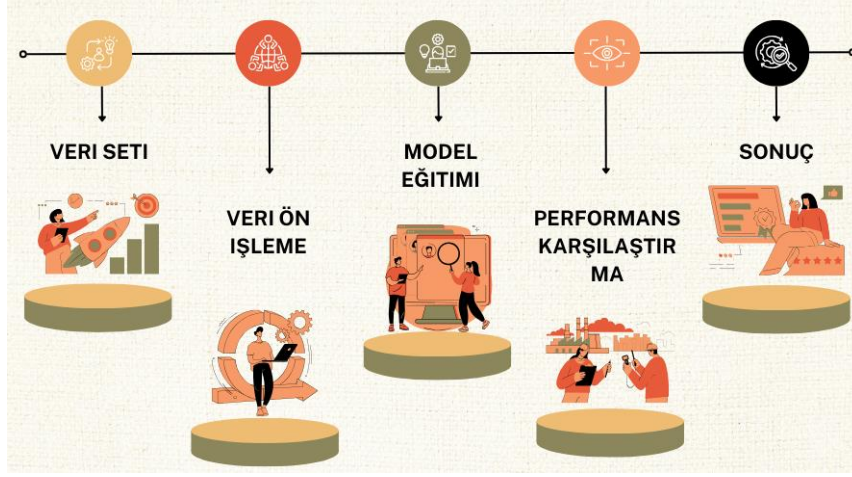
2.2.1. Veri Seti

Bu çalışmada kullanılan veri seti, 3D yazıcı plastiklerinin fiziksel ve performans özelliklerini içermektedir. Veri seti, plastik türü, erime noktası, esneklik, dayanıklılık, kullanım alanları ve marka gibi bilgileri içeren 800 veri örneğinden oluşmaktadır. Dayanıklılık tahmini, makine öğrenmesi algoritmaları kullanılarak gerçekleştirilmiştir. Veri setindeki sütunlar arasında plastik türü (ABS, PLA vb.), erime noktası (derece Celsius cinsinden), esneklik (düşük, orta, yüksek), dayanıklılık (düşük, orta, yüksek) ve kullanım alanları gibi özellikler yer alır. Dayanıklılık tahmini yapılacak hedef değişkendir. Başlangıçta veri seti daha az veri içeriyordu; bu nedenle veri artırma işlemi gerçekleştirilmiştir. Veri artırma için bootstrap sampling (rastgele örnekleme) kullanılarak veri seti genişletilmiş ve veri sayısı 800’e çıkarılmıştır.

Bu çalışmada üç farklı makine öğrenmesi algoritması kullanılmıştır: Karar Ağaçları (budanmış), Destek Vektör Makineleri (SVM) ve Naive Bayes. Veri artırma işlemi, model

performansını artırmak ve genelleme kapasitesini iyileştirmek amacıyla uygulanmıştır. Çalışma, plastiklerin dayanıklılığını tahmin etmek için veri setindeki özelliklerden faydalanarak çeşitli makine öğrenmesi modelleri ile gerçekleştirilmiştir.

2.2.2. İş akış şeması



Şekil 2. İş akış diyagramı

3. ARAŞTIRMA BULGULARI

Yapılan çalışmada model eğitimlerinden sonra, kullanılan üç farklı modellerin performans ölçümleri doğruluk ve F1-skoru ile değerlendirilmiştir. Aşağıda yer alan Tablo 1'de bu modellerin eğitim süreci sonucunda elde edilen doğruluk değerleri ve F1-skorları sunulmaktadır. Tablo sonuçları değerlendirildikten sonra, modellerin detaylı analizine karmaşıklık matrisleri üzerinden yer verilecektir.

Tablo 1. Performans değerlendirme metrikleri

Model	F1-skor	Doğruluk
Pruned Decision Tree	0.9562	0.95625
SVM	0.7248	0.73125
Naive Bayes	0.6725	0.66875

Tablo 1 incelendiğinde Pruned Decision Tree modeli, hem doğruluk hem de F1-skoru açısından açık ara en iyi performansı sergilemektedir. %95.625'lik doğruluk oranı, modelin veriyi yüksek bir doğrulukla sınıflandırdığını göstermektedir. Ayrıca 0.9562 F1-skoru,


modelin hem pozitif hem de negatif sınıflardaki performansının dengeli olduğunu ve sınıflandırma hatalarını iyi yönettiğini işaret etmektedir. Bu yüksek performans, ağacın budanmış olması sayesinde aşırı uyumdan (overfitting) kaçınıldığını ve modelin genelleme yeteneğinin başarılı bir şekilde korunduğunu göstermektedir. Pruned Decision Tree modelinin, veri setindeki farklı sınıfları doğru bir şekilde ayırt edebildiği ve bu nedenle sınıflandırma problemlerinde genellikle tercih edilebilir bir seçenek olduğunu söyleyebiliriz.

SVM modeli, Pruned Decision Tree modeline göre daha düşük bir performans sergilemektedir. %73.125'lik doğruluk oranı, modelin hatalı sınıflandırmalar yaptığını ve veriyi tam olarak ayırt edemediğini göstermektedir. Ayrıca, 0.7248 F1-skoru, özellikle sınıf dengesizliklerinin olduğu durumlarda modelin zorlandığını işaret etmektedir. SVM modelinin, daha yüksek doğruluk ve F1-skoru elde edebilmesi için veri setindeki sınıflar arasında daha net ayrımlar yapılabilmesi gerekebilir. Özellikle sınıflar arasında çok fazla örtüşme veya veri dağılımında dengesizlik olduğunda, SVM'nin performansı bu sonuçlara benzer şekilde düşebilir. Bu model, doğruluk ve F1-skorunun orta seviyede olması nedeniyle, sınıflandırma hatalarının daha belirgin olduğu bir performans sergilemiştir.

Naive Bayes modeli ise en düşük performansı göstermiştir. %66.875 doğruluk oranı, modelin veri setini sınıflandırma konusunda yetersiz kaldığını ve birçok sınıflandırma hatası yaptığını göstermektedir. 0.6725 F1-skoru ise modelin özellikle sınıf dengesizliği karşısında zorlandığını ortaya koymaktadır. Naive Bayes, genellikle basit ve hızlı çalışan bir model olmasına rağmen, verinin sınıfları arasındaki ilişkileri yeterince karmaşık bir şekilde ele alamamış olabilir. Özellikle sınıflar arasındaki bağımsızlık varsayımının geçerli olmadığı durumlarda, Naive Bayes performans düşüklüğü yaşar. Bu sonuçlar da modelin sınıflandırmada zayıf kaldığını ve veriyi doğru bir şekilde ayırt edemediğini göstermektedir.

Sonuçlar incelendiğinde, Pruned Decision Tree modeli tüm metriklerde en iyi sonuçları vermiştir. SVM ve Naive Bayes ise, Pruned Decision Tree'ye kıyasla önemli ölçüde daha düşük doğruluk ve F1-skorlarına sahiptir. Pruned Decision Tree'nin bu kadar iyi performans göstermesi, karar ağaçlarının budanmasının model genellenebilirliğine olumlu katkı sağladığını göstermektedir. SVM modeli, orta seviyede bir başarı göstermiş olup, özellikle doğruluk oranının %73 civarında kalması, modelin sınıfları ayırt etme kabiliyetinde zorluklar yaşadığını işaret etmektedir. Naive Bayes ise en düşük performansı sergileyen modeldir ve

sınıf bağımsızlığı varsayımı nedeniyle veriyi yeterince iyi ayırt edememiştir. Bu sonuçlar, daha karmaşık modellerin ve veri ön işleme adımlarının, doğruluk ve F1-skorlarını artırabileceğini düşündürmektedir.



Şekil 3. Karmaşıklık matrisi

Karmaşıklık matrislerine bakıldığında, her üç modelin sınıflandırma performansı farklılık göstermektedir. Pruned Decision Tree modelinde doğru sınıflamalar ağırlıklı olarak ana köşegende yer almakta ve özellikle 0, 2 ve 3 etiketli sınıflar için çok yüksek doğru sınıflandırma oranları görülmektedir. Bu durum, modelin bu sınıfları neredeyse mükemmel şekilde tanıdığını göstermektedir. Ancak, 1 sınıfı için bazı yanlış sınıflandırmalar dikkat çekmektedir. Bu sınıfın 9 örneği 2 sınıfına yanlış sınıflandırılmıştır. Bu durum, modelin bu iki sınıfı birbirinden ayırt etmekte biraz zorlandığını göstermektedir. Genel olarak, Pruned Decision Tree modeli diğer sınıflarda oldukça iyi bir ayırım yapmıştır ve bu durum modelin yüksek doğruluk ve F1-skorları ile uyumlu olarak gözlemlenmiştir.

SVM modeline bakıldığında, doğru sınıflamalar Pruned Decision Tree'ye kıyasla daha düşük seviyededir. Özellikle 0 sınıfında 30 doğru sınıflamaya rağmen, 17 örnek 2 sınıfına yanlış atanmıştır. Ayrıca, 2 sınıfında da çok fazla yanlış sınıflama görülmektedir; 15 örnek 0 sınıfına, 4 örnek ise 1 sınıfına yanlış atanmıştır. Bu durum, SVM'nin sınıflar arasında net bir ayırım yapamadığını ve daha fazla sayıda hatalı sınıflandırma yaptığını göstermektedir. SVM'nin sınıflar arasında ayırım yapmakta zorlandığı bu hatalar, modelin daha düşük doğruluk ve F1-skoru elde etmesinin nedenidir.

Naive Bayes modelinde ise hatalı sınıflandırmalar çok daha yaygın bir şekilde gözlemlenmiştir. Örneğin, 0 sınıfında 19 doğru sınıflama yapılırken, 20 örnek yanlış sınıflandırılmıştır. Bu yanlış sınıflandırmaların 8’i 2 sınıfına, 7’si ise 3 sınıfına atanmıştır. Ayrıca, 2 sınıfında da 9 örnek 0 sınıfına yanlış atanmıştır. Bunun yanı sıra, 1 sınıfında doğru bir sınıflama yapılmamış ve tüm örnekler diğer sınıflara yanlış atanmıştır. Naive Bayes modelinin sınıflar arasındaki ayrımı yeterince yapamadığı ve karmaşık ilişkileri öğrenmekte zorlandığı görülmektedir. Bu durum, modelin düşük doğruluk ve F1-skoru elde etmesine neden olmuştur.

Genel olarak, Pruned Decision Tree diğer modellere göre sınıfları daha iyi ayırt etmiş ve hatalı sınıflandırmaların büyük çoğunluğunu önleyebilmiştir. SVM modeli bazı sınıflarda başarılı olsa da, özellikle 0 ve 2 sınıflarını ayırt etmede zorluk çekmiştir. Naive Bayes modeli ise genel olarak çok daha fazla yanlış sınıflandırma yapmış ve sınıflar arasında ciddi ayrım sorunları yaşamıştır. Bu durum, modelin düşük performansına katkıda bulunmuştur.

4. SONUÇ ve ÖNERİLER

Yapılan çalışma, makine öğrenmesi algoritmalarının 3D yazıcı teknolojilerinde çekme dayanımı gibi kritik mekanik özelliklerin tahminindeki etkinliğini ortaya koymaktadır. Özellikle Budanmış Karar Ağacı algoritmasının %96 doğruluk oranıyla diğer modellere üstünlük sağladığı belirlenmiştir. Bu bulgular, literatürdeki diğer çalışmalara kıyasla bu çalışmanın özgün katkılarını öne çıkarmaktadır.

Zhang ve arkadaşları (2023), yapay sinir ağları kullanarak FDM tabanlı üretimlerde PLA ve ABS malzemelerin mekanik özelliklerini tahmin etmiş ve %94 doğruluk oranı elde etmişlerdir. Bu çalışma, makine öğrenmesinin üretim süreçlerindeki mekanik özelliklerin tahmini konusunda güvenilir bir yöntem olduğunu göstermektedir [39]. Ayrıca, Wu ve Li (2022), metal bazlı 3D baskı malzemelerinde destek vektör makineleri algoritmasını kullanarak çekme dayanımı tahmininde başarılı sonuçlar elde etmiş, özellikle karmaşık veri kümelerinde algoritmanın güçlü bir genelleme yeteneği sunduğunu vurgulamışlardır [40].

Günay ve arkadaşları (2020), 3D baskı işlem parametrelerinin optimizasyonu üzerine yaptıkları çalışmada, baskı hızı, doluluk oranı ve tarama açısının mekanik özellikler

Muzaffer EYLENCE, Bekir AKSOY, Koray ÖZSOY, “ Makine Öğrenmesi ile 3 Boyutlu Yazıcı Plastik Filamentlerinin Ergime Noktası ve Esneklik Özelliklerine Dayalı Çekme Dayanımının Tahmini ”, Yekarum e-Dergi, 9 / 2 (2024) 91-107

üzerindeki etkilerini detaylı şekilde incelemişlerdir. Bu tür çalışmalar, üretim parametrelerinin mekanik performansa etkisini anlamada önemli katkılar sağlamaktadır [41].

Bu bağlamda, çalışmamız literatüre şu iki önemli katkıyı sunmaktadır: birincisi, EBM tabanlı 3D baskı süreçlerinde farklı makine öğrenmesi algoritmalarının performanslarını karşılaştırmalı olarak ele alarak, üretim süreçlerini optimize etmede en etkili algoritmayı belirlemek; ikincisi ise, makine öğrenmesi algoritmalarının farklı veri setleri ve parametrelerle nasıl geliştirilebileceğini göstermektir. Gelecekte yapılacak çalışmalarda, daha geniş veri setlerinin ve hibrit model yaklaşımlarının denenmesi önerilmektedir.

Teşekkür

Çalışmada kullanılan “3Dprinting plastics 2024” veri setini kullanıma açan açık erişim internet sitesinde (Kaggle.com)’a teşekkür ederiz.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması yoktur.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

KAYNAKLAR

- [1] Franco Urquiza, E. A. (2024). Advances in additive manufacturing of polymer-fused deposition modeling on textiles: From 3D printing to innovative 4D printing—A review. *Polymers*, 16(5), 700.
- [2] Ramful, R. (2024). Numerical modelling of the warping behaviour at the first layer-build plate interface in 3D-printed models produced via the fused deposition modelling process. *Advanced Manufacturing Research*.
- [3] ISO/ASTM 52900:2021. (2021). *Additive manufacturing—General principles—Fundamentals and vocabulary*. Geneva, Switzerland: ISO.
- [4] Jayanth, N., Jaswanthraj, K., Sandeep, N. H., Mallaya, S. R., & Siddharth, S. (2021). Effect of heat treatment on mechanical properties of 3D printed PLA. *Journal of Mechanical Behavior of Biomedical Materials*, 123, 104764.

- [5] Mallikarjuna, B., Bhargav, P., Hiremath, S., & Jayachristiyan, K. G. (2023). A review on the melt extrusion-based fused deposition modeling (FDM): Background, materials, process parameters, and military applications. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 1-15.
- [6] Srivatsan, T. S., & Sudarshan, T. S. (2016). *Additive manufacturing: Innovations, advances, and applications*. New York, NY: CRC Press.
- [7] Liu, Z., Wang, Y., Wu, B., Cui, C., & Yan, C. (2019). A critical review of fused deposition modeling 3D printing technology in manufacturing polylactic acid parts. *International Journal of Advanced Manufacturing Technology*, 102, 2877–2889.
- [8] Marwah, O. M. F., Shukri, M. S., Mohamad, E. J., Johar, M. A., & Khiretdin, R. H. A. H. K. (2017). Direct investment casting for pattern developed by desktop 3D printer. *MATEC Web of Conferences*, 135, 00036.
- [9] Mohamed, O. A., Masood, S. H., & Bhowmik, J. L. (2015). Optimization of fused deposition modeling process parameters: A review of current research and future prospects. *Advances in Manufacturing*, 3, 42-53.
- [10] Zhang, M., Zeng, W., Lei, Y., Chen, M., Qin, X., & Li, S. (2022). A novel sustainable luminescent ABS composite material for 3D printing. *European Polymer Journal*, 176, 111406.
- [11] Maspoch, M. L., Santana, O. O., Cailloux, J., Franco-Urquiza, E., Rodriguez, C., & Martínez, J. (2015). Ductile-brittle transition behaviour of PLA/o-MMT films during the physical aging process. *Express Polymer Letters*, 9, 185–195.
- [12] Bhagia, S., Kore, S., Wasti, S., Đurković, J., Zhao, X., & Andrews, H. B. (2023). 3D printing of a recycled copolyester of terephthalic acid, cyclohexanedimethanol, and tetramethylcyclobutanediol. *Polymer Testing*, 118, 107916.
- [13] Kumar, M., Ramakrishnan, R., & Omarbekova, S. (2021). Experimental characterization of mechanical properties and microstructure study of polycarbonate (PC) reinforced acrylonitrile-butadiene-styrene (ABS) composite with varying PC loadings. *AIMS Materials Science*, 8, 18–28.
- [14] Andrzejewski, J., & Marciniak-Podsadna, L. (2020). Development of thermal resistant FDM printed blends. The preparation of GPET/PC blends and evaluation of material performance. *Materials*, 13, 2057.

- [15] Zhang, Y., Purssell, C., Mao, K., & Leigh, S. A. (2020). Physical investigation of wear and thermal characteristics of 3D printed nylon spur gears. *Tribology International*, 141, 105953.
- [16] Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- [17] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- [18] Searle, J. R. (1980). Minds, brains, and programs. *Behavioral and Brain Sciences*, 3(3), 417-424.
- [19] Bostrom, N. (2014). *Superintelligence: Paths, dangers, strategies*. Oxford University Press.
- [20] Mitchell, T. M. (1997). *Machine learning*. McGraw Hill.
- [21] Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging Artificial Intelligence Applications in Computer Engineering*, 160, 3-24.
- [22] Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507.
- [23] Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.
- [24] Çınar, İ., Gündüz, G., & Yılmaz, Ö. (2020). Machine learning approaches for tensile strength prediction in 3D printed polymers. *Journal of Applied Polymer Science*, 137(15), 485-492.
- [25] Yılmaz, M., & Demir, E. (2021). Prediction of tensile strength of 3D printed materials using artificial neural networks and decision trees. *Materials & Design*, 209, 109930.
- [26] Huang, Y., Leu, M. C., Mazumder, J., & Donmez, A. (2019). Additive manufacturing: Current state, future potential, gaps and needs, and recommendations. *Journal of Manufacturing Science and Engineering*, 141(1), 011014.
- [27] Kaggle. (2024). *3D printer plastics dataset*. Retrieved from <https://www.kaggle.com/datasets/sourceduty/3d-printer-plastics-2024>
- [28] Quinlan, J. R. (1987). Simplifying decision trees. *International Journal of Man-Machine Studies*, 27(3), 221-234.

- [29] Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. Wadsworth International Group.
- [30] Esposito, F., Malerba, D., & Semeraro, G. (1997). A comparative analysis of methods for pruning decision trees. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5), 476-491.
- [31] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- [32] Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. MIT Press.
- [33] Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer.
- [34] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.
- [35] Domingos, P., & Pazzani, M. (1997). On the optimality of the simple Bayesian classifier under zero-one loss. *Machine Learning*, 29(2-3), 103-130.
- [36] Rish, I. (2001). An empirical study of the naive Bayes classifier. In *IJCAI Workshop on Empirical Methods in AI*, 3, 41-46.
- [37] Zhang, H. (2004). The optimality of naive Bayes. In *AAAI 2004 Conference on Artificial Intelligence*, 562-567.
- [38] H. Çetiner and S. Metlek, “CNNTuner: Image Classification with A Novel CNN Model Optimized Hyperparameters,” Bitlis Eren Üniversitesi Fen Bilim. Derg., vol. 12, no. 3, pp. 746–763, 2023.
- [39] Günay, M., Yıldırım, Z., & Demirci, E. (2020). 3D baskı işlem parametrelerinin çekme dayanımı üzerindeki etkileri. *Politeknik Dergisi*, 23(4), 1043-1050.
- [40] Wu, J., & Li, F. (2022). Predicting tensile strength in metal 3D printing using support vector machines. *Journal of Additive Manufacturing Science*, 18(3), 145-157.
- [41] Zhang, T., Huang, Y., & Chen, L. (2023). Application of artificial neural networks for predicting mechanical properties of PLA and ABS in FDM-based 3D printing. *International Journal of Polymer Science*, 45(2), 215-227.



Süleyman Demirel Üniversitesi
YEKARUM e-DERGI
(Journal of YEKARUM)



Cilt 9, Sayı 2, 108-127, 2024
E - ISSN: 1309-9388

Makine Öğrenimi Algoritmaları Kullanılarak Bina Enerji Verimliliğinin Doğrusal Regresyon Analizi

Hakan YÜKSEL^{1*}

^{1*} Isparta Uygulamalı Bilimler Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Isparta, Türkiye, (ORCID: 0000-0003-2186-533X), hakanyuksel@isparta.edu.tr

(İlk Geliş Tarihi 01/10/2024 ve Kabul Tarihi 18/12/2024)

ÖZET:

İklim değişikliği günümüz dünyasında kritik bir sorun haline gelmiştir. Günümüzde binalar, küresel enerjinin büyük çoğunluğunu kullandığından, bina enerji verimliliği (ısıtma yükü ve soğutma yükü) düzenlemeleri giderek daha katı hale gelmektedir. Binaların, enerji tüketimini anlamak ve bina tasarım aşamasında enerji yükünün iyi bir tahminine sahip olmak ise oldukça önemlidir. Geleneksel enerji tahmin çözümleri zaman alıcı ve maliyetli iken, makine öğrenimi algoritmaları bu duruma alternatif bir yaklaşım sunabilmektedir. Bu çalışmada, binaların ısıtma ve soğutma yüklerini tahmin etmek için bir lineer regresyon modeli kullanılmıştır. Veri modeli için enerji verimliliği veri seti kullanılarak enerji verimliliğinin değerlendirilmesi gerçekleştirilmiştir.

Anahtar Kelimeler: *Makine öğrenmesi, Doğrusal regresyon analizi, Bina verimliliği*

Linear Regression Analysis of Building Energy Efficiency Using Machine Learning Algorithms

ABSTRACT

Climate change has become a critical issue in today's world. Since buildings consume the vast majority of global energy today, building energy efficiency (heating load and cooling load) regulations are becoming increasingly stringent. Understanding the energy consumption of buildings and having a good estimate of the energy load during the building design phase is very important. While traditional energy estimation solutions are time-consuming and costly, machine learning algorithms can offer an alternative approach. In this study, a linear regression model is used to estimate the heating and cooling loads of buildings. The energy efficiency dataset is used for the data model to evaluate energy efficiency.

Keywords: *Machine learning, Linear regression analysis, Building efficiency,*

* Sorumlu yazar E-mail: hakanyuksel@isparta.edu.tr

1. GİRİŞ

Enerji verimliliği, enerji tüketimini düşürme, sera gazı emisyonlarını azaltma ve iklim değişikliğinin etkilerini hafifletme ihtiyacıyla yönlendirilen küresel bir öncelik haline gelmiştir. Günümüzde binalar, toplam küresel enerji kullanımının yaklaşık %40’ını oluşturmakta ve bu da sürdürülebilirlik hedeflerine ulaşmak için inşa edilmiş çevrede enerji verimliliği iyileştirmelerini gerekli kılmaktadır. Binaların enerji verimliliğini artırmak, operasyonel maliyetleri önemli ölçüde azaltabilirken aynı zamanda çevresel faydalar da sağlamaktadır. Bu da onu politikacılar, mühendisler ve şehir plancıları için önemli bir alan haline getirmektedir. [1], [2], [3].

Binalardaki enerji tüketimi aslında oldukça karmaşıktır. Yapısal özellikler (boyut, tasarım, malzemeler), çevre koşulları (yerel iklim, mevsimsel değişiklikler) ve yapım davranışları (kullanım kalıpları, ısıtma/soğutma tercihleri) gibi çok sayıda faktörden etkilenmektedir. Bu faktörler son derece dinamik şekillerde etkileşime girerek enerji tüketiminin yalnızca geleneksel yöntemlerle doğru bir şekilde modellenmesini zorlaştırmaktadır. Tarihsel olarak istatistiksel yaklaşımlar bina enerji tüketimini tahmin etmek için kullanılmış olsa da bu yöntemler genellikle değişkenler arasındaki doğrusal olmayan ilişkileri yakalamada başarısız sonuçlar ortaya koymaktadır. Makine öğreniminin, bina enerji tüketimini tahmin etmek için kullanılması, karmaşık, yüksek boyutlu verileri daha büyük bir hassasiyetle analiz edebilen güçlü bir alternatif olarak görmektedir [4], [5], [6].

Makine öğrenimi (ML) algoritmaları, büyük veri kümelerini kullanarak ve bunlardaki kalıpları ortaya çıkararak binalardaki enerji tahmininin karmaşıklıklarını ele almak için oldukça uygundur. Özellikle ML tabanlı regresyon algoritmaları, bina enerji tüketimini doğru bir şekilde tahmin etme konusunda güçlü bir potansiyel göstermektedir. Enerji kullanımı ve diğer ilgili özellikler hakkındaki geçmiş verileri inceleyerek, regresyon tabanlı ML modelleri önemli tahmin faktörlerini belirleyebilir, bağımlı ve bağımsız değişkenler arasındaki ilişkileri modelleyebilir ve gelecekteki enerji ihtiyaçlarını tahmin edebilmektedir [7]. Bu yaklaşım, bina iyileştirmeleri ve enerji tasarrufu müdahaleleriyle ilgili kararları bilgilendirebilecek daha ayrıntılı ve veri odaklı içgörüler sağlamaktadır [8], [9], [10].

Bina enerji verimliliği için makine öğrenimi yaklaşımlarına odaklanan, temel yöntemleri, modelleri ve bulguları özetleyen karşılaştırmalı bir literatür incelemesi Tablo 1’ de verilmiştir. Bu tablo, her bir çalışmanın makine öğrenimi kullanılarak enerji verimliliğinin anlaşılmasına veya iyileştirilmesine nasıl katkıda bulunduğu dair yapılandırılmış bir görünüm sağlamaktadır.

Tablo 1. Veri Setinin Özellikleri

Yazar(lar) ve Yıl	Amaç	Makine Öğrenimi Model(ler)	Temel Bulgular	Enerji Verimliliğine Odaklanma
Dong ve diğerleri (2005) [11]	Tropikal binalarda SVM uygulaması	Destek Vektör Makineleri	SVM, belirli iklim bağlamları için etkilidir ve esneklik sunar	ML'nin bölgeye özgü enerji tasarrufu potansiyelini gösterir
González & Zamarrero (2005) [10]	Yapay Sinir Ağları ile saatlik enerjiyi tahmini	Yapay Sinir Ağları	Yapay Sinir Ağları'nın geri bildirim mekanizması gerçek zamanlı verilerle doğruluğu artırır	Binalarda sürekli enerji verimliliği iyileştirmelerini destekler
Ekici & Aksoy (2009) [12]	Yapay Sinir Ağları ile enerji kullanımını tahmini	Yapay Sinir Ağları	Yapay Sinir Ağları, doğrusal olmayan durumları iyi bir şekilde ele alarak tahmin gücünü artırır	Enerji tahmin doğruluğu, verimli enerji tahsisine yardımcı olur
Yu ve diğerleri (2010) [8]	Enerji talebi	Karar Ağaçları	Karar Ağaçları yorumlanabilirlik sunar ancak aşırı uyum riski taşır; özellik önemi açısından yararlıdır	Enerji verimliliği politikalarında karar vermeyi destekler
Zhao & Magoulès (2012) [2]	Bina enerji tüketiminin tahmini	Doğrusal Regresyon, Sinir Ağları	Sinir Ağları karmaşık ortamlarda doğrusal modellerden daha iyi performans gösterir	Enerji israfını azaltmada doğru tahminin rolünü vurgular
Fouquier ve diğerleri (2013) [4]	Enerji performansı modellemesinin gözden geçirilmesi	ML ile entegre simülasyon	ML, geleneksel simülasyonları geliştirir; dinamik faktörleri ele alır	ML'yi optimize edilmiş enerji planlaması için değerli bir araç olarak tanımlar
Liang ve diğerleri (2016) [13]	Doluluk verileriyle temel modelleri geliştirme	Çoklu Regresyon	Doluluk, enerji doğruluğunu önemli ölçüde etkiler; eklenen veriler model doğruluğunu artırır	Doluluk odaklı enerji verimliliği önlemlerinin önemini vurgular
Mocanu ve diğerleri (2016) [14]	Enerji tahmini için derin öğrenmeyi uygulamalar	Derin Öğrenme	DNN'leri karmaşık kullanım modellerini yakalamada daha basit modellerden daha iyi	Daha iyi verimlilik planlaması için enerji tahminlerini iyileştirir

Reyna & Chester (2017) [15]	Kentsel bina stoku büyüme etkilerini inceleme	Simülasyon, İstatistiksel Modeller	performans gösterir Kentsel büyüme yüksek enerji kullanımını sabitleyebilir; modeller erken müdahale ile verimlilik kazanımları gösterir	Uzun vadeli enerji verimliliği için proaktif tasarıma odaklanır
Wei ve diğerleri (2018) [16]	Veri odaklı enerji tüketim yöntemlerini inceleme	Regresyon, Karar Ağaçları, SVM	Karmaşık ML modelleri (ANN, SVM), yüksek doğruluklu tahmin için daha basit olanlardan daha iyi performans gösterir	Optimize edilmiş verimlilik için enerji sistemlerinin hassas kontrolünü destekler
Amasyalı & El-Gohary (2018) [9]	Enerji tüketimi için veri odaklı modellerin incelenme	Karar Ağaçları, Regresyon Modelleri	Regresyon modelleri temeldir, ancak karmaşık yöntemler daha fazla faktörü ele alır	Verimli enerji yönetimi stratejileri için bir araç olarak ML’ye odaklanma
Cuilla ve diğerleri (2018) [17]	Çoklu regresyonla bina enerjisini tahmin etme	Çoklu Doğrusal Regresyon	Regresyon güvenilir bir temel model sağlar; ek özellikler hassasiyeti artırır	Regresyon verimlilik değerlendirmeleri için temel model olarak kullanılır
Hong ve diğerleri (2018) [1]	Bina enerji simülasyonundaki zorlukları analiz etme	Simülasyon tabanlı ML entegrasyonu	Simülasyon sınırlamalarla karşı karşıyadır; ML dinamik modelleme için umut verici geliştirmeler sunar	Karmaşık binalarda enerji verimliliğini ele almak için ML’nin uyarlanabilirliği
Yang ve diğerleri (2019) [18]	Bina enerjisi için model tahminli kontrol	Regresyon, Model Tahminli Kontrol (MPC)	ML ile MPC, enerji kullanımını dinamik olarak azaltır	Verimlilik için gerçek zamanlı enerji yönetimini optimize eder

Bu çalışma, bina enerji tüketimini tahmin etmedeki etkinlikleri açısından birkaç önemli makine öğrenimine ait doğrusal regresyon algoritmasını değerlendirmeyi amaçlamaktadır. Regresyon, giriş ve çıkış değişkenleri arasında doğrusal bir ilişki varsayan, genellikle bir temel model görevi gören temel bir tekniktir. Her ne kadar yorumlanabilir olsa da, performansı karmaşık, doğrusal olmayan veri kümeleri için sınırlı olabilmektedir [9]. Dolayısıyla regresyon analizinde ön plana çıkan değerlendirme ölçümlerinden olan Ortalama Karesel Hata (MSE), Kök Ortalama Karesel Hata (RMSE) ve Ortalama Mutlak Hata (MAE) değerleri çıktı sonuçları

kapsamında detaylı bir şekilde incelenmiştir. Yine doğrusal regresyon modeli, Karar Ağacı, Rastgele Orman, Gradient Boosting, Ada Boost, K-En Yakın Komşu, Destek Vektör Makineleri (SVR) performanslarının karşılaştırılması çıktıları üzerinde gerçekleştirilmiştir.

Bu araştırma, regresyon algoritmalarını inceleyerek bina enerji verimliliği alanına değerli içgörüler sağlamayı amaçlamaktadır. Bulgular, bina sahipleri, mühendisler ve şehir plancıları gibi paydaşların enerji tasarrufu stratejileri, tasarım optimizasyonları ve yenileme planlaması hakkında bilinçli kararlar almalarına yardımcı olmayı amaçlamaktadır. Bu araştırma, nihayetinde azaltılmış bir çevresel ayak izine ve önemli enerji tasarruflarına yol açacak olan enerji verimli binaların inşasını ve bakımını destekleyerek sürdürülebilir kalkınmanın daha geniş hedeflerine de uyum sağlamaktadır.

2. MATERYAL ve METOT

2.1. Veri Seti

Enerji verimliliği veri seti, bina parametrelerinin bir fonksiyonu olarak enerji verimliliğinin değerlendirilmesi için hazırlanmış ve Kaggle platformunda bulunan bir veri seti kümesidir [19]. Binaların ısıtma yükü ve soğutma yükü gereksinimlerini (yani enerji verimliliğini) bina parametrelerinin bir fonksiyonu olarak değerlendirmeyi ele almaktadır. Veri kümesi sekiz öznitelik (özellik) ve iki sonuç (çıkıtı) içermektedir. Amaç, sekiz özelliği kullanarak her iki yanıtı da tahmin etmektir. Veri setine ait özellik ve çıktılar şu şekildedir:

Relative_Compactness (Göreceli_Kompaktlık); binanın hacminin, binayı çevreleyen eşdeğer bir küboidin hacmine oranı olarak tanımlanan binanın görece kompaktlığıdır. Bu değişken 0.62 ile 0.98 arasında değişmektedir.

Surface_Area (Yüzey_Alanı); duvarlar, çatı ve pencereler dahil olmak üzere binanın toplam yüzey alanıdır. Bu değişken 514.5 ile 808.5 m² arasında değişmektedir.

Wall_Area (Duvar_Alanı); binanın duvarlarının toplam alanıdır. Bu değişken 245 ile 416,5 m² arasında değişmektedir.

Roof_Area (Çatı_Alanı); binanın çatısının toplam alanıdır. Bu değişken 110.25 ile 220.5 m² arasında değişmektedir.

Overall_Height (Genel_Yükseklik); binanın yüksekliğidir. Bu değişken 3.5 ile 7.0 metre arasında değişmektedir.

Orientation (Yönlendirme); 2: Kuzey, 3: Doğu, 4: Güney, 5: Batı: Bu, binanın yönüdür. 2, 3, 4 ve 5 değerleri sırasıyla Kuzey, Doğu, Güney ve Batı yönlerini temsil etmektedir.

Glazing_Area (Cam Alanı); binanın toplam cam alanıdır ve kat alanının yüzdesi olarak ifade edilmektedir. Bu değişken dört değerden birini almaktadır: %0, %10, %25 veya %40.

Glazing_Area_Distribution (Cam Alanı Dağılımı); cam alanının bina genelindeki dağılımıdır. 1, 2, 3, 4 ve 5 değerleri, düzgün bir dağılımı ve sırasıyla 2- Kuzey, 3- Doğu, 4- Güney ve 5- Batı dağılımlarını temsil etmektedir.

Heating_Load (Isıtma Yüğü); binanın ısıtma yüküdür ve metrekare başına kilovatsaat olarak ifade edilmektedir. Bu değişken 6.01 ila 43.1 kWh/m² arasında değişmektedir.

Cooling_Load (Soğutma Yüğü); binanın soğutma yüküdür ve metrekare başına kilovatsaat olarak ifade edilmektedir. Bu değişken 10.9 ila 48.03 kWh/m² arasında değişmektedir.

Veri seti, farklı binaların şeklini kullanarak enerji analizi gerçekleştirebilmek için kullanılmaktadır. Binalar, diğer parametrelerin yanı sıra cam alanı, cam alanı dağılımı ve yönlendirme açısından farklılık göstermektedir. Veri seti, iki gerçek değerli yanıtı tahmin etmeyi amaçlayan 768 örnek ve 8 özellikten oluşmaktadır.

2.2. Veri Ön işleme

Veri seti, 768 kayıt ve 8 özellikten oluşmaktadır. Veri seti eksik ya da hatalı veri kapsamında pandas kütüphanesinin fonksiyonları tarafından gözden geçirilmiştir. Bu kapsamda `duplicate()` ve `isna()` fonksiyonlarıyla veri seti denetlenmiştir.

Yapılan incelemeler neticesinde veri setinde herhangi bir eksik değer ya da tekrar eden bir veriye rastlanılmamıştır. İlgili detaylar Tablo 2’ de gösterilmiştir.

Tablo 2. Veri Setinin Özellikleri

Sıra	Özellik & Çıktı	Toplam Kayıt	Veri Tipi
0	relative_compactness	768	float64
1	surface_area	768	float64
2	wall_area	768	float64
3	roof_area	768	float64
4	overall_height	768	float64
5	orientation	768	int64
6	glazing_area	768	float64
7	glazing_area_distribution	768	int64
8	heating_load	768	float64
9	cooling_load	768	float64

2.3. Verilerin İncelenmesi

Enerji verimliliği veri seti’ ne ait ilk 5 kayıt Tablo 3’ te gösterilmektedir. Özellikler ve çıktı sütunlarının Tablo 1’ de verilen veri tipine ait değerler olduğu tabloda açıkça görülmektedir.

Tablo 3. Veri Setinin Değerleri

	Relative Compac tness	Surface _Area	Wall_ Area	Roof_ Area	Overall_ Height	Orient ation	Glazing _Area	Glazing_ Area_Distr ibution	Heating_ Load	Cooling_ Load
0	0.98	514.5	294.0	110.25	7.0	2	0.0	0	15.55	21.33
1	0.98	514.5	294.0	110.25	7.0	3	0.0	0	15.55	21.33
2	0.98	514.5	294.0	110.25	7.0	4	0.0	0	15.55	21.33
3	0.98	514.5	294.0	110.25	7.0	5	0.0	0	15.55	21.33
4	0.90	563.5	318.5	122.50	7.0	2	0.0	0	20.84	28.28

2.4. Lineer Regresyon

Doğrusal regresyon, özellikle girdi özellikleri ile hedef değişken arasındaki ilişki doğrusal olduğunda, öngörücü analiz için kullanılan makine öğrenimindeki (ML) en basit ve en popüler modellerden birisidir. Bu model, bir bağımlı değişken ile bir (basit doğrusal regresyon) veya birden fazla bağımsız değişken (çoklu doğrusal regresyon) arasındaki ilişkiyi, gözlemlenen verilere doğrusal bir denklem uygulayarak tahmin etmektedir [20], [21], [22].

2.4.1. Doğrusal Regresyonun Temel Bileşenleri

Basit bir doğrusal regresyon için, model tipik olarak şu şekilde gösterilir:

$$y=w \cdot x+b \quad (1)$$

y ; y bağımlı değişkendir (hedef).

x ; x bağımsız değişkendir (giriş özelliği).

w ; x için ağırlık veya katsayıdır ve doğrunun eğimini temsil eder.

b ; doğrunun y -kesişimini temsil eden önyargı terimidir.

n ; özelliği olan çoklu doğrusal regresyon için şu hale gelir:

$$y=w_1 \cdot x_1+w_2 \cdot x_2+\dots+w_n \cdot x_n+b \quad (2)$$

Doğrusal regresyonun amacı, tahmin edilen ve gerçek değerler arasındaki farkı (hatayı) en aza indirmektir. Bu fark genellikle, tahmin edilen ve gözlenen değerler arasındaki kare farklarının toplamını en aza indiren en küçük kareler kullanılarak en aza indirilir:

$$\text{Cost} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3)$$

burada; y_i gerçek değer, \hat{y}_i öngörülen değer ve N veri noktası sayısıdır.

2.5. Değerlendirme Ölçütleri

Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE) ve Kök Ortalama Karesel Hata (RMSE) genellikle modelin performansını değerlendirmek için kullanılmaktadır. Doğrusal regresyon, ekonomi (giderleri tahmin etme), sağlık (hastalıkların ilerlemesini tahmin etme), çevre bilimi (kirlilik seviyelerini tahmin etme) ve birçok farklı alanlarda uygulanmaktadır.

Makine öğrenimi modelleri, verilerdeki kalıpları anlamayı, tahminler yapmayı, sorulara yanıtlar vermeyi veya gizli kalıpların daha derin bir şekilde anlaşılmasını sağlamayı hedefler. Bu yinelemeli öğrenme süreci, modelin kalıpları edinmesini, yeni verilerle test etmesini, parametreleri ayarlamasını ve tatmin edici bir performans elde edene kadar tekrarlamasını içermektedir. Regresyon sorunları için olmazsa olmaz olan değerlendirme aşaması, kayıp fonksiyonlarını kullanmaktadır.

Kayıp fonksiyonları, modelin tahmin edilen değerlerini gerçek değerlerle karşılaştırır ve X (özellik) ile Y (hedef) arasındaki ilişkiyi haritalamadaki etkinliğini ölçmektedir. Tahmin edilen ve gerçek değerler arasındaki farklılığı gösteren kayıp, model iyileştirmesine rehberlik sunmaktadır. Daha yüksek bir kayıp, daha zayıf performansı belirtir ve optimum eğitim için ayarlamalar olduğu göstermektedir.

2.5.1. Ortalama Mutlak Hata (MAE)

Ortalama Mutlak Hata veya L1 kaybı, en basit ve kolay anlaşılır kayıp fonksiyonlarından ve değerlendirme ölçütlerinden biri olarak öne çıkmaktadır. Veri kümesi boyunca tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasını alarak hesaplanmaktadır. Matematiksel olarak, yönden bağımsız olarak yalnızca büyüklüklerine odaklanarak mutlak hataların aritmetik ortalamasını temsil etmektedir. Daha düşük bir MAE, üstün model doğruluğuna işaret eder.

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

y_i = gerçek değer

\hat{y}_i = tahmin edilen değer

n = örneklem büyüklüğünü ifade etmektedir.

2.5.2. Ortalama Karesel Hata (MSE)

MSE, en yaygın regresyon kayıp fonksiyonlarından biri ve önemli bir hata metriğidir. L2 kaybı olarak da bilinen Ortalama Karesel Hata’da, tahmini değer ile gerçek değer arasındaki farkı kareleyerek ve veri kümesi boyunca ortalamasını alarak hata hesaplanmaktadır.

MSE, cezanın hataya değil, hatanın karesine orantılı olması nedeniyle Kuadratik kayıp olarak da bilinmektedir. Hatanın karesi, aykırı değerlere daha yüksek ağırlık verir ve bu da küçük hatalar için düzgün bir eğimle sonuçlanır.

Optimizasyon algoritmaları, en küçük kareler yöntemini kullanarak parametreler için optimum değerleri bulmaya yardımcı olduğu için büyük hatalar için bu cezalandırmadan faydalanır. Hatalar karelendiği için MSE asla negatif olmamaktadır. Hata değeri sıfırdan sonsuza kadar değişmektedir. MSE, hata arttıkça üstel olarak artar. İyi bir modelin MSE değeri sıfıra yakın olacaktır ve bu da verilere daha iyi uyum sağladığını gösterir.

$$MAE = \frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

2.5.3. Kök Ortalama Karesel Hata (RMSE)


Makine Öğrenmesinde Kök Ortalama Kare Hatası (RMSE), makine öğrenmesi ve istatistikte bir tahmin modelinin doğruluğunu ölçmek için kullanılan popüler bir ölçümdür. Tahmin edilen değerler ile gerçek değerler arasındaki farkları niceliksel olarak belirler, hataları kareler, ortalamayı alır ve ardından karekökünü bulur. RMSE, modelin performansı hakkında net bir anlayış sağlar ve daha düşük değerler, kök ortalama kare hatasına göre daha iyi tahmin doğruluğu göstermektedir.

MSE’nin karekökü alınarak hesaplanır. RMSE, Kök Ortalama Kare Sapması olarak da adlandırılır. Hataların ortalama büyüklüğünü ölçer ve gerçek değerden sapmalarla ilgilenir. Sıfır olan RMSE değeri, modelin mükemmel bir uyuma sahip olduğunu gösterir. RMSE ne kadar düşükse, model ve tahminleri o kadar iyidir. Makine öğreniminde daha yüksek bir göreceli kök ortalama kare hatası, kalıntıdan temel gerçeğe büyük bir sapma olduğunu gösterir. RMSE, özelliğın modelin tahminini iyileştirip iyileştirmediğini anlamaya yardımcı olduğu için farklı özelliklerle kullanılabilir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

3. ARAŞTIRMA SONUÇLARI

Enerji verimliliği veri seti’ nin temel istatistik değerleri Tablo 4’ te verilmiştir. Veriler ait histogram grafikleri ise Şekil 1’ de gösterilmiştir.



Şekil 1. Histogram Grafikleri

Tablo 4. Veri Setine Ait Temel İstatistik Değerler

	RelativeCompactness	Surface_Area	Wall_Area	Roof_Area	Overall_Height	Orientation	Glazing_Area	Glazing_Area_Distribution	Heating_Load	Cooling_Load
count	768.0000	768.0000	768.0000	768.0000	768.0000	768.0000	768.0000	768.0000	768.0000	768.0000
mean	0.764167	671.7083	318.5000	176.604167	5.25000	3.50000	0.234375	2.81250	22.307201	24.587760
std	0.105777	88.086116	43.626481	45.165950	1.75114	1.118763	0.133221	1.55096	10.090196	9.513306
min	0.620000	514.5000	245.0000	110.25000	3.50000	2.00000	0.000000	0.00000	6.010000	10.900000
25%	0.682500	606.3750	294.0000	140.875000	3.50000	2.75000	0.100000	1.75000	12.992500	15.620000
50%	0.750000	673.7500	318.5000	183.750000	5.25000	3.50000	0.250000	3.00000	18.950000	22.080000
75%	0.830000	741.1250	343.0000	220.500000	7.00000	4.25000	0.400000	4.00000	31.667500	33.132500
max	0.980000	808.5000	416.5000	220.500000	7.00000	5.00000	0.400000	5.00000	43.100000	48.030000

Relative_Compactness; Binanın genel genişliği, uzunluğu ve yüksekliğinin çarpımının alınarak binanın toplam hacmine bölünmesiyle hesaplanan boyutsuz bir niceliktir. Bu sütun 0,62 ile 0,98 arasında değişir ve ortalaması 0.764, standart sapması 0.106'dır. Değer ne kadar düşükse bina o kadar kompakttır, daha yüksek değerler ise daha az kompakt bir binayı gösterir.

Surface_Area; Çatı, duvarlar ve pencereler dahil binanın yüzey alanını metrekare olarak gösteren sayısal veridir. Ortalama değeri 671.71 metrekare, standart sapması 88.09 metrekaredir. Minimum değeri 514.50 metrekare, maksimum değeri ise 808.50 metrekaredir. 25., 50. (ortanca) ve 75. yüzdeler sırasıyla 606.38, 673.75 ve 741.13 metrekaredir.

Wall_Area; Her binanın toplam duvar alanını metrekare olarak temsil eder. 245 ila 416.5 arasında değişen değerlere sahip, ortalama değeri yaklaşık 318.5 metrekare ve standart sapması yaklaşık 43.6 metrekare olan sürekli bir sayısal bir parametredir. Minimum değer 245 maksimum değer ise 416.5'tir. 25. yüzdeler değeri yaklaşık 294 iken 75. yüzdeler değeri yaklaşık 343'tür. Duvarlar, çatılar ve pencereler dahil olmak üzere binanın toplam yüzey alanını ölçen "Surface_Area" sütunuyla karşılaştırıldığında, "Wall_Area" sütunu yalnızca duvarların alanını ölçer. Bu nedenle, daha büyük toplam yüzey alanına sahip binalar daha büyük duvar alanlarına

sahip olabilir, ancak bu her zaman böyle değildir, çünkü bu binanın belirli tasarımına ve yönüne bağlıdır.

Roof_Area; binanın toplam çatı alanını metrekare olarak ifade eder. Bu sütundaki minimum değer 110.25 metrekaredir. Bu sütundaki maksimum değer 220.5 metrekaredir. Bu özelliğin ortalama değeri 176.604167 metrekaredir. Bu sütunun standart sapması 45.165950 metrekaredir. Bu özelliğin medyan değeri 183.75 metrekaredir.

Overall_Height; Binanın yüksekliğini temsil eder. Metre olarak ölçülür ve minimum 3.5 metreden maksimum 7 metreye kadar değişir. Veri setindeki binaların ortalama yüksekliği 5.25 metredir ve standart sapması 1.751 metredir. Binaların yükseklik dağılımı simetrik, çünkü ortalama ve medyan (aynı zamanda 5.25 metredir) eşittir.

Orientation; Binanın yönünü temsil eder. 2 ile 5 arasında tam sayı değerleri alır, burada: 2: Kuzeye bakan bina 3: Doğuya bakan bina 4: Güneye bakan bina 5: Batıya bakan bina. Bir binanın yönü, aldığı güneş radyasyonu miktarını etkileyebilir ve bu da ısıtma ve soğutma yüklerini etkileyebilir.

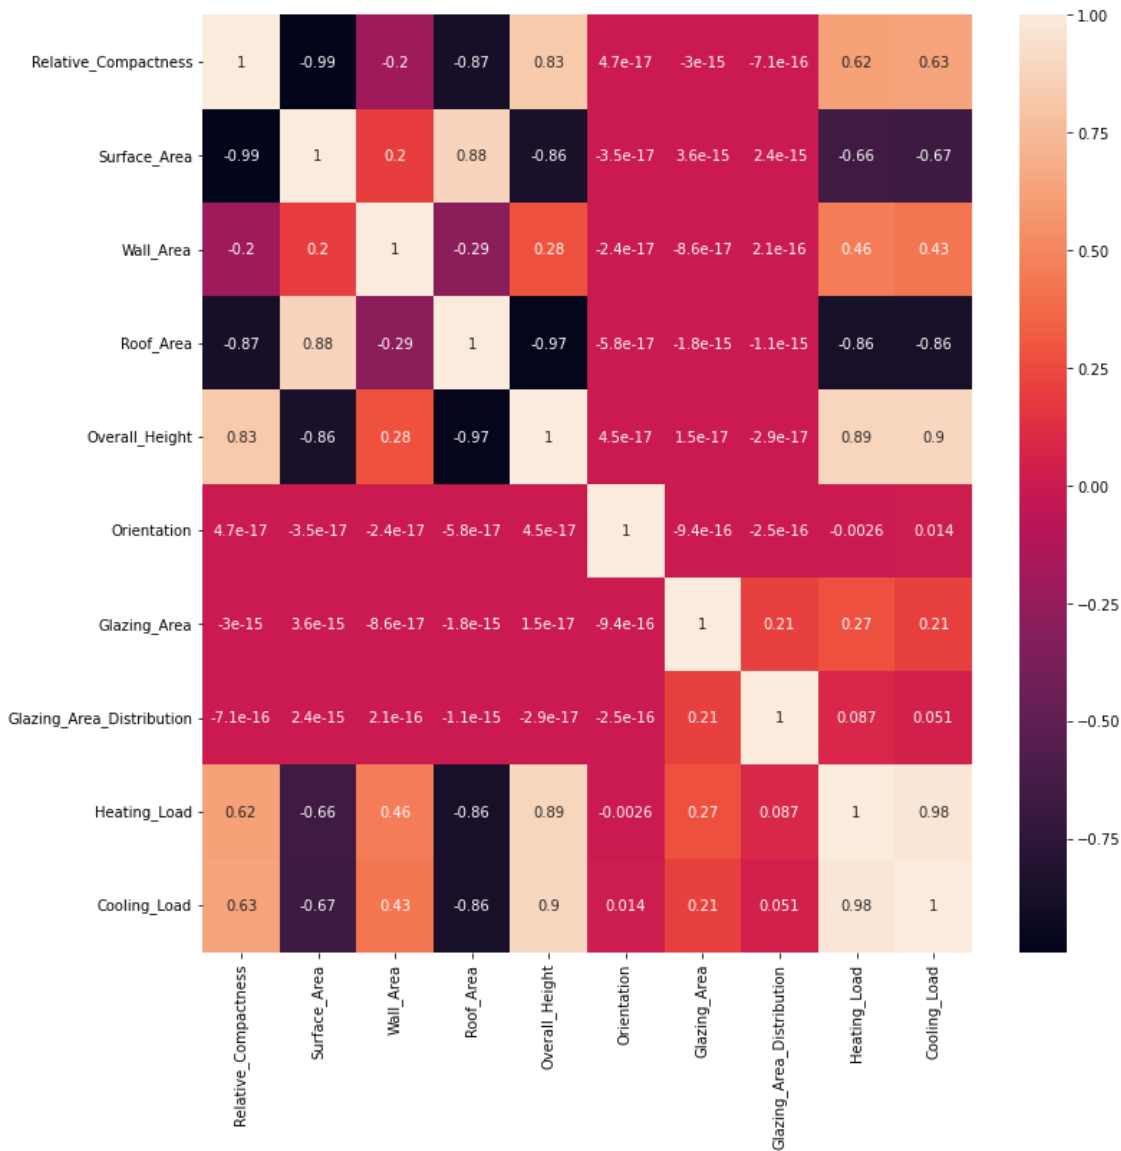
Glazing_Area; Toplam cam alanını binanın taban alanına oranı olarak temsil eder. 0.0 ile 0.4 arasında değişir, ortalaması 0.234 ve standart sapması 0.133'tür. Minimum değer 0.0'dır, yani binanın penceresi yoktur; maksimum değer ise 0.4'tür, yani taban alanının %40'ının pencerelerle kaplı olduğunu gösterir. Genel olarak, daha yüksek bir cam alanı daha fazla doğal ışık ve havalandırma sağlar ancak aynı zamanda daha yüksek ısıtma ve soğutma yüklerine de yol açabilir. Bu nedenle, optimum cam alanı iklim, bina yönü ve istenen enerji verimliliği seviyesi gibi çeşitli faktörlere bağlıdır.

Glazing_Area_Distribution; Binadaki cam alanının dağılımını temsil eden kategorik bir değişkendir. 0 ile 5 arasında bir değer aralığına sahiptir, burada: 0: cam olmadığını temsil eder 1: yalnızca kuzey tarafında cam olduğunu temsil eder 2: kuzey ve güney taraflarında cam olduğunu temsil eder 3: kuzey, güney ve doğu taraflarında cam olduğunu temsil eder 4: kuzey, güney, doğu ve batı taraflarında cam olduğunu temsil eder 5: doğu ve batı taraflarında cam olduğunu temsil eder. Bu sütun kategorik olduğundan, onu tanımlamak için ortalama veya standart sapma gibi ölçütler kullanılmamaktadır. Bunun yerine, her bir değer sıklığına bakarak her bir dağılımın ne kadar yaygın olduğuna dair bir fikir edinebiliriz.

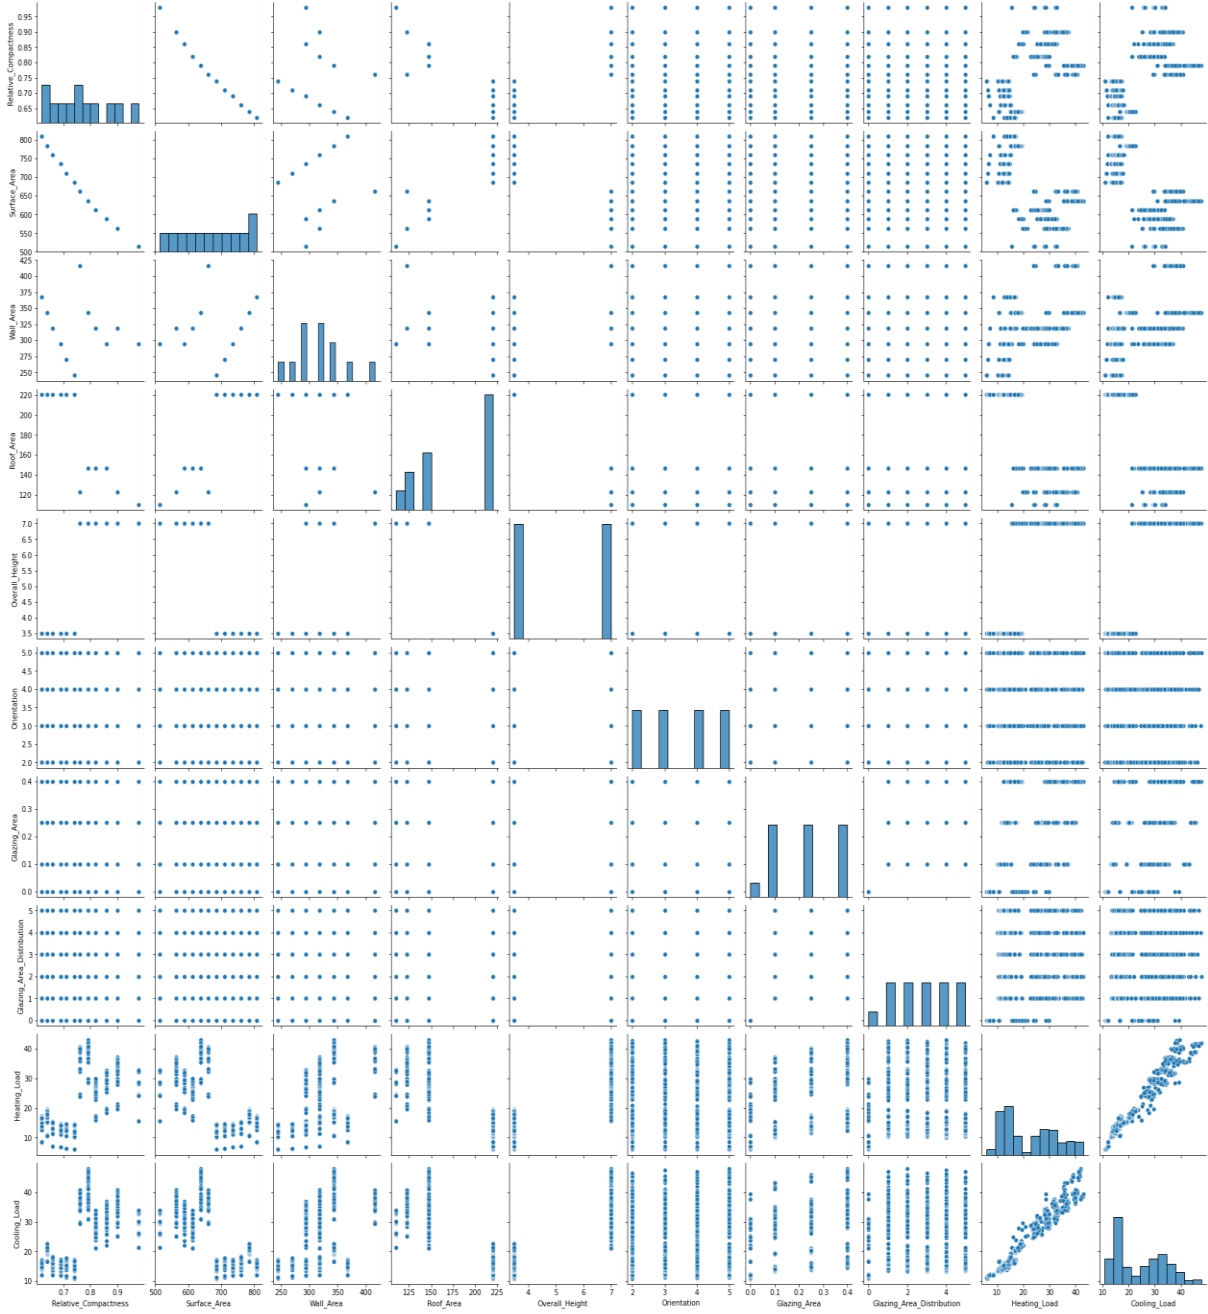
Heating_Load; Veri kümesindeki her bir bina için kWh/m² cinsinden ısıtma yükünü temsil eder. Sürekli bir sayısal değişkendir. Minimum ve maksimum değerler sırasıyla 6.01 ve 43.1Q'dir. Ortalama değer 22.31 kWh/m² ve standart sapma 10,09 kWh/m²'dir. Bu sütundaki değerler, bir binayı kışın konforlu bir sıcaklığa ısıtmak için gereken enerji miktarını temsil eder.

Cooling_Load; Bağımlı kompaktlık, yüzey alanı, duvar alanı, çatı alanı, genel yükseklik, yönelim, cam alanı ve cam alanı dağılımı gibi çeşitli özelliklere dayalı olarak her bir bina için soğutma yükünü (kWh/m^2 cinsinden) temsil eder. Soğutma yükü, konforlu bir iç mekan sıcaklığını korumak için bir binadan uzaklaştırılması gereken ısı miktarıdır. Bu sütun, 10.90 kWh/m^2 ’lik minimum değerden 48.03 kWh/m^2 ’lik maksimum değere kadar değişir ve ortalaması 24.59 kWh/m^2 ve standart sapması 9.51 kWh/m^2 ’ dir.

Orientation ve glazing_area_distribution alanları kategori cinsinden değerlendirilmiştir. Verilere ait karşılaştırma matrisi Şekil 2’ de gösterilmiştir. Enerji verimliliği veri seti’ nin karşılaştırma matrisi Şekil 2’ de verilmiştir. Verilerin çift grafiği ise Şekil 3’ te verilmiştir.



Şekil 2. Karmaşıklık Matrisi



Şekil 3. Verilerin Çift Grafiği

Değişkenler arasındaki dağılımı ve ilişki kontrol edildiğinde `relative_compactness` ve `surface_area` özelliklerinin ilişkili olduğu ve `surface_area`, `relative_compactness`'tan daha yüksek diğer değişkenlerle korelasyona sahiptir, bu nedenle kolineariteyi önlemek için `surface_area`'yı düşürülmüştür.

`Orientation` ve `glazing_area_distribution` alanları kategorik değerlerden oluştuğu için `heating_load` ve `cooling_load` ile neredeyse hiç korelasyonu yoktur, bu nedenle boyutluluğu azaltmak için bu alanlar karşılaştırma sürecinin dışında tutulabilir.

3.1. Linear Regression Model

Makine öğrenimindeki doğrusal regresyon modelinin amacı, bağımlı değişken (hedef) ile bir veya daha fazla bağımsız değişken (özellik) arasındaki ilişkiyi, bu ilişkiyi en iyi şekilde temsil eden düz bir çizgi (veya çoklu boyutlarda hiper düzlem) uydurarak tahmin etmek veya açıklamaktır.

3.2. Tahmin Sonuçlarının Yorumlanması

Isıtma yükü modeli ve soğutma yükü modelinin ayarlanmış R karesi sırasıyla 0.9003 ve 0.8623'tür ve bu da modelin farklı binaların enerji verimliliğindeki farklılıkların sırasıyla %90.03'ünü ve %86.23'ünü açıklayabileceğini göstermektedir. Modeller verilere iyi uyum göstermekte ve bir konut binasının 6 metriğine dayalı olarak enerji verimliliğini tahmin etmede yararlı olabilir.

Uygun modellerin MAE'si (Ortalama Mutlak Hata) sırasıyla 2.3002 ve 2.4978'dir; bu da enerji verimliliğinin tahmin edilen değerlerinin gerçek değerlerden sırasıyla ortalama 2.3002 ve 2.4978 birim sapacağı anlamına gelir. Bu metrik, uygun modeller ve 6 özellik kullanılarak tahminler yapılırken beklenen hatayı gösterir ve hatanın kullanım durumunda kabul edilebilir olup olmadığını belirlememizi sağlamaktadır.


MSE (Ortalama Karesel Hata) sırasıyla 9.8933 ve 12.2353'tür. Bu metrik, her hatayı kare olarak büyük hataları cezalandırdığı için MAE'den daha büyüktür. MSE, farklı modellerin tahmin performansının istikrarsızlığını gösterebildiği için farklı modellerin performansını karşılaştırırken yararlı olabilir.

RMSE (Ortalama Karesel Hatanın Kökü) sırasıyla 3.1454 ve 3.4979'dur. Bu metrik, RMSE'nin birimini hedef değişkenin birimiyle aynı yapmak için ortalama karesel hatanın karekökünü alır, bu durumda enerji verimliliğidir. Yine de MAE'den daha büyüktür çünkü büyük hataları cezalandırır.

Tablo 5. Tahmin Sonuçları

	Adjusted R2	MSE	RMSE	MAE
Heating load	0.9003	9.8933	3.1454	2.3002
Cooling load	0.8623	12.2353	3.4979	2.4978

Modelin performansını değerlendirdikten sonra, bir konut binasının hangi özelliklerinin enerji verimliliğine en çok katkıda bulunduğunu görmek için özellik önemini kontrol edilmiştir. İlgili kontrol görseli Şekil 4’ te verilmiştir.



Şekil 4. Model Performansının Sıcak ve Soğuk Yük ’ün Karşılaştırması

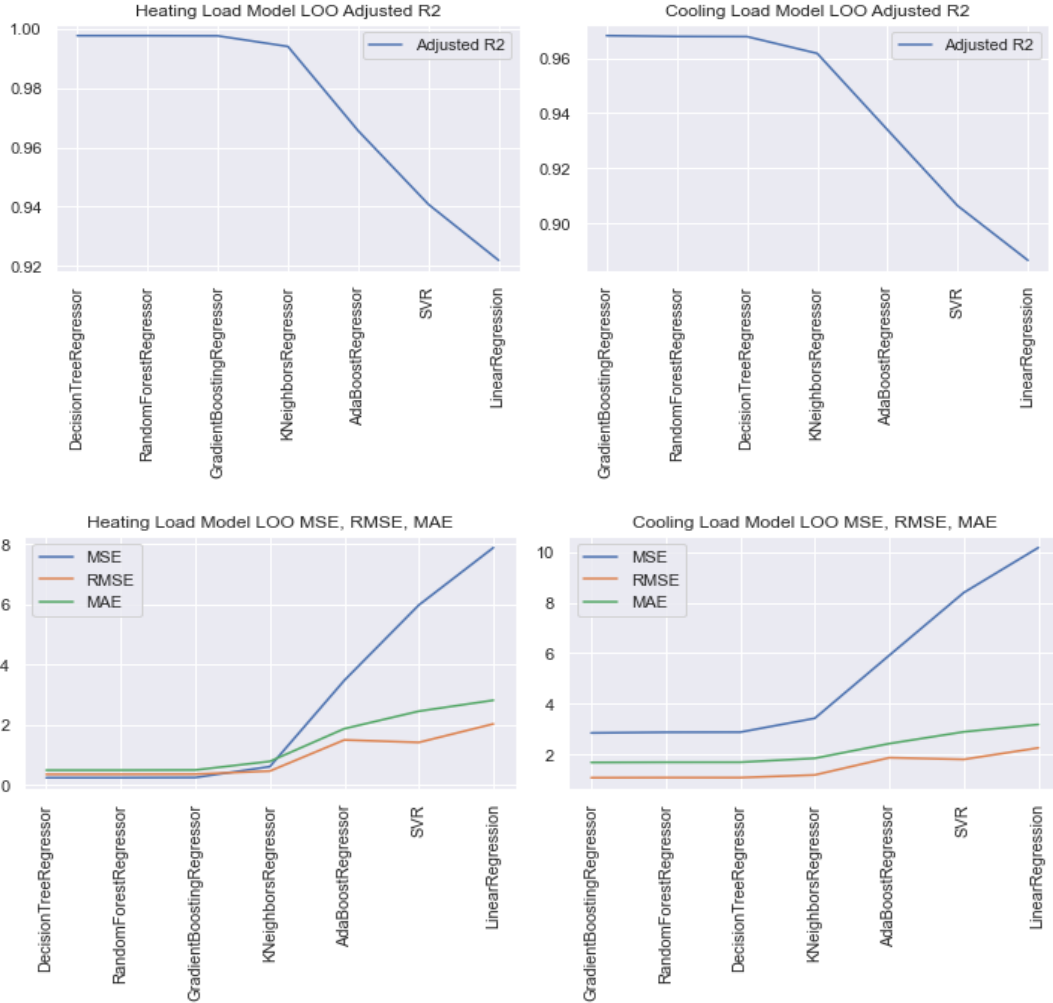
relative_compactness ve roof_area hem ısıtma yükü hem de soğutma yükü üzerinde önemli olumsuz etkiye sahiptir. Overall_height hem ısıtma yükü hem de soğutma yükü üzerinde önemli olumlu etkiye sahiptir. Bu üç özellik enerji verimliliği üzerinde en büyük etkiye sahiptir.

Tablo 6. Isıtma ve Soğutma Yükü

	Heating load model coefficients	Cooling load model coefficients
relative_compactness	-7.0958458730476455	-8.15611490605704
wall_area	-1.3159700922227593	-2.227514344870592
roof_area	-8.234793485188415	-8.970425365072838
overall_height	7.183266594217719	7.131722242939717
glazing_area	2.2416741152751656	1.7540712278958694
glazing_area_distribution	1.020804688621697	0.513058498698021
Heating load model intercept	21.91440595903166	24.170484171322162

Yukarıdaki çift diyagram, özellikler ve hedef değişkenler arasında çok fazla doğrusal ilişki olmadığını ve değişkenlerin normal dağılım göstermediğini gösteriyor, bu nedenle doğrusal regresyon modeli bu veri seti için en iyi seçim algoritma olmayabilir. Enerji verimliliğini tahmin etmek için daha iyi bir model olup olmadığını görmek için Karar Ağacı, Rastgele Orman, Gradient Boosting, Ada Boost, K-En Yakın Komşu, Destek Vektör

Makineleri (SVR) performansları incelenmiştir. Veri seti yalnızca 768 örnek içerdiğinden, çapraz doğrulama yöntemi olarak Leave-One-Out (LOO) kullanmak mümkündür.



Şekil 5. Farklı Algoritmalar Karşısında Tahmin Sonuçlarının Değerleri

Tablo 7. Isıtma Yüğü Model Sonuçları

Model	Heating	LOO_Adj_R2	LOO_MSE	LOO_RMSE	LOO_MAE
1	DecisionTreeRegressor	0.9977	0.2330	0.3457	0.4827
2	RandomForestRegressor	0.9977	0.2337	0.3470	0.4834
3	GradientBoostingRegressor	0.9976	0.2395	0.3514	0.4894
4	KNeighborsRegressor	0.9940	0.6040	0.4560	0.7771
5	AdaBoostRegressor	0.9656	3.4682	1.4889	1.8623
6	SVR	0.9408	5.9727	1.4068	2.4439
7	LinearRegression	0.9219	7.8788	2.0220	2.8069

Tablo 8. Soğutma Yükü Model Sonuçları

Model	Cooling	LOO_Adj_R2	LOO_MSE	LOO_RMSE	LOO_MAE
1	GradientBoostingRegressor	0.9682	2.8537	1.0858	1.6893
2	RandomForestRegressor	0.9679	2.8797	1.0904	1.6970
3	DecisionTreeRegressor	0.9678	2.8842	1.0897	1.6983
4	KNeighborsRegressor	0.9624	3.3747	1.1850	1.8370
5	AdaBoostRegressor	0.9340	5.9163	1.8755	2.4323
6	SVR	0.9064	8.3925	1.8098	2.8970
7	LinearRegression	0.8866	10.1666	2.2634	3.1885

4. SONUÇ

Enerji verimliliği veri seti incelendiğinde, Isıtma yükünü tahmin ederken beklenen hata ortalama 0,3840 birimdir ve soğutma yükünü tahmin ederken beklenen hata ortalama 1.2718 birimdir. Bir konut binasının bu özellikleri, %1.7214’ lük hata yüzdesiyle ısıtma yükünü tahmin etmede daha faydalıdır, soğutma yükünü tahmin ederken ise hata yüzdesi %5.1724’tür.

Test veri kümesinde, Gradient Boosting, Karar Ağacı ve Rastgele Orman mükemmel performansa sahipken, K-En Yakın Komşu çapraz doğrulama sonucuna kıyasla daha kötü performansa sahiptir ve bu da KNN modelinin olası bir aşırı uyum sorununa işaret ettiği gözlenmektedir.

Sonuç olarak, ağaç tabanlı modeller, özellikler ve hedef değişkenler arasındaki doğrusal olmayan ilişkiler nedeniyle bu veri kümesinde doğrusal modellerden daha iyi performans gösterdiği görülmektedir.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması yoktur.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

KAYNAKLAR

- [1] Hong, T., Langevin, J., & Sun, K. (2018, October). Building simulation: Ten challenges. In Building simulation (Vol. 11, pp. 871-898). Springer Berlin Heidelberg.
- [2] Zhao, H. X., & Magoulès, F. (2012). A review on the prediction of building energy consumption. Renewable and Sustainable Energy Reviews, 16(6), 3586-3592.

- [3] Reyna, J. L., & Chester, M. V. (2015). The growth of urban building stock: Unintended lock-in and embedded environmental effects. *Journal of Industrial Ecology*, 19(4), 524-537.
- [4] Foucquier, A., Robert, S., Suard, F., Stéphan, L., & Jay, A. (2013). State of the art in building modelling and energy performances prediction: A review. *Renewable and Sustainable Energy Reviews*, 23, 272-288.
- [5] Zhang, L., Wen, J., Li, Y., Chen, J., Ye, Y., Fu, Y., & Livingood, W. (2021). A review of machine learning in building load prediction. *Applied Energy*, 285, 116452.
- [6] Egwim, C. N., Alaka, H., Egunjobi, O. O., Gomes, A., & Mporas, I. (2024). Comparison of machine learning algorithms for evaluating building energy efficiency using big data analytics. *Journal of Engineering, Design and Technology*, 22(4), 1325-1350.
- [7] Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine learning and deep learning in energy systems: A review. *Sustainability*, 14(8), 4832.
- [8] Yu, Z., Haghighat, F., Fung, B. C., & Yoshino, H. (2010). A decision tree method for building energy demand modeling. *Energy and Buildings*, 42(10), 1637-1646.
- [9] Amasyali, K., & El-Gohary, N. M. (2018). A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, 81, 1192-1205.
- [10] Gonzalez, P. A., & Zamarreno, J. M. (2005). Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. *Energy and buildings*, 37(6), 595-601.
- [11] Dong, B., Cao, C., & Lee, S. E. (2005). Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*, 37(5), 545-553.
- [12] Ekici, B. B., & Aksoy, U. T. (2009). Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, 40(5), 356-362.
- [13] Liang, X., Hong, T., & Shen, G. Q. (2016). Improving the accuracy of energy baseline models for commercial buildings with occupancy data. *Applied energy*, 179, 247-260.
- [14] Mocanu, E., Nguyen, P. H., Gibescu, M., & Kling, W. L. (2016). Deep learning for estimating building energy consumption. *Sustainable Energy, Grids and Networks*, 6, 91-99.
- [15] Reyna, J. L., & Chester, M. V. (2015). The growth of urban building stock: Unintended lock-in and embedded environmental effects. *Journal of Industrial Ecology*, 19(4), 524-537.

- [16] Wei, Y., Zhang, X., Shi, Y., Xia, L., Pan, S., Wu, J., ... & Zhao, X. (2018). A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews*, 82, 1027-1047.
- [17] Ciulla, G., & D'Amico, A. (2019). Building energy performance forecasting: A multiple linear regression approach. *Applied Energy*, 253, 113500.
- [18] Yang, S., Wan, M. P., Chen, W., Ng, B. F., & Dubey, S. (2020). Model predictive control with adaptive machine-learning-based model for building energy efficiency and comfort optimization. *Applied Energy*, 271, 115147.
- [19] <https://www.kaggle.com/datasets/ujjwalchowdhury/energy-efficiency-data-set/data>
- [20] James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning* (Vol. 112, p. 18). New York: springer.
- [21] Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- [22] Hastie, T. (2009). *The elements of statistical learning: data mining, inference, and prediction*.



Süleyman Demirel Üniversitesi
YEKARUM e-DERGI
(Journal of YEKARUM)



Cilt 9, Sayı 2, 128-146, 2024
E - ISSN:1309-9388

Machine Learning-Based Energy Forecasting for PV Power Plants

Muhammed TAMAY¹, Gul Fatma TURKER^{2*}

¹ Suleyman Demirel University, Graduate School of Natural and Applied Sciences, Department of Computer Engineering, 3200, Isparta, Türkiye, (ORCID: 0009-0006-5872-5866), mhmmdtamay@gmail.com

^{2*} Suleyman Demirel University, Faculty of Engineering, Department of Computer Engineering, 3200, Isparta, Türkiye (ORCID: 0000-0001-5714-5102), gulturker@sdu.edu.tr

(İlk Geliş Tarihi 23/11/2024 ve Kabul Tarihi 18/12/2024)

ABSTRACT

As the global population continues to grow and technological advancements progress, energy demand is becoming increasingly noticeable worldwide. Solar energy, which is among the sustainable energy sources to reduce the environmental impact of fossil fuels, has a critical role in the global energy transition. Energy generation forecasts play a vital role in supply-demand balance, grid stability and cost optimization. Moreover, accurate and reliable generation forecasts are essential to facilitate the integration of renewable energy sources and improve the efficiency of energy systems. In this study, generation data from April 2022 to April 2024 for a solar power plant in Denizli province and weather data obtained from Solcast API service are used. The performance of machine learning algorithms such as XGBoost, Extra Trees, k-Nearest Neighbors (KNN), Gradient Boosting, Random Forest and Linear Regression are evaluated. The results show that the KNN model outperforms the other algorithms with a Mean Square Error (MSE) of 112.282, Root Mean Square Error (RMSE) of 10.596, Mean Absolute Error (MAE) of 4.094 and R² score of 0.969. This study contributes to a more reliable estimation of solar power generation, facilitating the integration of renewable energy sources and offering significant potential for the optimization of energy management systems.

Keywords: *PV Plants, Solar Power Generation Forecasting, Machine Learning, Renewable Energy*

PV Enerji Santralleri için Makine Öğrenmesi Tabanlı Enerji Üretim Tahmini

ÖZET:

Dünya nüfusu ve teknolojik gelişmelerin sürekli artmasıyla birlikte, enerji talebi tüm dünyada giderek daha fazla hissedilmektedir. Fosil yakıtların çevresel etkilerini azaltmak amacıyla sürdürülebilir enerji kaynakları arasında yer alan güneş enerjisi, küresel enerji dönüşümünde kritik bir öneme sahiptir. Enerji üretim tahminleri, arz-talep dengesi, şebeke stabilitesi ve maliyet optimizasyonu açısından hayati bir rol oynamaktadır. Ayrıca, doğru ve güvenilir üretim tahminleri, yenilenebilir enerji kaynaklarının entegrasyonunu kolaylaştırmak ve enerji

* Corresponding author E-mail: gulturker@sdu.edu.tr

sistemlerinin verimliliğini artırmak için gereklidir. Bu çalışmada, Denizli ilindeki bir güneş enerji santraline ait Nisan 2022 ile Nisan 2024 arasındaki üretim verileri ve Solcast API servisinden elde edilen hava durumu verileri kullanılmıştır. XGBoost, Extra Trees, k-Nearest Neighbors (KNN), Gradient Boosting, Random Forest ve Linear Regression gibi makine öğrenmesi algoritmalarının performansı değerlendirilmiştir. Elde edilen sonuçlar, KNN modelinin Ortalama Kare Hata (MSE) değeri 112.282, Kök Ortalama Kare Hata (RMSE) değeri 10.596, Ortalama Mutlak Hata (MAE) değeri 4.094 ve R^2 skoru 0.969 ile diğer algoritmalarından daha iyi performans gösterdiğini ortaya koymaktadır. Bu çalışma, güneş enerjisi üretiminin daha güvenilir bir şekilde tahmin edilmesine katkıda bulunarak yenilenebilir enerji kaynaklarının entegrasyonunu kolaylaştırmakta ve enerji yönetim sistemlerinin optimizasyonu için önemli bir potansiyel sunmaktadır.

Anahtar Kelimeler: PV Santraller, Güneş Enerjisi Üretim Tahmini, Makine Öğrenmesi, Yenilenebilir Enerji

1. INTRODUCTION

With growing population and production, energy demand is constantly increasing worldwide. As the environmental impacts of fossil fuels have become increasingly evident, the importance of renewable energy sources has increased. According to data from the Turkish Electricity Transmission Company (TEIAS), Turkey's total electricity generation capacity will reach 114,342 MW by October 2024, of which 67,223 MW will be generated from renewable energy sources [1]. Within the power generated from renewable sources, solar power plants (SPPs) have a total installed capacity of 18,839 MW. Turkey's National Energy Plan, published in 2022, aims to increase solar power by 3,500 MW per year until 2035, bringing the total installed capacity to 52.9 GW [2].

The increase in the number of SPPs makes the production forecast of the energy to be generated from these plants and the safe management of the system critical for grid security. The annual variability in seasonal patterns caused by global warming has made day-ahead production forecasts based on short-term weather predictions increasingly valuable. Additionally, consistent and accurate forecasting not only reduces costs and uncertainties but also prevents potential penalties arising from discrepancies between forecasted and actual production, thereby protecting plant investors from potential financial losses [3]. The generation capacity of SPPs is highly dependent on weather conditions; the amount of generation is affected by various meteorological factors such as temperature, solar radiation, cloudiness, humidity and wind speed. In this context, the accuracy of models used for power generation forecasting relies on an effective assessment of these factors [4].

Machine learning models are playing an increasingly important role in forecasting renewable energy production. By predicting fluctuations in power generation, these models contribute to maintaining grid stability, optimizing costs and efficient integration of renewable energy sources. In particular, production forecasting of photovoltaic (PV) systems has become critical as this technology has become more accessible and widespread. Machine learning in solar power generation forecasting offers high accuracy rates and better performance can be achieved by comparing or combining different models. For example, in one study, an approach using the outputs of deep learning models, Artificial Neural Networks (ANN) and Long Short Term Memory (LSTM), as inputs for the XGBoost model improved the R^2 value by 10%-12% compared to other methods [5]. Machine learning models are widely used for short-, medium- and long-term forecasting of PV power generation, and the performance of different algorithms in power generation forecasting is continuously evaluated with data generated under various conditions.

In his study, Tsai (2023) emphasized that models developed with the integration of meteorological data give more successful results in short-term PV generation forecasts, while the accuracy rate of hybrid models is close to 90% [4]. In a study conducted in Morocco, six different machine learning algorithms, namely Support Vector Regressor (SVR), ANN, Decision Trees (DT), Random Forest (RF), Generalized Additive Model (GAM) and XGBoost, were trained using solar energy production data and meteorological parameters and the effectiveness of ANN in modeling complex and non-linear relationships was emphasized [6].

In the study where a deep and machine learning-based ConvLSTM1D model was proposed for the prediction of residential-scale PV generation, models such as XGBoost, RF, SVR, Multilayer Perceptron (MLP) and LSTM were evaluated, and it was stated that RF and ConvLSTM1D outperformed the others [7]. In a similar study, an LSTM-based model was found to perform better than other conventional methods for energy production prediction in PV systems [8].

In a study where a total of 64 different machine learning algorithms were used to predict the energy production of a PV system on a university campus in Manchester to reduce the carbon footprint of buildings, it was reported that the RF algorithm provided higher accuracy compared to other methods and was an effective tool in energy management [9]. AlShafeey et

al. (2021), using Multiple Regression (MR) and ANN techniques with three years of PV generation data, examined how the choice of input data used in PV power generation forecasting affects model performance and stated that artificial neural networks provide higher accuracy than MR models regardless of the input method [10].

In another study investigating the impact of different meteorological data on PV generation forecasting, Lasso Regression, Support Vector Machines (SVM), RF and Linear Regression models were used on three years of meteorological and PV generation data in the USA and the Netherlands, and it was stated that temperature, humidity and cloud cover are the most critical factors in energy generation forecasting [11]. Mahmud et al. (2021) compared various machine learning algorithms for PV power generation forecasting in the Alice Springs region of Australia and examined machine learning methods for short and long-term forecasts to reduce fluctuations in generation. At the end of their study, they reported that the RF algorithm provided the highest accuracy in PV generation forecasting and data normalization significantly improved the forecasting performance [12].

Nicoletti and Bevilacqua [13], aiming to facilitate energy production forecasts of individual PV panel users, developed two different feed-forward neural network models using numerical weather forecast data and tested the accuracy of these models with experimental data. In the first model, detailed radiation data were used, while in the second model, more easily accessible general weather data were used. As a result of the study, the models obtained accuracy values of R^2 0.879 and RMSE 10.5%, respectively. Similarly, Buonanno et al. [14] examined the combination of linear models, LSTM, XGBoost and LightGBM for energy forecasting in new PV power generation plants with limited data and found that linear models provide lower error rates than other methods.

Focusing on long-term forecasting of solar energy production, Sedai et al. [15] compared statistical (ARIMA), machine learning (SVR), deep learning (LSTM, GRU, CNN) and ensemble models and concluded that the RF model provided 50% higher accuracy compared to other methods. Similarly, Khadke et al. [16] achieved high accuracy values such as maximum R^2 0.87 and MSE 0.002 with the machine learning-based prediction model they developed using weather data. Andi A. H. Lateko et al. [17], working with data from Zhangbin Industrial Zone in Taiwan, proposed a regression-based ensemble method and achieved a 20%

improvement in MRE compared to a single RF model. These studies show that different types of data and modeling techniques play a critical role in PV power generation forecasting.

Voyant et al. (2017) evaluated various machine learning techniques, including ANN, SVM, decision trees, KNN, and hybrid methods. Their study concluded that single-model approaches such as SVR, ANN, KNN, regression trees, boosting, and random forests produced better predictions compared to classical regression models. They also noted that further research is needed for the KNN algorithm to serve as an alternative [18].

Su et al. (2019) evaluates ten machine learning algorithms, including six neural networks and four intelligent methods, for short-term photovoltaic forecasting. A novel hybrid prediction approach is introduced, integrating the top-performing models to improve forecasting accuracy. Among the tested methods, the Nonlinear Autoregressive Neural Network with Exogenous Inputs (NARXNN) achieved the highest performance among neural networks, while Random Forest (RF) stood out among intelligent algorithms. Their hybrid model demonstrated superior accuracy, achieving the lowest overall normalized RMSE (nRMSE) of 6.74%, underscoring its effectiveness in enhancing forecasting precision [19].

This study aims to develop a forecasting model using past production and weather data through machine learning algorithms and to predict energy production based on future weather forecasts using this model. The main objective of this study is to improve the accuracy of power generation forecasting by improving commonly used machine learning models with hyperparameter optimizations and to identify the most appropriate modeling approach. By presenting an innovative approach to improve the accuracy of machine learning methods in solar photovoltaic (PV) generation forecasting, this study addresses a critical need, especially in countries like Turkey that are rapidly expanding their renewable energy capacity. Generation forecasting of PV systems is of great importance for both maintaining grid stability and optimizing energy management. Although there are many studies in the literature where accuracy is improved by integrating meteorological data, combining different machine learning algorithms and using hybrid models, the capacity of existing models to adapt to specific meteorological conditions and geographical constraints is often limited. In this context, we aim to improve the accuracy of power generation forecasting with machine learning models developed using real-time PV generation data collected in Turkey and detailed meteorological

parameters. The study makes a significant contribution to the literature by not only optimizing short- and medium-term forecasts, but also by comparing the performance of different models and providing an applicable framework for energy management.

2. MATERIAL and METHODS

The flowchart of the system designed in this study, which uses machine learning methods for accurate prediction of energy production in photovoltaic solar power plants, is given in Figure 1. After data collection, data preprocessing was performed, data from different sources were combined, tested with machine learning models and the most appropriate prediction model was determined by comparing the results obtained.




Figure 1. Flowchart of the designed system

2.1. Dataset and Preprocessing

The production data used in this study was obtained from a SMA brand inverter device with a capacity of 1 MW. From the raw inverter data, the records with state codes 512 and 513, which contain the states in which the inverter is operating properly, were selected and the inverter dataset was created by checking for missing data. The maximum value that the inverter can generate in 5 minutes was calculated by equation (1).

$$(1000/60) \times 5 \cong 83,33 \text{ (kW)} \quad (1)$$

In addition, weather data with 15-minute periods were obtained from Solcast (weather forecasting service). These data include meteorological parameters such as solar radiation,

temperature and wind speed. Table 1 shows the weather parameters used with their descriptions and units.

Erroneous and larger than calculated production values were identified and linear interpolation methods were applied on these values. In order to harmonize the production data with the weather data, the production data were converted into 15-minute periods and the values produced in each period were summed.

Weather parameters include data with different units. For the data with angular features, sine and cosine transformations were applied to enable the model to better learn the periodic information and new features were added to the dataset with these transformations. In addition, all other numerical features were normalized by applying the StandardScaler method.

The successful application of machine learning models is highly dependent on the quality and accurate preprocessing of the data. These processes directly affect the accuracy and performance of energy production forecasting models.

Table 1. Weather dataset parameters

Parameter	Description	Unit
air_temp	Air temperature measured at a height of 2 meters	°C
albedo	Indicates how much sunlight the surface reflects	value between 0-1
azimuth	The azimuth of the sun, measured clockwise from the north	Degree (°)
cloud_opacity	Indicates how much sunlight is blocked by clouds	% (percent)
dewpoint_temp	Indicates the temperature point at which dew starts to form	°C
dhi	Diffuse Horizontal Irradiance, diffuse solar radiation reaching the surface horizontally	W/m ²
dni	Direct Normal Irradiance, solar radiation reaching the surface directly	W/m ²
ghi	Global Horizontal Irradiance, total solar radiation reaching the surface horizontally	W/m ²

gti	Global Tilted Irradiance, total solar radiation reaching a tilted surface	W/m ²
precipitation_rate	Rainfall rate, the amount of precipitation that falls in a given period of time	mm/hour
relative_humidity	Refers to the relative humidity at 2 meters height	% (percent)
surface_pressure	Surface pressure, atmospheric pressure value	hPa (hektopascal)
wind_speed_10m	Wind speed, measured at a height of 10 meters	m/s
zenith	The zenith angle of the sun, the angle formed by the sun's rays with the earth's surface	Degree (°)

Proper data preparation facilitates the model learning process, reduces the risk of over-learning and helps the model to make more reliable predictions. Standardized data contributes to more effective optimization of weights during model training. Furthermore, well-prepared datasets for energy forecasting significantly improve the accuracy of forecasting [12].

After the initial preprocessing on the inverter and weather datasets, the data were merged according to time columns, eliminating the time differences between the two datasets and making them ready for model training. Following the data preprocessing step, the main dataset, formed by merging the inverter and weather datasets, comprises 70,127 rows of data spanning from 2022-04-01 04:30:00 to 2024-03-31 13:45:00, with 15-minute intervals. This dataset is split into 80% for training and 20% for testing.

2.2. K-Nearest Neighbors

The K-Nearest Neighbors (KNN) algorithm is a machine learning method used in classification and regression problems that groups data points based on the characteristics of neighboring samples. It is especially preferred in renewable energy forecasting, where historical data is used to predict future trends. KNN is an effective method for solar and wind energy forecasting due to its simple structure and high accuracy rates in various data sets. In one study, KNN was used to predict solar and wind power generation, and 90% accuracy was achieved, especially in daily forecasts. It is stated that these results will provide a great advantage in terms of increasing the security of energy grids and reducing costs [20].

2.3. XGBoost

XGBoost (eXtreme Gradient Boosting) is a powerful machine learning algorithm based on gradient boosting decision trees. With its fast computational capability and robustness against overlearning, it provides effective forecasting results on large data sets. XGBoost is especially preferred for PV power generation forecasts. In a study, the XGBoost model was used in combination with time series such as ANN and LSTM for solar energy forecasting with an R^2 score of 98% and a low error rate compared to other algorithms [5].

2.4. Random Forest

Random Forest is a powerful model that combines multiple decision trees to achieve both high accuracy in energy prediction and reduce the risk of overlearning. Each tree is trained on a random subset of the dataset and the forecast is made by averaging these trees. RF is widely used in solar and wind power generation forecasting due to its high accuracy and robustness to overlearning. Different tree models along with RF have been tested for short-term wind power forecasting and found to be robust techniques [23].

2.5. Extra Trees

Extra Trees is similar to Random Forest, but differs in that it chooses the split points in each decision tree completely at random. This randomization strategy introduces more diversity into the model, reducing the risk of overlearning and resulting in highly accurate forecasts. The Extra Trees algorithm has been observed to provide consistent forecast performance, especially under different meteorological conditions and across a variety of data sets [21]. In addition, it has been reported that this model has a faster computational process compared to other tree-based methods and improves forecast accuracy.

2.6 Gradient Boosting

Gradient Boosting, as an ensemble model of weak learners, improves overall performance by learning and reducing the errors of the previous model at each iteration. Although it is generally highly accurate, the computational cost can be high. However, it can be highly effective on time series data used in solar energy forecasting. The Gradient Boosting model was evaluated

together with other decision tree models and it was observed that the ensemble model provided a higher prediction accuracy compared to other boosting algorithms used alone [22].

2.7. Linear Regresyon

This model allows the prediction of a dependent variable based on a given independent variable or set of variables. It is widely used in power generation forecasting, such as PV power forecasting, due to its simplicity and easy applicability. It offers high performance and improves the interpretability of forecasts, especially when the linear relationship between the dependent and independent variables is evident. In a study conducted by H. Sarper et al. in 2021, linear regression models were used to predict the daily energy production of three different PV systems. Trained with four years of data, it was emphasized that the model can provide additional benefits when combined with other advanced forecasting methods [24].

2.8. Evaluation Parameters

The metrics used to evaluate the performance of machine learning models - Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and R-Squared (R^2) are critical for measuring the accuracy and bias of predictions. Each of these metrics helps determine which model is better by analyzing different aspects of model performance.

2.8.1. Mean Squared Error

MSE is the mean of the squares of the differences between predicted values (\hat{y}) and actual values (y). Its ability to highlight large errors is useful in identifying models with extreme bias. It measures the overall error of the model, but the results are in terms of the square of the prediction unit.

Mathematically, it is expressed as shown in function 2.

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

2.8.2. Root Mean Squared Error

It is calculated by taking the square root of the MSE. This metric allows the error to be expressed in the original units. It presents the results in the same units as the predicted variable and is

often preferred when evaluating prediction accuracy. It is mathematically defined in function 3.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

2.8.3. Mean Absolute Error

It is the average of the absolute values of the differences between predicted and actual values. Although it is not as sensitive as MSE or RMSE in terms of assessing the magnitude of error, it is less sensitive to large errors because it measures errors directly in absolute value. It is therefore highly interpretable and not affected by extreme deviations. It is expressed mathematically in function 4.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

2.8.4. R-Squared

It is a measure of the proportion of a model's independent variables that can explain the dependent variable. It expresses the overall performance of the model with a single ratio and takes a value in the range 0-1. The closer the results are to 1, the higher the explanatory power of the model. Mathematically, it is calculated as in function 5 [6].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

3. RESULTS and DISCUSSION

In this study, XGBoost, Extra Trees, k-Nearest Neighbors (KNN), Gradient Boosting, Random Forest and Linear Regression machine learning models are evaluated and their performances are compared for the prediction of photovoltaic (PV) energy generation. Hyperparameter

optimization plays a crucial role in determining the performance of machine learning models. Effectively managing this process significantly enhances model accuracy while also reducing training costs, providing an advantage [25]. In model training, the most appropriate hyperparameter values were determined for each algorithm with the RandomizedSearchCV method. The best tested hyperparameter values are presented in Table 2. Techniques such as data normalization, sine and cosine transformations increased the learning capacity of the models and improved the overall accuracy.

Table 2. Best hyperparameter values of the models used

Model	Hyperparameter	Values
KNN	weights	distance
	p	1
	n-neighbors	5
	leaf-size	50
	algorithm	kd_tree
XGBoost	subsample	0.6
	reg-lambda	2
	reg-alpha	0.1
	n-estimators	300
	min-child-weight	1
	max-depth	9
	learning-rate	0.05
	gamma	0.1
	colsample-bytree	0.8
Gradient Boosting	subsample	1.0
	n-estimators	500
	min-sample-split	2
	min-samples-leaf	2
	max-depth	9
	loss	squared_error

	learning-rate	0.1
	alpha	0.95
	validation_fraction	0.2
Random Forest	n-estimators	500
	min-samples-split	5
	min-samples-leaf	1
	max-features	sqrt
	max-depth	20
Extra Trees	n-estimators	100
	min-samples-split	2
	min-samples-leaf	1
	max-features	log2
	max-depth	30
Linear Regression	-	-

This optimization process contributed to a significant increase in accuracy and reduced prediction errors, especially in the KNN model. The model scores obtained using the test data are presented in Table 3 to evaluate in detail the performance of the machine learning algorithms in energy production forecasting. In this table, MSE, RMSE, MAE and R² metrics are given for each model. It is seen that the KNN model has the lowest error rates and the highest R² score compared to the other models. Especially the low RMSE value shows that the production values predicted by KNN are very close to the actual values and that it strongly models the relationship between the dependent variable and the independent variables. KNN algorithm stands out with its high accuracy rates. The scores obtained for the KNN model are given in table3 as follows: MSE value 112.282, RMSE value 10.596, MAE value 4.094 and R² score 0.969.

Table 3. Prediction scores of the models using test data

Model	MSE	RMSE	MAE	R2
KNN	112.282	10.596	4.094	0.969
Gradient Boosting	125.604	11.207	4.344	0.965

XGBoost	131.177	11.453	4.398	0.964
Extra Trees	148.614	12.190	4.611	0.959
Random Forest	150.619	12.272	4.580	0.958
Linear Regression	197.996	14.071	6.699	0.94

One-day production prediction scores with test data are presented in Table 4. Similarly, the KNN algorithm is found to be more accurate than the other algorithms, although it produces lower scores with a small deviation from its score in Table 3. These tables show the performance advantages of different models in a comparative perspective.

A comparison of the actual and predicted values using test data is presented in Figure 2 to visualize the success of the model predictions. The graph shows that while acceptable predictions are obtained in the tested models, the actual and predicted values of the KNN model are quite close to each other, the deviations are minimal and the model generally predicts the data points accurately. This suggests that the model not only improves the overall forecast accuracy but also effectively models production fluctuations.

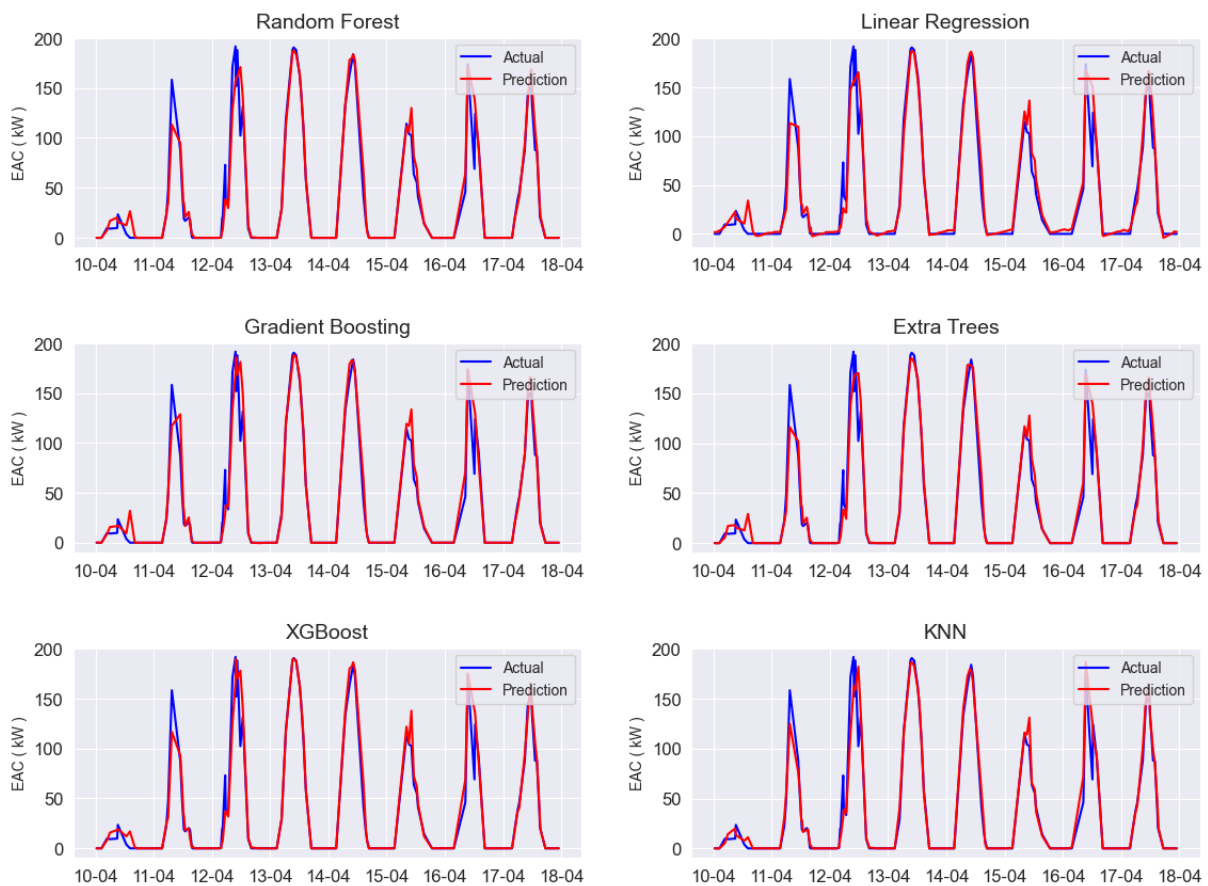


Figure 2. Actual and predicted value comparison graph with test data

This study has showed the potential of machine learning methods in solar power generation forecasting and has shown that the KNN model in particular stands out for its high success rate in this field. The findings provide a valuable framework for optimizing energy management and enhancing grid stability by enabling reliable energy forecasts for PV systems. Future studies may offer the opportunity to further generalize these results with larger datasets and testing in different geographical regions.

This study examines the performance of machine learning models for the prediction of photovoltaic power generation using generation data collected from a 1 MW solar power plant over a two-year period and meteorological data obtained from the Solcast API service. In the study, the effects of important meteorological parameters such as temperature, irradiance, humidity, wind speed on power generation forecasting are considered and various machine learning algorithms are tested. The KNN algorithm showed the best performance compared to other algorithms with 96% R^2 score, 112.282 MSE, 10.596 RMSE and 4.094 MAE. The quality of the data used plays an important role in the performance of machine learning models. In this study, a careful data preprocessing process was applied using two years of datasets with detailed parameters and the accuracy of the models was improved. In particular, harmonization of production and weather data, modeling of periodic features with angular transformations and other scalings have contributed significantly to forecast accuracy. Moreover, the hyperparameter optimization further improved the overall performance of the models.

Similarly, in a study focused on wind farm production forecasting, the KNN algorithm was proven to be a robust predictive model for short-term wind power calculations, achieving an R^2 score of 97% [23]. In another study comparing 24 different machine learning models, the high sensitivity of the KNN algorithm to hyperparameters was emphasized, with findings indicating that proper optimizations allowed it to outperform many other models [21]. In a study on radiation estimation for solar power plants, Uğuz et al. (2019) tested ANN, Multiple Linear Regression (MLR), and KNN algorithms. As a result of their research, they concluded that the ANN algorithm produced the best accurate estimates with an R^2 score of 0.979 [26].

In conclusion, the findings revealed the potential of KNN in solar power generation forecasting models, especially in providing reliable forecasts. Such forecasting models offer

important contributions for more efficient management of energy systems and integration of renewable energy sources.

4. CONCLUSION

This study presents an in-depth analysis of machine learning algorithms for solar power plant production forecasting, utilizing an original dataset comprising real-time production data and comprehensive meteorological parameters collected from a solar power plant located in Denizli, Turkey. The uniqueness of the dataset provides a significant contribution by reflecting real field conditions and enabling an objective evaluation of the performance of various algorithms, thereby enhancing the accuracy of prediction systems. The models examined included XGBoost, Extra Trees, KNN, Gradient Boosting, Random Forest and Linear Regression. Among these models, the KNN model performed the best with 96% R² score, 112.282 MSE, 10.596 RMSE and 4.094 MAE. These results demonstrate the effectiveness of KNN in providing accurate and reliable predictions. The research contributes to the importance of accurate PV generation forecasting in the field of renewable energy, especially in rapidly growing markets such as Turkey. Improving forecast accuracy through hyperparameter optimizations and model comparisons provides a robust framework for optimizing energy management systems and ensuring grid stability. The integration of real-time meteorological data and comparative analysis of machine learning models provide valuable scientific contributions towards the development of renewable energy integration. This study not only improves short and medium-term forecasts, but also paves the way for future research on hybrid and adaptive models that adapt to different meteorological and geographical conditions.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması yoktur.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

REFERENCES

- [1] Enerji Ajansı, "Türkiye'nin Kurulu Gücü (Ekim 2024)," 2024. [Online]. Available: <https://enerjiajansi.com.tr/turkiyenin-kurulu-gucu/>. [Accessed: Nov. 21, 2024].

- [2] T.C. Ministry of Energy and Natural Resources, *Turkey National Energy Plan*, Ankara, Turkey, 2022.
- [3] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison, and F. Antonanzas-Torres, "Review of photovoltaic power forecasting," *Solar Energy*, vol. 136, pp. 78-111, 2016.
- [4] W.-C. Tsai, C.-S. Tu, C.-M. Hong, and W.-M. Lin, "A review of state-of-the-art and short-term forecasting models for solar PV power generation," *Energies*, vol. 16, no. 14, p. 5436, 2023.
- [5] W. Khan, S. Walker, and W. Zeiler, "Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach," *Energy*, vol. 240, p. 122812, 2022.
- [6] Y. Ledmaoui, A. E. Maghraoui, M. E. Aroussi, R. Saadane, A. Chebak, and A. Chehri, "Forecasting solar energy production: A comparative study of machine learning algorithms," *Energy Reports*, vol. 10, pp. 1004–1012, 2023.
- [7] S. Cantillo-Luna, R. Moreno-Chuquen, D. Celeita, and G. Anders, "Deep and machine learning models to forecast photovoltaic power generation," *Energies*, vol. 16, no. 10, p. 4097, 2023.
- [8] D. K. Dhaked, S. Dadhich, and D. Birla, "Power output forecasting of solar photovoltaic plant using LSTM," *Green Energy and Intelligent Transportation*, vol. 2, no. 5, p. 100113, 2023.
- [9] C. Scott, M. Ahsan, and A. Albarbar, "Machine learning for forecasting a photovoltaic (PV) generation system," *Energy*, vol. 278, p. 127807, 2023.
- [10] M. AlShafeey and C. Csáki, "Evaluating neural network and linear regression photovoltaic power forecasting models based on different input methods," *Energy Reports*, vol. 7, pp. 7601–7614, 2021.
- [11] T. AlSkaif, S. Dev, L. Visser, M. Hossari, and W. van Sark, "A systematic analysis of meteorological variables for PV output power estimation," *Renewable Energy*, vol. 153, pp. 12–22, 2020.
- [12] K. Mahmud, S. Azam, A. Karim, S. Zobaed, B. Shanmugam, and D. Mathur, "Machine learning-based PV power generation forecasting in Alice Springs," *IEEE Access*, vol. 9, pp. 46117–46128, 2021.

- [13] F. Nicoletti and P. Bevilacqua, "Hourly photovoltaic production prediction using numerical weather data," *Energies*, vol. 17, no. 2, p. 466, 2024.
- [14] A. Buonanno et al., "Machine learning and weather model combination for PV energy forecasting," *Energies*, vol. 17, no. 9, p. 2203, 2024.
- [15] A. Sedai et al., "Performance analysis of statistical, machine learning, and deep learning models in long-term forecasting of solar power production," *Forecasting*, vol. 5, no. 1, pp. 256–284, 2023.
- [16] S. Khadke et al., "Predicting active solar power with machine learning and weather data," *Materials Circular Economy*, vol. 5, no. 15, 2023.
- [17] A. A. H. Lateko, H.-T. Yang, and C.-M. Huang, "Short-term PV power forecasting using a regression-based ensemble method," *Energies*, vol. 15, p. 4171, 2022.
- [18] C. Voyant, G. Notton, S. Kalogirou, M. L. Nivet, C. Paoli, F. Motte, and A. Fouilloy, "Machine learning methods for solar radiation forecasting: A review," *Renewable Energy*, vol. 105, pp. 569–582, 2017.
- [19] D. Su, E. Batzelis, and B. Pal, "Machine learning algorithms in forecasting of photovoltaic power generation," in *2019 International Conference on Smart Energy Systems and Technologies (SEST)*, 2019, pp. 1-6.
- [20] T. Ahmad, S. Manzoor, and D. Zhang, "Forecasting high penetration of solar and wind power in the smart grid environment using a robust ensemble learning approach for large-dimensional data," *Sustainable Cities and Society*, vol. 75, p. 103269, 2021.
- [21] D. Markovics and M. J. Mayer, "Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction," *Renewable and Sustainable Energy Reviews*, vol. 161, p. 112364, 2022.
- [22] A. Abdellatif et al., "Forecasting photovoltaic power generation with a stacking ensemble model," *Sustainability*, vol. 14, no. 17, p. 11083, 2022.
- [23] U. Singh, M. Rizwan, M. Alaraj, and I. Alsaidan, "A machine learning-based gradient boosting regression approach for wind power production forecasting: A step towards smart grid environments," *Energies*, vol. 14, p. 5196, 2021.
- [24] H. M. I. and M. L. Sarper, "Prediction of daily photovoltaic energy production using weather data and regression," *Journal of Solar Energy Engineering-Transactions of the ASME*, 2021.

- [25] J. Wu, X. Chen, H. Zhang, L.-D. Xiong, H. Lei, and S. Deng, "Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization," *Journal of Electronic Science and Technology*, vol. 17, pp. 26-40, 2019.
- [26] S. Uğuz, O. Oral, and N. Çağlayan, "PV Güç Santrallerinden Elde Edilecek Enerjinin Makine Öğrenmesi Metotları Kullanılarak Tahmin Edilmesi," *International Journal of Engineering Research and Development*, vol. 11, no. 3, pp. 769–779, 2019.



Süleyman Demirel Üniversitesi
YEKARUM e-DERGI
(Journal of YEKARUM)



Cilt 9, Sayı 2, 147-163, 2024
E - ISSN:1309-9388

Güneş Işınım Verilerine Entropi Yaklaşımıyla Fotovoltaik Sistem Çıkış Gücü Değişiminin İncelenmesi

Ahmet KABUL^{1*}

^{1*} Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Burdur, Türkiye, (ORCID: 0000-0001-9579-2757), ahmetkabal@mehmetakif.edu.tr

(İlk Geliş Tarihi 02/12/2024 ve Kabul Tarihi 18/12/2024)

ÖZET:

Fosil yakıtların neden olduğu problemlerin gün geçtikçe görünür hale gelmesi, yenilenebilir enerji kaynaklarına yönelimi artırmaktadır. Fotovoltaik (PV) güneş panelleri tabanlı elektrik üretim santralleri gerek ülkemizde gerekse de dünyada yenilenebilir enerji kaynakları arasında tercih edilen santral tiplerinden birisidir. PV panel güç kapasitesini tahmin edebilmek ya da panel verimliliğini arttırabilmek amacıyla temel meteorolojik verilerin (sıcaklık, hava açıklığı, nem, rüzgâr, vb.) takibi ve analizi yapılmaktadır. Temel meteorolojik verilerin çeşitliliği ve her bir parametrenin ayrı ayrı değerlendirilmesi panel çıkış güçlerinin ve verimliliklerinin takibini zorlaştırmaktadır. Günümüzdeki çalışmalar temel meteorolojik verilerin güneş ışınım değerleri olan yatay düzlem global ışınım (GHI), direkt normal ışınım (DNI) ve difüz yatay ışınım (DHI) parametrelerini tahmin etme üzerine yoğunlaşmaktadır. Bu çalışmada DNI, DHI ve GHI verilerinin ayrı ayrı analizleri yapılarak hangi verinin panel çıkış gücünü doğrudan etkilediği tespit edilmektedir. Önerilen yöntem ilgili verilerin ortalama değerlerini kullanarak entropi analizi için özellik çıkarımı yapmaktadır. Önerilen yöntemin sonuçları Mendeley Data web sitesinde açık-kaynak olarak sunulan "Solar Panel Data" isimli ve Rajasthan/Hindistan bölgesinden elde edilen verilerin analizi ile test edilmektedir. Analiz sonucunda sıcaklık, hava açıklığı, DNI, DHI ve GHI verilerinin eğim fark açıları PV panel çıkış gücü eğim açıları ile karşılaştırılmaktadır. Elde edilen veriler GHI parametresinin güneş paneli çıkış gücü ile doğrudan ilgili olduğunu göstermektedir.

Anahtar Kelimeler: Fotovoltaik panel çıkış gücü, Direkt normal ışınım, Difüz yatay ışınım, Yatay düzlem global ışınım, Entropi, Fark eğim açıları

Investigation of Photovoltaic System Output Power Variation with Entropy Approach to Solar Radiation Data

ABSTRACT

Since the problems caused by fossil fuels become more visible, the trend towards renewable energy sources increases. Power generation plants based on photovoltaic (PV) solar panels are one of the most preferred types among renewable energy sources both in our country and in the world. Basic meteorological data (temperature, cloud opacity, humidity, wind, etc.) are monitored and analyzed in order to predict PV panel power capacity or increase panel efficiency. The variety of meteorological data and individual evaluation of each parameter make it

* Sorumlu yazar E-mail: ahmetkabal@mehmetakif.edu.tr

difficult to monitor panel output power and efficiency. Current studies focus on predicting the global horizontal irradiance (GHI), direct normal irradiance (DNI) and diffuse horizontal irradiance (DHI) which are basic solar irradiance data. In this study, the parameters of DNI, DHI and GHI are analyzed separately to determine the data which affects the panel output power directly. The proposed method uses the average values of aforementioned data for the process of feature extraction. The results of the proposed method have been tested by analyzing the data obtained from the Rajasthan/India region of “Solar Panel Data”, which is available as open-source on the Mendeley Data website. As a result of the analysis, the slope difference angles of temperature, cloud opacity, DNI, DHI and GHI data are compared with the PV panel output power slope angles. The obtained data show that the GHI parameter is directly related to the solar panel output power.

Keywords: *Photovoltaic panel output power, Direct normal irradiance, Diffuse horizontal irradiance, Global horizontal irradiance, Entropy, Difference slope angles*

1. GİRİŞ

Fosil yakıt rezervlerinin azalması ve çevresel kaygılar, fosil yakıt temelli enerji üretiminin geleceğini de sorgulamaya açmaktadır. Yenilenebilir enerji kaynakları çevre dostu enerji üretiminin önemli çözümlerinden bir tanesidir [1]. Yenilenebilir enerji kaynakları; güneş enerjisi, rüzgâr enerjisi, hidroelektrik enerji, biyokütle enerjisi, jeotermal enerji olarak günümüzde tercih edilmekte ve mevcut enerji talebinin karşılanmasında giderek artan oranda söz sahibi olmaktadır [2]. Yenilenebilir enerji kaynakları, çevresel etkileri ve sürdürülebilirlik çözümleri göz önüne alındığında temiz enerji kaynakları olarak da adlandırılmaktadır [3]. Uluslararası Enerji Ajansı verilerine göre 2020 yılında yaklaşık olarak her 1 birimlik temiz enerji yatırımına karşılık 1,23 birimlik fosil yakıt temelli enerji yatırımı yapılırken; bu durum 2023 yılı için yaklaşık her 1 birimlik temiz enerji yatırımına karşılık 0,6 birimlik fosil yakıt temelli enerji yatırımı olarak gerçekleşmiştir [4].

Güneş, Dünya için tükenmez bir enerji kaynağı olarak araştırmacıların ilgisini çekmektedir. Fotovoltaik (PV) güneş panelleri, güneş enerjisini elektrik enerjisine çevirerek yenilenebilir enerjinin kullanımına aracılık etmektedir. Güneş tarafından iletilen enerjinin PV paneller ile hasatında elde edilecek enerji miktarı farklı parametrelere (iklim, coğrafi konum, ışınım miktarı, vb.) göre değişiklik göstermektedir. Güneşten elde edilen yıllık enerjinin %1,25’i ($\approx 5 \cdot 10^4$ EJ) hasat edebilecek bir formda olmasına rağmen, solar enerji hasadında ulaşılan güncel değerler, bu yüzdenin çok uzağındadır [5]. Buna rağmen PV panellerin kullanım oranları gün geçtikçe artmaktadır. Son 20 yılda PV kapasitesinin kW seviyelerinden MW mertebesine yükseldiği yakın bir gelecekte de bu kapasitenin TW boyutlarına ulaşacağı öngörülmektedir [6]. Giderek yaygınlaşan PV panel tabanlı enerji tarlalarının kurulum

aşamasında birçok meteorolojik parametre birlikte değerlendirilerek elde edilebilecek enerji kapasitesi doğru bir şekilde tahmin edilmeye çalışılmaktadır [7].

Sıcaklık, nem, rüzgâr hızı gibi temel meteorolojik verilerin yanında solar ışınım verilerinin de doğru olarak yorumlanabilmesi enerji kapasitesinin belirlenmesinde ve tahmin edilmesinde oldukça önemlidir. Ancak solar ışınım verilerinin anlık olarak değişmesi bu verilerin sağlıklı yorumlanmasını zorlaştırmaktadır [8]. Ulusal Güneş Işınımı Veri Tabanı (NSRDB)’nda açık-kaynak olarak sunulan verilerde ışınım bilgilerinin en yaygın kullanılan üç ölçümüne yer verilmektedir. Bu ölçümler; yatay düzlem global ışınım (GHI), direkt normal ışınım (DNI) ve difüz yatay ışınım (DHI) bilgilerini içermektedir [9].

Temel meteorolojik verilerin güneş paneli gücü üzerindeki etkilerinin incelendiği çalışmalara literatürde sıklıkla rastlanmaktadır. Tripathi ve arkadaşları nem verisinin PV panel performansı üzerindeki etkilerini inceledikleri çalışmada panelin bulunduğu ortamın nemini farklı seviyelerde kurgulayarak, panel çıkış gerilimini ve akımını ölçmüşlerdir [10]. Güven tarafından 2022 yılında Denizli/Türkiye ilinde yapılan bir çalışmada PV panel yüzey sıcaklığının panel çıkış gücü ve verimi üzerindeki etkileri incelenmiştir [11]. Kirpichnikova ve Maksumov, PV panellerin ortam sıcaklığının fazlaca yükseldiği durumlarda çıkış güçlerinin olumsuz etkilendiğini ortaya koymuşlardır. Panel yüzey sıcaklıklarının ortam sıcaklığına dirençli hale gelmesi için gereken işlemleri de çalışmalarında paylaşmışlardır [12]. Adak ve arkadaşları 2019 yılında yaptıkları çalışmada benzetim programı aracılığıyla PV panel modellemesi yaparak, panel çıkış gücünün sıcaklık ve ışımaya bağlı olarak değişimlerini analiz etmişlerdir. Sıcaklık parametresinin PV panelin monokristal ve polikristal yapıları için ayrı ayrı simüle etmişlerdir. Çalışmalarında PV panele ait gerekli analitik verilerin çıkarımı Sosyal Bilimler için İstatistik Paketi (SPSS) programı ile yapılmıştır. Işınım durumu değişimi PV panel üzerinde kısmi gölgelenme durumu simüle edilerek yapılmıştır [13]. Aswati ve arkadaşları sıcaklık ve ışınım verilerinin PV sistemler üzerindeki etkilerini MATLAB/Simulink programı üzerinden incelemişlerdir. İlgili parametrelerin değişimlerini Alternatif Akım (AC) ve Doğru Akım (DC) yüklerinde maksimum panel gücü üzerinden yorumlamışlardır [14]. Mustafa ve arkadaşları PV paneller üzerinde doğal koşullar sonrası meydana gelen kirliliğin (toz, su damlaları, kuş pislikleri, vb.), panel çıkış gücü üzerindeki etkilerini incelemişlerdir [15]. Dhaundiya ve Atsu, rüzgârın PV panellerin yüzey sıcaklığı üzerindeki etkisini analiz etmişlerdir. Analiz sonuçlarını enerji ve hidrodinamik denklemler ile çerçevesiz ve çerçevesiz PV modül kullanan solar sistemler üzerinden ifade etmişlerdir [16].

Leow ve arkadaşları rüzgâr hızının PV panel üzerindeki etkisini Perlis/Malezya bölgesinde analiz etmişlerdir. Belirli saatlerde PV panel çıkış güçlerini rüzgârlı ve rüzgârsız durumlar üzerinden kaydetmişlerdir [17]. Başay ve arkadaşları, 835 m yükseklikte yapılan çalışmada nemin, hava açıklığının, sıcaklığın ve Ultraviyole (UV) ışınımının PV panel üzerindeki etkilerini modül ömrü üzerinden yorumlamışlardır. Modül ömrü üzerinden karşılaştırma deniz seviyesinde kullanılan PV panellerin modül ömrü ile kıyaslanarak yapılmıştır [18]. Watt ve Campell, PV paneller beslenen pompalama sistemi için panel çıkış gücünün pompa motor gücüne oranını ifade eden bir indeks hesaplamışlardır. Bu indeksin değişimi havanın açıklık oranına göre incelenmiştir [19]. Bonkaney ve arkadaşları 2017 yılında Niamey/Nijerya bölgesinde PV panel veriminin değişimini havanın açıklık durumu ve panel yüzeyindeki kirlilik üzerinden araştırmışlardır. Çalışma sonucunda yüzey kirliliğinin uzun vadede, hava açıklığı oranının ise kısa vadede PV panel verimi üzerinde etki ettiğini tespit etmişlerdir [20]. Dal, 2021 yılında panel eğim açılarının PV panel verimi üzerindeki etkisini Kayseri/Türkiye bölgesinde incelemiştir. Çalışmada panelin bulunduğu bölgedeki eğim açılara göre aylık, mevsimsel ve altı aylık şartlara göre panel eğim açısı ayarlanarak panel verimi analiz edilmiştir [21]. Literatür bilgisi sunulan bu çalışmalarda her ne kadar çevresel meteorolojik parametreler öncelenecek PV panel çıkış gücü ve verimliliği analiz edilse de neredeyse tamamında dolaylı yoldan bu parametrelerin ışınım verileri üzerindeki yansımaları da incelenmiştir. Önerilen bu çalışmada ise saha çalışmasında elde edilen PV panel gücü, sıcaklık ve hava açıklığı gibi temel meteorolojik parametrelerin yanında ışınım verileri (GHI, DHI ve DNI) üzerinden de analiz edilecektir.

Son yıllarda GHI, DHI ve DNI solar ışınım verileri üzerinden yapılan araştırma çalışmalarına da literatürde rastlanılmaktadır [22]-[26]. Bu veriler, belli bir lokasyondaki PV panel tabanlı güneş tarlalarından elde edilebilecek elektriksel gücün tahmin edilmesinde araştırmacılara doğruluğu yüksek bilgiler sunmaktadır. Tahmin tabanlı araştırma çalışmalarında tercih edilen veri eğitimi, makine öğrenmesi, yapay öğrenme, vb. yöntemlerde entropi tabanlı özellik çıkarımları da kullanılmaktadır. Tribak ve Zaz 2019 yılında yaptıkları çalışmada PV paneller üzerindeki kirlilik seviyesini görüntüde entropi hesaplaması ile tespit etmişlerdir [27]. Liu ve arkadaşları PV panel gücünü entropi tabanlı yöntem ile tahmin eden bir çalışma yapmışlardır [28]. Bir başka çalışmada da Zhang ve arkadaşları PV panel gücünü yine entropi tabanlı yöntem ile tahmin etmişlerdir [29]. Takamatsu ve Nakajima, güneş ışınım verilerinin analizi için gerekli olan özellik çıkarımlarını entropi ile hesaplamışlardır [30].

Önerilen bu çalışmada, entropi ile analiz yapılacaktır. Entropi analizi için ışıınım verilerinin standart sapmasından elde edilen özellik çıkarımı kullanılacaktır.


Önerilen çalışmanın temel motivasyonu GHI, DHI ve DNI ışıınım verilerinin entropi tabanlı analizi ile saha çalışmasından elde edilen PV panel gücü değişiminin karşılaştırmasının yapılmasıdır. Saha verileri olarak Mendeley Data web sitesinde açık-kaynak olarak sunulan “Solar Panel Data [31]” isimli ve Rajasthan/Hindistan bölgesinden elde edilen veriler kullanılacaktır.

Makalenin organizasyonu şu şekildedir. Çalışmanın 2. Bölümünde kullanılan yöntemlerin teorik bilgileri, 3. Bölümünde ise önerilen yöntemin analiz sonuçları sunulmaktadır. Çalışma, analiz sonuçlarının değerlendirildiği Sonuçlar Bölümü ile sonlandırılmaktadır.

2. MATERYAL ve METOT

2.1. Güneş Işınım Verileri

Güneş ışıınım verilerine ait temel parametreler GHI, DHI ve DNI olarak öne çıkmaktadır. Bu temel parametrelerin gösterimleri Şekil 1’de sunulmaktadır [32].



Şekil 1. Güneş ışıınım parametreleri (a) GHI, (b) DNI, (c) DHI.

Bu üç parametrenin birbiri ile olan ilişkisi Eşitlik 1 ile hesaplanmaktadır [32], [33].

$$GHI = DHI + DNI * \cos \emptyset \quad (1)$$

\emptyset , güneşin doğrultusu ile yatayın oluşturduğu açığı ifade etmektedir.

2.2. Önerilen Yöntem

Analiz edilen veriler Mendeley Data web sitesinde bulunan “Solar Panel Data [31]” isimli ve Rajasthan/Hindistan bölgesinden elde edilen verilerdir. İlgili verilerde panel çıkış gücü 20 kW ve 100 kW kapasiteye sahip iki adet evirici üzerinden ölçülmektedir. Panel gücü hesabında kullanılan akım ve gerilim verileri 6⁰⁰-15⁰⁰ saatleri arasında her 30 dk’da bir kaydedilmiştir. Ölçüm işlemleri 1 sene boyunca devam ettirilmiştir (Teknik bir nedenden dolayı Aralık ayına ait ölçümlerin büyük bölümü alınamamıştır). Sıcaklık, nem, hava açıklık oranı gibi temel meteorolojik verilerin yanında GHI, DNI ve DHI verileri de ilgili veri dosyası içinde bulunmaktadır [31].

Önerilen yönteme ait blok diyagram Şekil 2’de sunulmaktadır.



Şekil 2. Blok diyagram.

Veriler, açık-kaynak olarak “Solar Panel Data [31]” isimli dosyadan çekilmektedir. Dosyada bulunan verilerden “panel çıkış gücü (kW), hava sıcaklığı (°C), hava açıklık oranı, DNI (kWh/m²), DHI (kWh/m²) ve GHI (kWh/m²)” bilgileri bu çalışmada analiz edilmiştir. Gün içerisinde belirli saatlerde ölçülerek kayıt altına alınan bu verilerin öncelikle aylık ortalamaları hesaplanmıştır. Daha sonra Aralık ayı hariç tutularak ilgili verilerin kendi içerisindeki yıllık ortalamaları hesaplanmaktadır. Aylık ve yıllık ortalamalar kullanılarak

yukarıda bahsedilen her bir veri türünün standart sapmaları Eşitlik 2 ile hesaplanmaktadır [34].

$$\text{Standart Sapma} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (2)$$

Eşitlik 2’de sunulan ifadede N , örneklem sayısını; x_i , hesaplanan değeri; \bar{x} ise hesaplanan verilerin ortalama değerini ifade etmektedir. Standart sapma hesaplamasının ardından ilgili verinin entropi hesabı için özellik çıkarımı (σ) yapılmaktadır. Özellik çıkarımı Eşitlik 3 ile yapılmaktadır.

$$\sigma = \frac{\text{Veri}_{\text{Aylık Ortalama}}}{\text{Veri}_{\text{Standart Sapma}}} \quad (3)$$

Özellik çıkarımının ardından ilgili verinin entropisi Shannon entropisi [35] baz alınarak hesaplanmaktadır. Bu çalışmada entropi hesaplaması kümülatif toplam (Σ) üzerinden değil verilerin standart sapma değeri baz alınarak noktasal (lokal) olarak yapılmaktadır. Bu nedenle Shannon entropi hesaplamasında kullanılan kümülatif toplam (Σ) işareti hesaplama sırasında kullanılmamaktadır. Ayrıca bu çalışmada entropi sonuçları ardışıl iki nokta arasındaki değişimin eğim açısı olarak değerlendirilmektedir. Ardışıl iki noktanın ileri yönlü ya da geri yönlü seçilmesi eğim açısı hesaplamasını değiştirmeyeceği için Shannon entropi hesaplamasındaki (-1) çarpanı da entropi hesaplamasında kullanılmamaktadır. Çalışmada kullanılan entropi hesap denklemi Eşitlik 4’te sunulmaktadır.

$$\text{Entropi} = \text{Veri}_{\sigma} * \log_2 \text{Veri}_{\sigma} \quad (4)$$

3. ARAŞTIRMA SONUÇLARI ve TARTIŞMA

3.1. Ham Veriler

Açık-kaynak olarak sunulan “Solar Panel Data [31]” isimli dosyadan çekilen verilere ait bir görsel Şekil 3’te sunulmaktadır.

Ultra vibrant Solar Energy Pvt. Ltd.														
Plant Generation Datasheet														
Plant Name Fitpack Textiles														
Year Tem.05														
Inv-1 Sungrow														
Inv-2 Sungrow														
Month	Date	Main	AirTemp	CloudOpacity	Dni	DHI	Ghi	RelativeHumidit Y	PM2.5 (ug/m3)	PM10 (ug/m3)	NOx (ppb)	NH3 (ug/m3)	SO2 (ug/m3)	CC
1	1	351,70	12,44	6,85	188,83	93,58	159,88	64,68	113,67	159,33	98,57	68,29	9,81	
1	2	401,70	13,17	8,44	156,08	83,17	153,00	67,58	110,14	151,15	70,19	48,81	11,45	
1	3	378,00	14,49	4,10	184,88	93,92	158,83	67,36	125,42	173,39	77,03	53,30	16,33	
1	4	373,50	16,90	40,51	125,71	66,75	133,00	63,66	115,32	162,59	91,70	63,30	9,79	
1	5	115,70	14,68	62,47	0,00	0,00	32,50	90,64	76,95	95,76	38,80	28,01	9,00	
1	6	48,70	14,91	66,57	0,00	0,00	30,46	91,75	110,47	123,78	23,69	25,39	8,86	
1	7	201,60	16,04	62,85	0,00	0,00	60,25	92,38	45,10	61,96	16,46	21,76	8,68	
1	8	173,10	15,80	47,02	7,54	1,88	57,67	92,41	29,13	52,14	27,22	31,78	12,25	
1	9	355,30	12,49	15,35	163,33	75,75	153,71	80,75	22,96	48,97	22,28	25,91	12,64	
1	10	489,90	11,43	3,79	262,04	129,92	180,29	79,14	20,57	46,94	34,08	38,16	11,90	
1	11	451,20	11,13	7,20	176,88	95,13	165,29	75,71	39,30	83,29	58,74	64,67	13,45	
1	12	341,10	10,49	15,92	117,00	63,71	145,00	77,09	38,71	75,73	36,51	41,02	14,84	
1	13	405,20	10,46	7,20	161,46	88,58	163,75	79,73	54,67	103,75	55,03	60,74	13,50	
1	14	349,90	10,85	13,01	101,00	53,96	145,67	79,45	57,35	110,69	65,45	72,14	11,77	
1	15	274,70	9,75	13,90	81,75	46,92	139,75	83,23	57,84	106,15	42,25	47,25	12,73	
1	16	334,00	8,87	17,03	159,04	86,21	155,38	83,13	63,22	111,14	28,47	32,58	12,92	
1	17	319,50	9,87	8,20	194,58	107,33	167,04	82,34	41,42	77,52	32,52	36,87	13,76	
1	18	413,00	11,11	4,75	244,38	129,08	182,29	80,28	82,55	139,33	86,02	84,29	12,90	
1	19	464,20	13,66	5,80	197,13	101,33	169,96	76,29	56,61	89,32	51,34	39,93	8,93	
1	20	448,60	14,20	12,33	115,71	68,21	151,25	80,83	54,42	86,73	35,66	28,12	10,30	
1	21	315,10	13,88	35,03	99,50	56,96	137,04	83,36	74,07	106,97	33,76	26,85	8,76	

Şekil 3. Ham verilere ait bir görsel [31].

3.2. Aylık Ortalama Veriler

PV panel güçleri, hava sıcaklığı, bulutluluk oranı, DNI, DHI ve GHI verilerine ait ortalama değerler Tablo 1’de sunulmaktadır.

Tablo 1. Verilerin aylık ortalama değerleri

Aylar	PV panel güçleri (kW)	Hava sıcaklığı (°C)	Hava açıklık oranı	DNI (kWh/m ²)	DHI (kWh/m ²)	GHI (kWh/m ²)
Ocak	379	12,84	17,83	150,2	79,49	146,6
Şubat	458,6	18,5	6,43	211,6	126,7	205,7
Mart	608,8	26,6	8,9	226	157	251,4
Nisan	620,9	32,53	13,79	210,1	160,3	273,6
Mayıs	515	34,93	18,16	139,9	117,3	261,5
Haziran	478,5	33,68	31,44	125,4	102,3	238,5
Temmuz	439,7	29,15	50,09	94,4	74,43	200,2
Ağustos	440,2	27,94	47,61	80	61,94	174,5
Eylül	460,2	28,39	25,18	166,1	119,1	218
Ekim	480,4	24,73	9,2	216,7	135,4	211,3
Kasım	366,3	20,26	3,85	219,2	119,5	183,6

3.3. Standart Sapmalar

Eşitlik 2’de verilen denklem kullanılarak hesaplanan standart sapmalar Tablo 2’de sunulmaktadır.

Tablo 2. Verilerin standart sapmaları

Hava sıcaklığı (°C)	Hava açıklık oranı	DNI (kWh/m ²)	DHI (kWh/m ²)	GHI (kWh/m ²)
6,812	15,95	53,02	32,07	38,87

3.4. Özellik Çıkarımı

Eşitlik 3’te verilen denklem kullanılarak yapılan özellik çıkartım değerleri Tablo 3’te sunulmaktadır.

Tablo 3. Özellik çıkarımı

Aylar	Hava sıcaklığı (°C)	Hava açıklık oranı	DNI (kWh/m ²)	DHI (kWh/m ²)	GHI (kWh/m ²)
Ocak	1,885	1,118	2,833	2,479	3,772
Şubat	2,716	0,4031	3,991	3,951	5,292
Mart	3,905	0,5580	4,263	4,896	6,468
Nisan	4,775	0,8646	3,963	4,998	7,039
Mayıs	5,128	1,139	2,639	3,658	6,728
Haziran	4,944	1,971	2,365	3,190	6,136
Temmuz	4,279	3,14	1,780	2,321	5,151
Ağustos	4,102	2,985	1,509	1,931	4,489
Eylül	4,168	1,579	3,133	3,714	5,608
Ekim	3,630	0,5768	4,087	4,222	5,436
Kasım	2,974	0,2414	4,134	3,726	4,723

3.5. Entropi Hesabı

Eşitlik 4’te sunulan denklem kullanılarak yapılan entropi hesaplamaları Tablo 4’te sunulmaktadır.

Tablo 4. Entropi değerleri

Aylar	Hava sıcaklığı (°C)	Hava açıklık oranı	DNI (kWh/m ²)	DHI (kWh/m ²)	GHI (kWh/m ²)
Ocak	1,724	0,1797	4,256	3,246	7,223
Şubat	3,914	-0,5284	7,969	7,831	12,72
Mart	7,674	-0,4697	8,916	11,22	17,42
Nisan	10,77	-0,1815	7,872	11,60	19,82
Mayıs	12,09	0,2131	3,694	6,843	18,50
Haziran	11,40	1,93	2,937	5,338	16,06
Temmuz	8,975	5,185	1,482	2,819	12,18
Ağustos	8,352	4,709	0,8955	1,834	9,726
Eylül	8,582	1,04	5,161	7,030	13,95
Ekim	6,753	-0,4579	8,301	8,773	13,28
Kasım	4,677	-0,4950	8,466	7,071	10,58

3.6. Entropi Eğim Açılarının PV Panel Güçleri Eğim Açıları İle Karşılaştırılması

Eşitlik 5’te sunulan eğim açısı hesaplama denklemi ile elde edilen eğim açıları Tablo 5’te sunulmaktadır. Örnek eğim açısı hesaplama işlemi Eşitlik 6’da sunulmaktadır. Aylar arasındaki geçiş değeri 1 olarak kabul edilmiştir.

$$\begin{aligned} P_{Ocak \rightarrow \text{Şubat}} &= 89,33^\circ \\ P_{Ocak} &= 379 \text{ kW} \\ P_{\text{Şubat}} &= 458,6 \text{ kW} \\ \text{Eğim Açısı} &= \tan^{-1} \frac{(458,6 - 379)}{1} = 89,33^\circ \end{aligned} \quad (6)$$
$$\begin{aligned} GHI_{Ocak \rightarrow \text{Şubat}} &= 79,73^\circ \\ GHI_{Ocak} &= 7,223 \text{ kWh/m}^2 \\ GHI_{\text{Şubat}} &= 12,72 \text{ kWh/m}^2 \\ \text{Eğim Açısı} &= \tan^{-1} \frac{(12,72 - 7,223)}{1} = 79,73^\circ \end{aligned}$$

Tablo 5’te sunulan tüm eğim açısı değerleri Eşitlik 6’da sunulan referans çözümlere göre hesaplanmıştır.

Tablo 5. Eğim açıları

Aylar arasındaki geçişler	PV panel güçleri (°)	Hava sıcaklığı (°)	Hava açıklık oranı (°)	DNI (°)	DHI (°)	GHI (°)
Ocak→Şubat	89,33	65,50	-35,32	74,96	77,74	79,73
Şubat→Mart	89,66	75,14	3,362	43,47	73,59	78,02
Mart→Nisan	85,33	72,14	16,08	-46,27	21,11	67,39
Nisan→Mayıs	-89,50	52,91	21,55	-76,58	-78,18	-52,78
Mayıs→Haziran	-88,48	-34,73	59,81	-37,11	-56,42	-67,77
Haziran→Temmuz	-88,57	-67,63	72,96	-55,54	-68,38	-75,58
Temmuz→Ağustos	26,58	-31,96	-25,44	-30,40	-44,59	-67,86
Ağustos→Eylül	87,18	12,99	-74,79	76,85	79,15	76,72
Eylül→Ekim	-88,45	-61,37	-56,3	72,37	60,19	-33,98
Ekim→Kasım	-89,06	-64,31	-2,125	9,329	-59,59	-69,70

Hesaplanan eğim açılarının PV panel güç eğim açıları ile ilişkisinin kurulabilmesi amacıyla ilgili ay geçişlerindeki PV panel güçleri eğim açılarından her bir parametredeki eğim açıları çıkartılarak Tablo 6 elde edilmektedir. Örnek hesaplama Eşitlik 7’de sunulmaktadır.

$$\begin{aligned}
 & \text{Fark } (GHI_{Nisan \rightarrow Mayıs}) = -36,72^\circ \\
 & P_{Nisan \rightarrow Mayıs} \quad \text{Eğim Açısı } (GHI_{Nisan \rightarrow Mayıs}) \quad -89,50^\circ - (-52,78^\circ) = -36,72^\circ \quad (7) \\
 & \quad \quad \quad -89,50^\circ \quad \quad \quad -52,78^\circ
 \end{aligned}$$

Tablo 6’da sunulan tüm eğim açısı değerleri Eşitlik 7’de sunulan referans çözüme göre hesaplanmıştır.

Tablo 6. PV panel güçleri ile eğim açısı tabanlı kıyaslama

Aylar arasındaki geçişler	PV panel güçleri (°)	Hava sıcaklığı (°)	Hava açıklık oranı (°)	DNI (°)	DHI (°)	GHI (°)
Ocak→Şubat	89,33	23,83	124,6	14,36	11,59	9,59
Şubat→Mart	89,66	14,52	86,30	46,20	16,08	11,64
Mart→Nisan	85,33	13,18	69,24	131,6	64,22	17,93
Nisan→Mayıs	-89,50	-142,4	-111,1	-12,93	-11,33	-36,72
Mayıs→Haziran	-88,48	-53,75	-148,3	-51,36	-32,05	-20,71
Haziran→Temmuz	-88,57	-20,94	-161,5	-33,03	-20,18	-12,98
Temmuz→Ağustos	26,58	58,53	52,02	56,98	71,17	94,44
Ağustos→Eylül	87,18	74,19	162,0	10,34	8,04	10,46
Eylül→Ekim	-88,45	-27,08	-32,15	-160,8	-148,6	-54,47
Ekim→Kasım	-89,06	-24,74	-86,93	-98,39	-29,47	-19,36

Analiz edilen verilerden PV panel güçleri eğim açısına yaklaşan değeri tespit edebilmek amacıyla hesaplanan fark değerlerinin ortalama değerleri alınmaktadır. Sonuçlar Tablo 7’de sunulmaktadır.

Tablo 7. Farkların ortalama değerleri

Hava sıcaklığı	Hava açıklık oranı	DNI	DHI	GHI
-8,47	-4,58	-9,71	-7,06	-0,02

Tablo 7 değerlendirildiğinde PV panel güç eğim açısı değerlerine en çok yaklaşan parametrenin, ortalama değeri sıfıra oldukça yaklaşan GHI olduğu tespit edilmiştir. GHI, eviricilerden elde edilen toplam güçteki dalgalanmaya entropi hesaplamasında anlık olarak tepki vermektedir. Ay bazında değişimler incelendiğinde ay geçişlerindeki toplam güç kapasitesindeki değişimlere bağlı olarak GHI verileri de aşağı ya da yukarı yönlü belirgin hareketlerde bulunmaktadır. Tablo 1’de sunulan güç kapasitelerine göre ay geçişlerinde 6 adet yukarı yönlü 4 adet de aşağı yönlü hareket bulunmaktadır. Aylık geçişlerdeki güç kapasitesi artım ve güç kapasitesi azalım miktarları toplandığında sıfıra yakın bir değer elde edilmektedir. Önerilen yöntemde entropi hesaplamasına en iyi cevap veren parametrenin de

bu değişimleri takip ederek sifıra en yakın ortalamaya ulaşması gerekmektedir. GHI parametresinin entropi eğim açısı fark değerlerinin de yıllık bazdaki toplamı sifıra oldukça yakın çıkmaktadır. Bu da GHI değerinin aylık bazdaki toplam güç değişimine bağlı olarak anlık belirgin iniş ve çıkış eğrisi çizmesine rağmen, bu değerleri güçteki değişime bağlı olarak belli bir aralıkta ayarladığını göstermektedir.

Gerek anlık entropi değişim değerleri ile gerekse de eğim açısı değerinin güç kapasitesi eğim açısı değeri ile oluşturduğu farkın değerlendirildiği matematiksel yaklaşım ile GHI verileri, güç kapasitesindeki değişime çok daha iyi uyum sağlamaktadır. Işınım verileri ile güç kalitesi arasında bir korelasyon kurulacaksa verdiği kararlı değişim tepkisinden dolayı bu korelasyonun GHI ile kurulması mantıklı olacaktır.

4. SONUÇ ve ÖNERİLER

PV güneş panellerinin güçlerini ve verimliliklerini artırma çalışmalarına yakın zamana kadar temel meteorolojik parametreler (sıcaklık, nem, hava açıklık oranı, rüzgâr, vb.) yön vermektedir. Bu parametrelerin tekil analizleri doğru ve etkili sonuçlar verse de parametrelerin çoklu ve eş zamanlı etkileri PV panellerin güçlerinin ve verimliliklerinin analizini karmaşık ve zor bir hale getirmektedir.

Bu çalışmada günümüz literatür çalışmalarına da yön veren güneş ışınım verilerinin analizi üzerinde durulmaktadır. Literatürde temel güneş ışınım parametreleri GHI, DHI ve DNI'dır. Bu çalışmada Mendeley Data web sitesinde açık-kaynak olarak sunulan “Solar Panel Data” isimli, Parashar ve Verma tarafından Rajasthan/Hindistan bölgesinden alınan veriler analiz amaçlı kullanılmıştır [31].

Çalışmada önerilen yöntem, verilerin ortalama değerlerinden elde edilen özellik çıkarımına uygulanan entropi analizi ile bu analiz sonucunda hesaplanan PV panel güçleri eğim açılarından sırasıyla sıcaklık, hava açıklığı, DNI, DHI ve GHI eğim açılarının çıkarılması prensibi ile çalışmaktadır. Önerilen yöntemin son aşamasında elde edilen fark değerlerinin ortalamaları hesaplanmıştır. Sıcaklık, hava açıklığı, DNI, DHI ve GHI verileri için sırasıyla bu açı fark değerleri “ $-8,47^\circ$, $-4,58^\circ$, $-9,71^\circ$, $-7,06^\circ$ ve $-0,02^\circ$ ” olarak hesaplanmıştır. Hesaplanan bu değerler yorumlandığında PV panel güç kapasitesinin aylık değişimine (aşağı ve yukarı yönlü) en uygun tepkinin GHI parametresi tarafından verildiği tespit edilmiştir.

DNI, DHI ve GHI verilerinin sensörler aracılığıyla ölçümleri yüksek maliyetli bir işlemdir. Bu nedenle bu parametrelerin doğrudan ölçüldüğü sistemler oldukça azdır. Bu verilere ulaşım genellikle uydu sistemleri üzerinden ölçüm yapan ve ölçüm sonuçlarını açık-kaynak olarak sunan kuruluşlara başvurularak yapılmaktadır. PV güneş tarlalarının kurulmadan önceki güç kapasitelerinin tahmin edilmesinde ışınım verilerinin temel meteorolojik verilere bağlı olarak makine/veri öğrenmesi teknikleri ile tahmin edilmesi çalışmaları gelecekteki çalışmalar için değerlendirilebilir. Bu çalışmanın literatüre sunduğu katkı ise bu üç temel güneş ışınım verisinden hangisine daha çok ihtiyaç duyulacağı sorusuna alternatif bir cevap sunmasıdır. Ayrıca makine/veri öğrenmesine dayalı tekniklerin ihtiyaç duyduğu özellik çıkarımlarına ulaşmak için de entropi tabanlı hesaplamaların kullanılabileceğine yine bu çalışmada değinilmiştir.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

KAYNAKLAR

- [1] Y. Gu, Y. Huang, Q. Wu, C. Li, H. Zhao and Y. Zhan, “Isolation and Protection of the Motor-Generator Pair System for Fault Ride-Through of Renewable Energy Generation Systems,” *IEEE Access*, vol. 8, pp. 13251-13258, 2020.
- [2] A. Qazi et al., “Towards Sustainable Energy: A Systematic Review of Renewable Energy Sources, Technologies, and Public Opinions,” *IEEE Access*, vol. 7, pp. 63837-63851, 2019.
- [3] Ö. Bilhan, “Türkiye’de yenilenebilir enerji kaynakları açısından hidroelektrik ve güneş enerjisinin bölgesel ve iller bazında incelenmesi”, *NÖHÜ Müh. Bilim. Derg.*, c. 13, sy. 4, ss. 1504–1516, 2024.
- [4] International Energy Agency (IEA), “Global energy investment in clean energy and in fossil fuels, 2015-2023,” *IEA*, 2023. [Online]. Available: <https://www.iea.org/data-and-statistics/charts/global-energy-investment-in-clean-energy-and-in-fossil-fuels-2015-2023> [Accessed: Dec. 02, 2024].
- [5] E. Kabir, P. Kumar, S. Kumar, A. A. Adelodun and K.-H. Kim, “Solar energy: Potential and future prospects,” *Renewable and Sustainable Energy Reviews*, vol. 82 (1), pp. 894-900, February 2018.

- [6] N. M. Haegel and S. R. Kurtz, "Global Progress Toward Renewable Electricity: Tracking the Role of Solar," *IEEE Journal of Photovoltaics*, vol. 11, no. 6, pp. 1335-1342, Nov. 2021.
- [7] S. Somuncu ve C. Oral, “Yapay Sinir Ağı ve ANFIS kullanılarak Meteorolojik Verilere Bağlı Güneş Enerjisi Tahmini”, *OKÜ Fen Bil. Ens. Dergisi ((OKU Journal of Nat. & App. Sci)*, c. 7, sy. 4, ss. 1685–1701, 2024.
- [8] K. Achuthan et al., "Remote Triggered Dual-Axis Solar Irradiance Measurement System," *IEEE Transactions on Industry Applications*, vol. 56, no. 2, pp. 1742-1751, March-April 2020.
- [9] M. Sengupta, Y. Xie, A. Lopez, A. Habte, G. Maclaurin and J. Shelby, “The National Solar Radiation Data Base (NSRDB),” *Renewable and Sustainable Energy Reviews*, vol. 89, pp. 51-60, 2018.
- [10] A. K. Tripathi, S. Ray, M. Aruna and S. Prasad, “Evaluation of solar PV panel performance under humid atmosphere,” *Materials Today: Proceedings*, vol. 45(7), pp. 5916-5920, 2021.
- [11] Ş. Güven, “Fotovoltaik Panel Yüzey Sıcaklığının Denizli İli için Çıkış Gücü ve Verim Üzerindeki Etkisinin İncelenmesi,” *Mühendis ve Makina*, c. 63, sy. 707, ss. 429-442, 2022.
- [12] I. M. Kirpichnikova and I. B. Makhsumov, “The Influence of Ambient Temperature on the Energy Characteristics of Solar Modules,” *2020 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*, Sochi, Russia, 2020, pp. 1-5.
- [13] S. Adak, H. Cangi ve A. S. Yılmaz, “Fotovoltaik Sistemin Çıkış Gücünün Sıcaklık ve Işımaya Bağlı Matematiksel Modellemesi ve Simülasyonu,” *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, c. 11, sy. 1, ss. 316-327, Ocak 2019.
- [14] R. J. Mustafa, M. R. Gomaa, M. Al-Dhaifallah and H. Rezk, “Environmental Impacts on the Performance of Solar Photovoltaic Systems,” *Sustainability*, 12(2), 608, 2020.
- [15] A. Dhaundiyal and D. Atsu, “The effect of wind on the temperature distribution of photovoltaic modules,” *Solar Energy*, vol. 201, pp. 259-267, 2020.
- [16] W. Z. Leow, Y. M. Irwan, M. Irwanto, A. R. Amelia and I. Safwati, “Influence of wind speed on the performance of photovoltaic panel,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 15 (1), pp. 60-68, Jul. 2019.

- [17] A. M. A. Aswadi, Ç. Aydın, M. Farazadi ve D. Ç. Atilla, “Sıcaklık ve Güneş Işınım Değişimlerinin Fotovoltaik Sistemler Üzerindeki Etkileri,” *AURUM Mühendislik Sistemleri ve Mimarlık Dergisi*, c. 7, sy. 2, ss. 235-257, 2023.
- [18] V. Başay, R. Eken, ve G. Yılmaz, “Orta Yükseklikte Dağlık Bölgelerde Kurulan Güneş Enerjisi Santralinde Fotovoltaik Modüllerin Yaşlanması Araştırılması”, *UUJFE*, c. 24, sy. 2, ss. 325–336, 2019.
- [19] F. W. Watt and P. A. Campell, “The effects of solar insolation and cloud opacity on the optimum array size for a direct-coupled solar pumping system,” *Renewable Energy*, vol. 228, 120594, July 2024.
- [20] A. Bonkaney, S. Madougou and R. Adamou, “Impacts of Cloud Cover and Dust on the Performance of Photovoltaic Module in Niamey,” *Journal of Renewable Energy*, vol. 217, 9107502, September 2017.
- [21] A. R. Dal, “Güneş Enerji Panellerindeki Optimum Eğim Açısının Verime Etkisinin İncelenmesi,” *BSEU Journal of Science*, c. 8, sy. 1, ss. 241-250, 2021.
- [22] J. A. Qadourah, A. M. Al-Falahat and S. S. Alrwashdeh, “Assessment of solar photovoltaics potential installation into multi-family building’s envelope in Amman, Jordan,” *Cogent Engineering*, vol. 9, 2082059, 2022
- [23] M. H. d. S. Campos and C. Tiba, “npTrack: A n-Position Single Axis Solar Tracker Model for Optimized Energy Collection,” *Energies*, vol. 14, p. 925, 2021.
- [24] R. Pravalie, C. Patriche and G. Bandoc, “Spatial assessment of solar energy potential at global scale. A geographical approach,” *Journal of Cleaner Production*, vol. 209, pp. 692-671, 2019.
- [25] A. Kumler, Y. Xie and Y. Zhang, “ A Physics-based Smart Persistence model for Intra-hour forecasting of solar radiation (PSPI) using GHI measurements and a cloud retrieval technique,” *Solar Energy*, vol. 177, pp. 494-500, 2019.
- [26] A. R. Pazikadin et al., “Solar irradiance measurement instrumentation and power solar generation forecasting based on Artificial Neural Networks (ANN): A review of five years research trend,” *Science of the Total Environment*, vol. 715, 136848, 2020.
- [27] H. Tribak and Y. Zaz, "Dust Soiling Concentration Measurement on Solar Panels based on Image Entropy," *7th International Renewable and Sustainable Energy Conference (IRSEC)*, Agadir, Morocco, 2019, pp. 1-4.

- [28] H. Liu, H. Wang, L. Lin, L. Yao, W. He and Y. Zhou, "Prediction of Photovoltaic Power Based on Entropy Weight Combination Forecasting Method," *IEEE 4th Conference on Energy Internet and Energy System Integration (EI2)*, Wuhan, China, 2020, pp. 4081-4086.
- [29] X. Zhang, B. Jiang, X. Zhang, F. Fang, Z. Gao and T. Feng, "Solar Photovoltaic Power Prediction Based on Similar Day Approach," *Proceedings of the 36th Chinese Control Conference*, Dalian, China, 2017, pp. 10634-10639.
- [30] T. Takamatsu and T. Y. Nakajima, "Study of Spatial Asynchrony Analysis for Solar Irradiance," *7th International Conference on Renewable Energy Research and Applications (ICRERA)*, Paris, France, 2018, pp. 711-714.
- [31] B. Parashar and R. Verma, Richa, "Solar Panel Data", *Mendeley Data*, V1, 2024.
- [32] A. Balabel et al., "Potential of Solatube technology as passive daylight systems for sustainable buildings in Saudi Arabia," *Alexandria Engineering Journal*, vol. 61, pp. 339-353, 2022.
- [33] B. L. Madhavan and M. V. Ratnam, "Impact of a solar eclipse on surface radiation and photovoltaic energy," *Solar Energy*, vol. 223, pp. 351-366, 2021.
- [34] A. Boretti, "High-frequency standard deviation of the capacity factor of renewable energy facilities: Part 1—Solar photovoltaic," *Energy Storage*, vol. 2(1), 2:e101, Feb. 2020.
- [35] C. E. Shannon, "A mathematical theory of communication", *Bell Syst. Tech. J.*, 27, pp. 379-423, Oct. 1948.



Süleyman Demirel Üniversitesi

YEKARUM e-DERGI

(Journal of YEKARUM)



Cilt 9 , Sayı 2, 164-189, 2024
E - ISSN:1309-9388

Yeni Nesil Savaş Uçaklarında Silah Sistemi Tasarım Yaklaşım Yöntemleri

Gürel BUR¹, Mustafa İZGÜDEN^{2*}

¹ İstanbul Teknik Üniversitesi, Uçak ve Uzay Bilimleri Fakültesi, Uçak Mühendisliği Bölümü, İstanbul, Türkiye,
(ORCID: 0009-0008-8087-4651), gurelbur@hotmail.com

^{2*} Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik ve Elektronik Mühendisliği Bölümü, Ankara,
Türkiye (ORCID: 0009-0004-0015-1519), izguden@hotmail.com

(İlk Geliş Tarihi 12/09/2024 ve Kabul Tarihi 18/12/2024)

ÖZET:

Artan harekât ihtiyaçlarını karşılamak ve savaş ortamında hava üstünlüğü sağlamak için farklı kabiliyet ve özelliklere sahip savaş uçaklarının kullanımına ihtiyaç duyulmuştur. Teknolojik gelişmeler ve bu gelişmelerin hava araçlarına uygulanması ile farklı özelliklere sahip savaş uçakları tasarlanmaya başlanmıştır. Tasarlanan yeni nesil savaş uçaklarının operasyon gücünü arttırarak etkin hale getirmek ve modern savaş ortamlarına entegrasyonunu karşılamak için gelişmiş silah sistemleri ile donatmak silah sistemleri tasarımının kritik bir geliştirme ortamı olarak ortaya konmasına sebep olmuştur. Modern silah sistemlerinin kompleks yapısı nedeniyle silah sistemi tasarımı birçok farklı disiplini ve uzmanlık sahasını bünyesinde barındıran bir süreç haline gelmiştir. Bu çalışmada, yeni nesil savaş uçağına ait silah sistemlerinde bulunması gereken fonksiyonlar ve fonksiyonların etkin bir şekilde kullanılabilmesi için dikkate alınması gereken tasarım yaklaşım yöntemleri incelenmiş, gelecekteki savaş uçaklarının silah sistemi tasarımlarının şekillendirilmesine, gelişen tehditlere karşı uyarlanabilir olmasına ve hava üstünlüğü sağlamak için ihtiyaç olacak yeteneklerin belirlenmesine yönelik uygulanacak yaklaşımların önemi vurgulanmıştır.

Anahtar Kelimeler: Savaş Uçağı, Silah Sistemi, Tasarım Yaklaşımı

Weapon System Design Approach Methods in Next Generation Fighter Aircraft

ABSTRACT

In order to meet increasing operational needs and sustain air superiority in warfare environment, military is forced to utilize advanced fighter aircraft. With the technological developments and by the application of these developments to fighter aircraft design, new generations of fighters have been developed. Increased operational effectiveness of new generation fighter aircraft stems from being equipped with advanced weapon systems which has become a critical area of development. Weapon system design for advanced air vehicles involves a multidisciplinary process that relies on many different area of expertise. In this study, it is aimed to provide an insight into the design approaches to be considered to realize functions that are necessary to exist on the new

* Sorumlu yazar E-mail: izguden@hotmail.com

generation fighter aircraft weapon systems and emphasize the importance of design approaches for future aircraft weapon systems, ability to adapt everchanging threat environment and determining applicable capabilities to maintain air superiority.

Keywords: *Fighter Aircraft, Weapon System, Design Approach*

1. GİRİŞ

Askeri uçaklar, harp sahasında yer hedeflerini bombalamak, hava tehditlerini tahrip etmek, keşif gerçekleştirmek, personel ve teçhizat taşımak gibi rolleri yerine getirmek amacıyla kullanılmaktadır [1]. Askeri uçaklar arasında bir alt sınıf olan savaş uçakları ise kendi üzerlerinde taşımakta olduğu ekipman ve mühimmatları kullanarak düşman tehditlerini tespit edip, yok etmeye yönelik tasarlanmışlardır. Düşman unsurların tespit edilmesine yönelik savaş uçakları, elektro-optik, kızılötesi ve radar sistemleri gibi gelişmiş ekipmanlarla donatılmışlardır. Tespit edilmiş olan tehditleri etkisiz hale getirmek için askeri savaş uçakları görev ve tehdit tiplerine göre Hava-Yer mühimmatları, Hava-Hava mühimmatları ve Top Sistemi ile donatılmışlardır.

Gelişen teknoloji ve değişen harekât ihtiyaçları ile savaş uçaklarının üstlenmiş olduğu roller ve nesilleri değişmiştir. Birinci nesil sayılan ilk jet motorlu uçaklardan günümüzde halen geliştirme faaliyetleri devam etmekte olan beşinci nesil savaş uçaklarına geçiş yapılmıştır. Nesiller arası genel bir geçiş standardı açık bir şekilde tanımlanmıyor olsa da geliştirilen yeni bir teknolojinin mevcut uçaklara entegrasyonu ile bir üst nesile geçiş uçak üreten devletler ve firmalar tarafından kabul görmektedir [2]. Tablo1’de savaş uçaklarının gelişimine yönelik entegre edilmiş olan yeni teknolojiler genel olarak verilmiştir.

Tablo 1. Savaş Uçakları Nesil ve Özellikleri [2]

Savaş Uçağı Nesilleri	Periyot	Başlıca Özellikler
Birinci Nesil	1945 - 1955	Jet motorları ile ses altı hızda seyir Güdümsüz mühimmat taşıma Entegre makineli tüfek
İkinci Nesil	1955 - 1960	Ses hızını geçen sürat Güdümlü mühimmat kullanımı Radar kullanımı
Üçüncü Nesil	1960 - 1970	Manevra ve taarruz kabiliyetlerinde artış Analog göstergelerin kullanılması Radar görünürlüğünün azalması
Dördüncü Nesil	1970 - 1990	Motor performanslarında artış Hassas güdümlü mühimmatların kullanımı Etkin manevra kabiliyeti Dijital aviyonik sistemler

Savaş Uçağı Nesilleri	Periyot	Başlıca Özellikler
Dördüncü - Beşinci Ara Nesil	1990 - 2000	Dördüncü nesil uçaklar üzerinde iyileştirmeler Aviyonik kabiliyetlerin artırılması Düşük görünürlük İtke yönlendirme
Beşinci Nesil	2000 - 2025	Daha gelişmiş manevra kabiliyeti Düşük termal iz ve düşük görünürlük Gelişmiş aviyoniklerin kullanımı ve veri füzyonu Ağ yetenekli muharebe ortamında görev kabiliyeti Gelişmiş akıllı silah sistemleri

Yeni nesil savaş uçaklarının tasarımı gelişen teknoloji ve modern savaş ihtiyaçlarına göre şekillenmektedir. Söz konusu teknolojilere; düşük görünürlük, gelişmiş sensörler ve hedefleme sistemleri, sensör füzyonu, yapay zekâ ve otonom destek sistemleri, elektronik harp yetenekleri ve dahili silah sistemleri örnek gösterilebilir. Uygulanan teknolojiler hem platformun daha etkin olmasını sağlamak hem de pilotun güvenliğini artırmak adına kritik öneme sahiptir.

Her ne kadar yeni nesil savaş uçakları teknolojik olarak gelişmiş donanımları üzerinde bulundursa da hava aracının harekât ortamında yeteneklerini etkin bir şekilde kullanıp, tehditleri bertaraf etmesi için gelişmiş bir silah sistemine ihtiyacı bulunmaktadır. Günümüzde başarılı bir hedef angajmanı gerçekleştirmek için, uçak ve mühimmatın, mühimmatın tüm yeteneklerini kullanabilecek şekilde birbirine entegre edilmesi gerekmektedir. Mühimmatın hazır hale getirilmesi ve doğru zamanda hedefe yönlendirilmesine yönelik gereksinimler dikkate alındığında mühimmatların uçağa entegrasyonu için çok sayıda farklı disiplini bünyesinde bulunduran bir organizasyonun teşkil edilmesi gerekmektedir [3].

Uçak tasarımında kullanılacak olan mühimmat konfigürasyonu ve taşıma gereksinimleri hem gövde hem de kanat tasarımı için büyük bir öneme sahiptir. Uçak içerisinde yani dahili taşımada bu unsurlar gövdenin boyutlandırılmasına ve yapısal yerleşimin tasarımına yön verirken, kanat altında yani harici taşımada kanat yüklerine ve hava akışı tasarımına yön vermektedir. Ayrıca mühimmatların doğru bir şekilde kontrol edilip, hedefe yönlendirilmesi için kullanılacak olan mühimmatların arayüz bilgileri güç ihtiyaçlarının belirlenmesinde, kablaç tasarımında ve atış kontrol ve yük yönetim sistemi kabiliyetinin belirlenmesinde büyük bir öneme sahiptir [4]. Mekanik arayüz bilgileri (örn. kütle ve atalet bilgileri, bağlantı noktası bilgileri) mühimmatın taşınması ve bırakılması için

önemli girdiler sağlarken, uçuş kontrol sistemi tasarımı ve uçak mekanik yerleşimi gibi farklı alt sistemlerin tasarımına da yön vermektedir.

Mühimmat konfigürasyonları ihtiyaç makamı tarafından ortaya konularak sözleşme dokümanlarında tanımlanmaktadır. Süreç içerisinde gerçekleştirilen konsept tasarım, alternatif sistem tasarım ve ön tasarım gözden geçirme çalışmalarında istenen konfigürasyonlar olgunlaştırılarak sistem tasarımlarına girdi sağlamaktadır. Ek olarak standartlarda belirtilmiş gereksinimler ve ilerleyen süreçte entegre edilmesi muhtemel mühimmatların arayüzleri de sistem tasarımlarına girdi sağlayabilmektedir.

Bu çalışma kapsamında yeni nesil savaş uçaklarında uygulanan silah sistemi tasarım yaklaşımları ile bu yaklaşımların önceki nesil savaş uçaklarında uygulanan çözümler ile farkları değerlendirilmiştir.

2. DAHİLİ SİLAH YUVASI TASARIM YAKLAŞIMI


Beşinci nesil savaş uçaklarının gelişimi ile birlikte bu neslin en ayırt edici özelliklerinden birisi olan düşük görünürlük özelliği uçak üzerinde taşınacak yüklerin ve özellikle de silahların yerleşimi açısından tasarımda büyük değişikliklere yol açmıştır. Uçakların radar kesit alanının düşük tutulabilmesi için ana gövde dışında kalan bölümlerinde geometrik olarak en az çıkıntı yaratacak şekilde tasarlanması ve faydalı yüklerin de bu doğrultuda uçak dış geometrisini bozmayacak bir şekilde veya gövde içerisine yerleştirilmesi zorunluluğu ortaya çıkmıştır (Şekil 1).



Şekil 1. F-35 Dahili Silah Yuvası [5]

Gövde içerisinde mühimmat taşınması bir takım tasarım zorluklarını beraberinde getirmiştir. Beşinci nesil bir uçağın nihai silah konfigürasyonu ve hangi mühimmatları taşıyabileceği konusu dahili silah yuvası tasarımına ilişkin kararlardan ciddi ölçüde etkilenmektedir. Silah sistemi ve silahların yerleşimi açısından tasarımcılar arasında yan yana, arka arkaya, düşey ekseninde sıralanmış veya dönerli silah yerleşimi gibi alternatiflerin etkinliği ile ilgili birçok farklı görüş ortaya atılmıştır. Ancak bu tasarım yaklaşımlarının hangisi seçilirse seçilsin tasarlanacak sistemin uçağa entegrasyonu yapılmadan nihai sistemin değerlendirilebilmesi mümkün olmamaktadır.

Silah yuvasında silahların yerleşimine yönelik alternatifler arasında yapılan karşılaştırmalarda her yaklaşımın belli avantajlarının yansıra birtakım dezavantajları da oraya çıkmaktadır. Tandem yerleşim adı verilen, silahların uçağı uzunlamasına eksenini boyunca birbiri arkasında kalacak şekilde yerleştirilmesi yanal yönde yer kazandıracığı için özellikle çift motorlu uçaklarda bir avantaj sağlamaktadır (Şekil 2). Ancak bu yaklaşımda uçuş esnasında uçağın genel ağırlık merkezinde dramatik kaymalar ve dolayısıyla uçağın kontrol edilebilirlik özelliklerinde olumsuz sonuçlar yaratmaktadır. Silahların yan yana yerleştirilmesi yaklaşımda ise ağırlık merkezi değişimleri daha kontrol edilebilir olmakla birlikte motorlar ve hava alıklarının yerleşimi ile ilgili çakışmalar yaşanabilmekte, bu durum da taşınabilecek silahlar ile ilgili seçimde kısıtlamalara yol açmaktadır (Şekil 3). Genel olarak dönerli veya düşey ekseninde sıralanmış silah yerleşimlerinde taşınabilecek silah miktarında artış sağlanabilirken bu yaklaşımda da uçağın ana gövdesi içerisinde düşey doğrultuda işgal edilmesi gereken yerin arttığı görülmekte ve silahların ilave mekanizmalar yardımıyla atış pozisyonuna getirilmesi ihtiyacı nedeniyle ilave ekipman, dolayısıyla da tasarım karmaşıklığı ve ağırlık artışı kaçınılmaz olmaktadır. Ayrıca yüksek geometrili derin dahili silah yuvalarında genel olarak gözlemlenen yüksek akustik seviyelerini önlemek için gerekli olacak ekipmanlar da yapı üzerinde olumsuz etkiye sebep olacaktır [6].




Şekil 2. Dahili Silah Yuvası Tandem Yerleşim Örneği [7]



Şekil 3. Dahili Silah Yuvası Yan Yana Yerleşim Örneği [8]

Dahili yuvada mühimmat taşıma konusunda karşılaşılan en büyük mühendislik problemlerinden birisi yuva kapakları açılmasıyla uçağın dışındaki yüksek hızlı akış ile yuva içerisindeki durgun ortam karşılaştığında görülen çok önemli iki olay meydana gelmektedir (Şekil 4). Bunlardan birincisi yuva çıkışında oluşan ve davranışının modellenmesi çok zor olan bir hava akışı bölgesidir. Diğeri ise dahili yuva içerisinde aerodinamik olarak tetiklenmiş dinamik titreşimlerdir. Bu iki olay birleştiğinde mühimmatın taşınması ve dahili yuvadan emniyetli bir biçimde atılması konusunda birçok probleme sebep olabilmektedir. Bu nedenle

atışlardan önce yeterli sayıda yer ve uçuş testleri yapılarak yuva içerisinde ve çıkışında gerekli ölçümler yapılarak istenmeyen etkilerin giderilmesi için tasarım değişiklikleri yapılmalıdır [9].




Şekil 4. Dahili Silah Yuvası İç ve Dış Bölge Hava Akışı Modelleme Gösterimi [10]

Silah sistemleri açısından tasarımda izlenecek yaklaşımlar arasında karşılaştırma yapılırken dikkate alınması gereken en önemli hususların başında dahili silah yuvasında ekipman ve parçaların yerleşiminin silah yükleme prosesini optimize edecek şekilde sıkışık bir şekilde yapılması zorunluluğu gelmektedir.

Uçakta konfigürasyona dahil edilecek silahların neler olacağı uçak tasarımcısı tarafından belirlenebilmesi halinde silah üreticileri tarafından sunulan katlanabilir kanatlı veya uçaktan atıldıktan sonra açılan kumanda yüzeylerine sahip silahların seçilebilmesi mümkün olacaktır. Bu durum yerleşim ve dahili yuva tasarımı açısından büyük kolaylık sağlayan bir alternatif olarak ortaya çıkmaktadır. Fakat günümüzde beşinci nesil uçakların tedarikini öngören büyük savunma projelerinde taşınacak silahların neler olması gerektiği büyük çoğunlukla kullanıcı tarafından yazılan gereksinimlerle belirlenmekte olduğundan bu tasarım güçlüğü de kolayca elimine edilememektedir.

Geçmiş yıllarda dahili yuvalarda mühimmat taşıyabilen savaş uçakları tasarlanırken dahili yuvaların sadece silahlar için kullanılacağı varsayımı ile hareket edilmiş ve diğer ekipmanların silah yuvası içerisinde konuşturılması gibi kısıtlayıcı bir tasarım girdisi söz konusu olmamıştır. Ancak beşinci nesil bir uçağın tasarımında uçağın boyutlarını büyütmeyecek şekilde dahili ekipman yerleşimi en önemli gereksinimlerden biri olarak gündeme gelmiş ve yer kısıtları nedeniyle silah yuvasının diğer ekipmanlarla ortak kullanılması zarureti doğmuştur. Bu nedenle dahili silah yuvası tasarlanırken taşınacak silahların ön yerleşimi yapılmalı ve bu bölgede konuşturılacak diğer üniteler, silah yuvası kapak mekanizmaları, elektrik sistemine ait kablolar, akışkan sistemlerine ait borular ve diğer

aviyonik ekipmanlar silah yerleşimine ve aynı zamanda operasyon esnasında yükleme indirme işlemlerine engel olmayacak şekilde yerleştirilmesi gerekmektedir (Şekil 5).



Şekil 5. Dahili Silah Yuvası Personel Erişim Çalışması Örneği [4]

Silah sistemi tasarımı açısından dahili silah yuvası içerisinde yerleşimi etkileyen bir diğer faktör de taşınması planlanan farklı mühimmatların farklı boyutlarda, ağırlıklarda olması ve bağlantı yöntemlerinin aynı olmamasıdır. Tasarımda bütün bu farklılıkları göz önüne alarak tüm mühimmatların taşınmasını ve atılabilmesini sağlayan bir yaklaşımın benimsenmesi gerekmektedir. Bu maksatla dahili silah yuvası içerisinde farklı geometrik özelliklere sahip mühimmatların ortak taşıma ekipmanlarına bağlanabilmesi amacıyla değişik boyut ve geometriye sahip adaptör parçalar tasarlanmalıdır. Bu yaklaşım operasyonel açıdan ekipman envanterini artıracak olsa da en küçük dahili yuva hacmi ile en fazla çeşit mühimmatın atılabilmesine olanak sağlayacaktır.

Dahili yuva içerisindeki sıkı yerleşim zorunluluğu, yerleşimi yapılacak olan mühimmatın yer personeli tarafından monte edilip sökülmesi ve en önemlisi de mühimmatın uçaktan atılması esnasında emniyetli ayrılmanın sağlanabilmesi açısından mühimmat ile dahili yuva içerisindeki yapılar ve ekipmanlar arasında sürekli olarak muhafaza edilmesi gereken güvenli bir bölge ihtiyacı ortaya çıkmaktadır. Mühimmatın monte edildiği bölgede, uçağın normal uçuş zarfı içerisinde maruz kalacağı manevra yükleri ve titreşimler nedeniyle çevreleyen yapı ve ekipmanlarla veya mühimmatın atışı esnasında dahili yuvadan ayrılırken çarpışma olasılığının ortadan kaldırılması amacıyla tasarım esnasında mühimmat çevresine

güvenli bir hacmin tanımlanması gerekmektedir. Bu hacim içerisinde hiçbir ekipmanın monte edilmesine ve herhangi bir yapısal parçanın bu hacimden geçmesine müsaade edilmeyecek şekilde yerleşim yapılmalıdır. Tasarım yaklaşımı olarak bu tür bir güvenli hacim bırakılması zorunlu olmakla birlikte, bu hacmin ne kadar olacağı konusu her tasarımın özelliklerine göre değişkenlik gösterebilmektedir. Bırakılacak hacmin yeterliliği ancak bilgisayar ortamındaki güvenli ayrılma analizleri, rüzgâr tüneli testleri ve nihayetinde de yerde ve uçuşta atış testleri ile doğrulanabilmektedir. Ancak tasarım için bir başlangıç noktası teşkil edebilmesi açısından MIL-STD-1289D “Airborne Stores Ground Fit And Compatibility, Requirements” standardı gibi bir referansta sağlanan değerler ile yola çıkılabilmesi mümkündür. Ancak bu tür standartlarda verilen değerler genel durumlar dikkate alınarak belirlendiği için verilen güvenli bölge değerleri zaman zaman fazlasıyla güvenli tarafta kalabilmekte ve bu durum da dahili silah yuvasının gereğinden fazla büyümesine yol açabilmektedir. Bu nedenle tasarlanan sistemin özellikleri ile standartlarda sunulan değerler arasında belli bir dengeyi gözeterek şekilde bir tasarım yaklaşımının benimsenmesi en uygun sonuçların elde edilmesini sağlayacaktır.

3. HARİCİ SİLAH TAŞIMA TASARIM YAKLAŞIMI

Beşinci nesil savaş uçaklarında harekât esnasında düşük görünürlük avantajının korunması açısından silah taşıma işinin dahili olarak yapılması esastır. Ancak radar tehdidinin düşük olduğu belli görevlerde kanat altındaki istasyonlardan faydalanarak daha fazla mühimmat ile göreve çıkılması veya harici yakıt tankları kullanılarak menzil artırılması gibi faydaları nedeniyle beşinci nesil uçaklarda da harici yük taşıma yeteneğinin sağlanması istenmektedir. Harici silah taşıma tasarım yaklaşımı belli birkaç farklılık dışında genel olarak geleneksel sistemlerdekine benzer şekilde olmaktadır. Harici yük istasyonları kanatların altında, kanat yapısındaki güçlendirilmiş noktalara bağlanan ve taşınacak yüke bağlı olarak farklılık gösterebilen pylon adı verilen ikincil yapılardır (Şekil 6). Mühimmatlar veya yakıt tankları, pylonlara monte edilen taşıma ve bırakma ekipmanları ile taşınmaktadır. Taşıma ve bırakma ekipmanları uçağın özelliklerine göre değişkenlik gösterebilse de geleneksel olarak yüksek tonajlı hava-yer mühimmatları veya yakıt tankları gibi en ağır yükler kanat altında uçak gövdesine en yakın istasyonlara takılırken hava-hava füzeleri gibi görece daha hafif yükler kanadın ucuna yakın istasyonlarda konumlandırılırlar. Kanat altında taşınacak yüklerin yerleşiminde ve pylon tasarımında, yükün uçuş esnasında taşınması gereken pozisyon analiz edilerek pylonlar buna göre tasarlanmalı ve üretilmelidir. Çoğu savaş uçağı uçuş esnasında

herhangi bir manevra yapmadığı yatay uçuş sırasında belli bir pozitif hücum açısı ile seyahat etmektedir. Kanat altında taşınan yüklerin yaratacağı aerodinamik sürüklemenin minimize edilmesi amacıyla harici yükler uçağa söz konusu hücum açısını sıfırlayacak veya sıfıra yaklaştıracak bir şekilde monte edilmelidir. Söz konusu açılı montaj ise pylonların uygun açı ile üretilmesi ile sağlanacaktır. Ayrıca bazı durumlarda uçak kanadından dolayı yüklere gelebilecek aerodinamik etkinin azaltılması amacıyla yüklerin burnu gövdeye yakın olacak şekilde yanal bir açıyla da yerleştirilebilmektedir.



Şekil 6. F-35 Hava Yer Yük Pylon'u [11]

Beşinci nesil uçaklarda yukarıda bahsedilen geleneksel harici yük tasarım yaklaşımından farklı olarak, kanat altında taşınan yüklerin uçağın radar görünürlüğüne artıracak olması gerçeğine rağmen mümkün olduğunca düşük görünürlüğe hizmet edecek tarzdeki askı ekipmanları ve pylonların kullanılması hedeflenmektedir. Bu tip askı ekipmanları pylonlar tasarlanırken düşük görünürlük sağlayacak şekilde tasarlanmalıdır. Bu tür bir yaklaşım birçok modern silahın veya diğer yüklerin kendi tasarımlarında yer alan düşük görünürlüğü de katkısıyla uçağın toplam radar kesitinin mümkün olduğu kadar düşük tutulmasında fayda sağlayacaktır.

Silah istasyonlarının yerlerinin belirlenmesinde ana kriterlerden birisi taşınacak silah ile kanat üzerindeki diğer yapılar, antenler, iniş takımları, flap ve eleron gibi kumanda yüzeyleri ile çakışmaların meydana gelmemesidir. Bu nedenle uçağa entegre edilmesi gereken silahlar ve diğer yükler tasarımın erken safhalarında kanat altı yerleşim analizine tabi tutulmalı ve bu yükler için de tıpkı dahili silah yuvasında olduğu gibi güvenli bölge tanımlanmalıdır. Sonraki aşamalarda uçak veya kanat tasarımında yapılacak değişiklikler veya eklenecek ekipmanlar da söz konusu güvenli bölge ile girişim yapmayacak şekilde tasarlanmalıdır (Şekil 7).



Şekil 7. F-35 Hava-Yer Yük Pylon’u Uçak Üstü Bağlantı Gösterimi [12]

Silah istasyonlarının kanat altında konumunun belirlenmesi için ele alınması gereken önemli bir husus da kanat, pylonlar, uçak gövdesi ve yükler arasındaki aerodinamik etkileşimdir. Hangi harici yükün nerede ve ne kadar taşınabileceğinin doğrulanabilmesi için çok detaylı statik stabilite, kontrol ve metrik yük testlerinin yapılması gereklidir. Farklı mühimmatların farklı uçaklardan ayrılma karakteristikleri ölçeklendirilmiş dinamik testlerle ve tutulu ayrılma testleri ile incelenir. Özellikle kanat altı pylonlarda ağır yükler taşınacak uçaklarda, yükün aerodinamik etkisi ve eylemsizliği nedeniyle oluşturacağı aeroelastik etkilerin ölçeklendirilmiş dinamik modellerle belirlenmesi gerekmektedir [13]. Bu nedenle farklı yükleme konfigürasyonları bir bütün olarak bilgisayar ortamında analiz edilmeli ve alınan sonuçlar öncelikle rüzgâr tüneli testlerinde, nihai olarak da uçuş testlerinde doğrulanmalıdır. Yapılan analizlerden elde edilen bulguların tasarıma erken safhalarda yansıtılması hem zaman kayıplarının hem de tasarımda büyük ölçekli geri dönüşlerin önüne geçilmesinde fayda sağlayacaktır.

4. TAŞIMA ve BIRAKMA EKİPMANI TASARIM YAKLAŞIMI

Taşıma ve bırakma ekipmanları bir savaş uçağında taşınacak her türlü mühimmatın veya yakıt tanklarının uçakla bağlantısını sağlayan, uçuş esnasında gelebilecek yüklere dayanabilecek şekilde sağlam üretilmiş olan ve istendiğinde bağlı olan yükü atabilme yeteneğine sahip mekanik ve elektriksel arayüz sağlayıcı ekipmanlardır. Adından da anlaşılacağı üzere bu

ekipmanın ana görevi bir yükü taşımak ve gerektiğinde güvenli bir şekilde uçaktan uzaklaştırılmasını sağlamaktır.

Taşıma ve bırakma ekipmanlarının, taşınacak yükün ne olduğuna göre farklı çeşitleri bulunmaktadır. Bu kapsamda en genel sınıflandırma taşınacak yükün uçaktan ayrılış şekline göre yapılmaktadır. Örneğin hava-hava füzeleri kendi roket motorlarını ateşleyerek uçaktan ayrılırlar ve bu nedenle ayrılış öncesi bağlı buldukları taşıma ekipmanı ray şeklinde bir yapıya sahiptir. Öte yandan hava yer tipi mühimmatlar uçaktan kendi ağırlıklarının etkisi ile veya itilerek ayrılırlar ve kancalar vasıtası ile üst taraftan asılı şekilde taşınacak taşıma ekipmanları ile taşınırlar.

En yaygın kullanımda olan taşıma ve bırakma ekipmanlarından birisi hava-hava füzeleri için kullanılan ray lançerdir (Şekil 8). Bu ekipmanda füzenin üzerinde bulunan ve tutunmasını sağlayan mekanik parçaların içine geçebileceği ve lançer boyunca bir kızak görevi gören raylar bulunmaktadır. Füze, pilot tarafından ateşlendiğinde belli bir itki seviyesi gelene kadar lançerde tutulmakta olup, istenen itki elde edildiğinde ise bir anda serbest kalmaktadır. Lançerin rayı boyunca hareket eden füze nihayetinde lançerden ayrılarak hedefe doğru uzaklaşır (Şekil 9).



Şekil 8. Örnek Ray Lançer Ekipmanı [14]



Şekil 9. Ray Lançer Uçak Üstü Gösterimi [15]

Yaygın kullanılan bir diğer taşıma ve bırakma ekipmanı çeşidi ise hava yer mühimmatları, harici yakıt tankları ve birçok harici yükün taşınması amacıyla kullanılan Ejection Release Unit veya Bomb Rack Unit olarak adlandırılan, yaygın Türkçe kullanımı ile Salan ekipmanıdır (Şekil 10, Şekil 11). En çok kullanılan salanlar taşıyacakları ağırlığa göre 1000 lb ve 5000 lb olmak üzere iki sınıfa ayrılmaktadır. Salanların çalışma prensibine göre de farklı çeşitleri bulunmaktadır. Bazı salanlar taşıdıkları yükü bir mekanizma vasıtası ile yüksek bir güç ile iterken bazı salanlar ise yükü yer çekiminin etkisine bırakarak yükün kendi ağırlığı ile ayrılması prensibine göre çalışmaktadır. Yerçekimi tipi salanlar çoğunlukla güvenli ayrılma risklerinin daha düşük olduğu, yavaş hızlarda hareket eden hava araçlarında kullanılabilmektedirler. Günümüzde yüksek hızlarda mühimmat atma gereksinimleri bulunan savaş uçaklarında bu tür salan kullanımı mümkün olamamaktadır. Savaş uçaklarında salanlar sadece mühimmatların taşınması ve atılmasında değil aynı zamanda harici yakıt tankları veya ikincil taşıma ve bırakma ekipmanlarının da taşınmasında kullanılabilmektedirler. İkincil taşıma ve bırakma ekipmanı kapsamına giren ekipmanlar çoklu bomba taşıyıcılar ve direk olarak uçak yapısına bağlanmayan ray lançerler gibi kendisi de taşıma ve bırakma ekipmanı olan ünitelerdir.



Şekil 10. Örnek Salan Ekipmanı [16]



Şekil 11. Salan Ekipmanı Test Sistemi Üstü Gösterimi [17]

Mühimmatlar salanlar üzerinde bulunan kancalara asılı olarak taşınmakta olup, atış anında bu kancaların açılması ve salan içerisinde ön ve arka konumda bulunan pistonların mühimmatı düşey eksende aşağı itmesi ile mühimmatın bırakılma işlemi gerçekleşmektedir. Geçmiş yıllarda üretilmiş olan salanlarda itme gücü piroteknik yöntemlerle sağlanmakta iken günümüzde birçok beşinci nesil platformda bu itme gücü pnömatrik basınç kaynağı kullanılarak sağlanmaktadır. Piroteknik yöntemde salan tasarımına bağılı olarak bir veya iki adet ateşleme kartuşu bulunmaktadır. Pilot tarafından atış yapıldığında kartuşlar içerisindeki barutun yanması sonucu ortaya çıkan basınçlı gaz söz konusu pistonları iterek mühimmatın atılmasını sağlamaktadır. Pnömatik sistemlerde ise aynı itme gücü yüksek basınçlı bir hava akümülatöründe bulunan havanın pistonlara sevk edilmesi ile elde edilmektedir. Beşinci nesil uçaklarda silah sistemi tasarımı yapılırken gerçekleştirilen fayda zarar analizleri sonucunda piroteknik salanların tasarım basitliğı açısından daha iyi olduğı ancak kimyasal reaksiyona dayalı bir sistem olması nedeniyle istikrarlı yanma performansı ve itme gücü üretme konusunda eksikleri bulunduğı, kartuşların patlayıcı ve dolayısıyla zaman aşımli malzemeler olmasından dolayı idame işletmede hem bakım maliyeti hem de nakliye ve depolama konusunda ilave yük getirdiğı görülmüştür. Pnömatik salanlar ise daha kompleks tasarım gerektirirken maliyet anlamında büyük tasarruf imkânı sunmaktadırlar [18].


Beşinci nesil uçakların taşıma ve bırakma ekipmanı tasarımında ortaya çıkan ana farklılık yine dahili silah yuvasından atılacak mühimmatlar için kullanılacak taşıma ve bırakma ekipmanlarının tasarım yaklaşımında görülmektedir. Dahili silah yuvasından mühimmatın istenen hızda itilerek uçaktan uzaklaştırılması güvenli ayrılma açısından büyük önem arz etmektedir. Bu nedenle salanların itme mesafesini uzun kılabacak ve aynı zamanda yer kısıtları sebebiyle dahili yuvada az yer işgal edecek tasarım yaklaşımlarının benimsenmesi gerekmektedir. Bu nedenle uçağı özel tasarım yapılması kaçınılmaz hale gelmektedir. Salan üzerindeki pistonların taşıma esnasında en az yer kaplayacak şekilde üretilmesi teleskopik piston kullanımını zorunlu kılmaktadır. Ancak bunun getireceğı rijitlik kayıpları mühimmatın dahili yuvadan aşağı itilirken etraftaki diğeri ekipmanlar ve uçak yapı ile girişimine neden olabileceğı dikkatten kaçırılmamalı, tasarımın erken safhalarında bu kapsamda gerekli analizler yapılarak güvenli çıkışı sağlayacak tedbirler alınmalıdır. Özellikle salan tasarımına eklenecek detay parçalar ile mühimmatın yanal yönde hareketini kısıtlayıcı önlemler alınması gerekmektedir. Harici taşıma açısından ise geleneksel tasarım yaklaşımlarının genel anlamda yeterli olacağı değerlendirilmektedir. Ek olarak, beşinci nesil bir uçakta düşük görünürlük

temel bir ister olduğundan salanlar ve füze lançerlerinin tasarımında da düşük görünürlük kaygısı göz önünde bulundurularak ilerlenmelidir.

5. TOP SİSTEMİ TASARIM YAKLAŞIMI

Hava topu sistemleri uzun yıllardır birçok askeri uçağın silah sistemi içerisinde yer ve hava hedeflerine karşı angajmanlarda ateş gücü sağlamak üzere tasarlanmış entegre bir ekipman olarak yer almaktadır. Tarihsel olarak bakıldığında hava araçlarında genelde makinalı tüfek ve otomatik top olmak üzere iki tip top sistemi kullanıldığı görülmektedir. Makinalı tüfekler daha düşük kalibreye sahip olup nispeten düşük ateş gücü gerektiren angajmanlarda kullanılmak üzere tasarlanırken, otomatik toplar yüksek atım sayısına sahip, uzun menzil sunan, tahrip gücü yüksek sistemlerdir.

Top sistemleri hava araçlarına yapı üzerine sabit bir şekilde monte edilerek (Şekil 12) ya da uçağın kanadı veya gövdesi altında taşınacak bir pod sistemi içerisine entegre edilerek (Şekil 13) taşınmaktadırlar. Yapıya monte edilen top sistemleri her zaman uçakta taşınırken, pod tipi sistemler görevin gerektirdiği duruma göre sökülüp takılarak kullanılabilirlerdir. Top sistemlerinde çok farklı tipte mermi kullanılabilirlerdir. En yaygın kullanılanlar; eğitim manevralarında kullanılan TP (Training Practice), hedefte patlama ve yanma etkisi yaratan HEI (High Explosive Incendiary) ve zırh delici özelliğe sahip AP (Armor Piercing) tipi mermilerdir. Top atış kontrol sistemlerinde nişan almak için kamera ve elektro-optik sistemler kullanılabilir gibi radar sistemlerinden destek alan radar güdümlü sistemlerde kullanılabilirlerdir.



Şekil 12. F-35 Top Sistemi Uçak Üstü Yerleşimi [4]



Şekil 13. F-35 Top Sistemi Pod Yerleşimi [4]

Top Sistemleri geçmiş yıllarda uçakların muharebe yeteneğine büyük katkılar sağlamış, harekât alanlarında gerek yer hedeflerine gerekse hava hedeflerine karşı etkili bir silah olarak kullanılmışlardır. Günümüzde özellikle beşinci nesil uçaklarda radar teknolojisinin gelişimi ve çok sayıda sensörden alınan bilgilerin füzyonu sayesinde hedeflerin tespit edilebileceği mesafelerin artmış olması, akıllı mühimmatlarla ve görüş ötesi hava-hava füzeleri ile hedeflere uzak mesafelerden taarruz gerçekleştirilebilmesi ve düşük görünürlük özellikleri sayesinde karşı tarafa görünmeden belirli bir mesafeye kadar yaklaşarak ilk atışın yapılabilmesi avantajları ile angajman mesafesi artık top sistemlerinin etkili menzillerinin oldukça dışında kalmaktadır [19]. Dolayısıyla silah sistemi içerisinde geçmişteki önemini nispeten yitirmiştir. Ancak kullanıcı tarafından halen belli durumlarda görüş içi hava-hava veya belirli yakın hava desteği gibi görevlerde hava-yer hedeflerine karşı kullanılmak üzere talep edilmektedir.


Beşinci nesil uçaklarda entegre edilecek top sisteminin geleneksel sistemlerle arasındaki en belirgin farklılık uçağın düşük görünürlük özelliğini muhafaza edecek şekilde tasarlanması gereksinimidir. Bu amaçla top sistemine ait ekipmanlar ve özellikle namlu kısımlarının uçağın ana gövdesi içerisinde gizlenmesi ve sadece top atışı esnasında açığa çıkarılmasını öngören bir tasarım yaklaşımı izlenmesi gerekmektedir. Bu maksatla gövdeye yapışık bir şekilde tasarlanan bir kapak namluyu veya namluları gizli tutmaktadır. Pilot tarafından atış komutunun gönderilmesi ile birlikte kapak açılarak atış gerçekleştirilmekte, komutun kesilmesinin ardından ise kapak tekrardan kapanmaktadır.

Diğer sistemlerde olduğu gibi top sisteminin de yerleşiminin uçak tasarımının ilk safhalarında netleştirilmesi gerekmektedir. Çünkü top sistemi çalışması esnasında gerek namlunun ön tarafından herhangi bir sistemin bulunmamasının elzem olması gerekse çalışma esnasında uçağa aktardığı geri tepme nedeniyle sebep olduğu titreşim etkisi nedeniyle diğer sistemlerin sağlığı açısından özel dikkat gösterilmesi gereken bir sistemdir. Uçağın harekât

yetenekleri ile ilgili olarak kullanıcı tarafından bildirilen isterler dikkate alınarak hangi top sisteminin entegre edileceğine dair kararın verilmesi sonrasında ilgili top sisteminin yerleşiminin yapılacağı bölge belirlenerek, diğer sistemlerde olduğu gibi, bir güvenli hacim oluşturulmalıdır. Uçak tasarımının ilerleyen aşamalarında bu bölgeye başka bir sistem veya ekipmanın yerleştirilmemesi uygun olacaktır.

Uçak yapısına top sistemi tarafından iletilecek geri tepme etkisinin bir kısmının sönmülmesi için özel olarak üretilmiş ekipmanların kullanılması kaçınılmazdır. Uçak yapısalı üzerinde top sisteminin ağırlığı ve manevralar esnasında yapıya aktaracağı yük göz önüne alınarak güçlendirilmiş noktalardan söz konusu geri tepme sönmüleyicileri kullanılarak montajı gerçekleştirilmelidir. Top sisteminin atış hattı ile uçak nişangah hattı arasındaki eksenel kaçıklıklar montaj esnasında kayıt altına alınmalı ve atış kontrol sistemi tasarımında bu kaçıklıkların kompanse edilmesine yönelik hesaplamalar yapılmalıdır. Bu şekilde hedefe atış yapılırken hedefin konumu düzeltilerek pilot yönlendirilebilmektedir.

Uçak içerisinde mermilerin yerleştirileceği ekipmana mermi kutusu, buradan top sistemine taşındığı sisteme ise mermi yolu adı verilmektedir. (Şekil 14) Beşinci nesil uçaklarda mermi kutusu ve mermi yolu tasarımında en az hacim içerisinde en fazla merminin depolanabileceği ve aynı zamanda atılan mermilerden kalan kovanların düzgün bir şekilde aynı kutu içerisine geri toplanabileceği kapalı çevrim bir sistemin tasarlanması şarttır. Bu sayede hem yer tasarrufu sağlanarak uçağın boyutlandırılması olumsuz etkilenmeyecek hem de mermi kovanları uçak içerisinde bir hacim içerisinde serbest kalmayacak ve daha emniyetli bir tasarım sunulmuş olacaktır.



Şekil 14. Top Sistemi Alt Bileşen Gösterimi [20]

Top sistemi entegrasyonunda dikkate alınması gereken bir diğer konu ise atış esnasında mermilerin ateşlenmesi ile ortaya çıkacak olan barut gazı ve ısının tahliyesidir. Bu amaçla top sisteminin konuşlandırıldığı bölgeye ilişkin gerekli termal analizler yapılarak ne kadarlık bir havalandırma ihtiyacı olacağının belirlenmesi gerekmektedir. Havalandırma ihtiyacına cevap verecek şekilde gerekli tahliye kapakları uçak yapısalı üzerinde tasarlanarak ilgili kapakların top sistemi ile senkron bir şekilde çalışması sağlanmalıdır.

Top sisteminde kullanılacak olan mermilerin görev öncesi uçağa yüklenebilmesi için bazı özel teçhizatlar kullanılmaktadır. Bu teçhizatlar uçak yerde iken uygun bir yükleme arayüzü vasıtası ile uçağa bağlanarak mermilerin mermi kutusuna aktarılması sağlanmaktadır. Bu aktarım için ihtiyaç duyulacak mermi yükleme kapakları da top sisteminin ve mermi kutusunun uçak üzerindeki yerleşimine uygun olacak ve yer personelinin kolay çalışmasına imkân sağlayacak konumlar göz önünde bulundurularak tasarlanmalıdır.

6. ATIŞ KONTROL ve YÜK YÖNETİM SİSTEMİ TASARIM YAKLAŞIMI


Mühimmatların atışa hazırlanması, güvenli bir şekilde uçaktan bırakılması ve sonrasında hedefe yönlendirilmesi için birçok alt sistemin birbiri ile uyumlu olacak şekilde çalışması gerekmektedir. Emniyet ve sertifikasyon gereksinimleri değerlendirildiğinde hem personelin hem de uçağın güvenliğini tehlikeye atmayacak şekilde atış ve yük yönetim kontrolünün gerçekleştirilmesi gerekmektedir. Bu sebeple söz konusu gereksinimleri sağlamak adına uçaklarda Atış Kontrol ve Yük Yönetim Sistemi (Fire Control and Store Management System) bulunmaktadır. Atış Kontrol ve Yük Yönetim Sistemi, uçak üzerinde yüklü olan mühimmatların sisteme girişinin yapılmasından, taşıma ve bırakma ekipmanlarının kontrolünden, mühimmatların doğru bir şekilde atışa hazırlanması için gerekli veri akışının sağlanmasından, atış için ihtiyaç duyulan hesapların yapılmasından ve mühimmatın istenildiği anda uçaktan bırakılmasından sorumludur. Bu bölümde Atış Kontrol ve Yük Yönetim Sistemi tasarımı için ihtiyaç duyulan gereksinimler ve bu gereksinimleri sağlamak için uygulanan çözüm yöntemlerinin değerlendirilmesi yapılacaktır.

Doğru bir Atış Kontrol ve Yük Yönetim Sistemi tasarımında dikkat edilmesi gereken öncelikli ve en önemli gereksinim güvenliktir. Herhangi bir hata durumunda sistemin güvenli konuma (Fail-Safe) geçecek şekilde tasarlanması gerekmektedir. Ek olarak, ihtiyaç duyulduğunda sistemin kullanılabilir olması da gerekmektedir. Bu iki temel gereksinim (güvenlik ve kullanılabilirlik) her ne kadar birbiri ile çelişiyor olsa da Atış Kontrol ve Yük Yönetim Sistemi tasarımında değerlendirilmesi gereken önemli hususlardır. Arayüz ve

gerçekleştirilecek fonksiyonların tanımlanmasının ardından platform üzerinde uygulanacak olan aviyonik mimarinin belirlenmesi ile tasarıma başlamak gerekmektedir [3].

Aviyonik tasarımında teknolojik imkanlar ve gelişmeler dahilinde farklı tasarım çözüm yaklaşımları kullanılmıştır. Her ne kadar ortaya çıkan çözümler maliyet artışına sebep olsa da performans artışları, güvenilir çözümlerin ortaya konuluyor olması, boyut, ağırlık ve güç tüketiminde sağlanan azalmalar ilgili teknolojilerin tercih edilmesinde önemli bir rol oynamıştır. 1960’lı yıllardan günümüze kadar gelişim göstermiş temel aviyonik mimari çözümleri; Dağıtık Analog Mimari, Dağıtık Dijital Mimari, Federe Dijital Mimari ve Entegre Modüler Mimari olarak verilmiştir [21].


Dağıtık Analog Mimari’de, kaynak ve alıcılar birbirine noktadan noktaya (peer-to-peer) bağlıdır. Sistemde merkezi bir kontrol ekipmanı bulunabilirken, alt sistemlere özel atanmış kontrol ve görüntüleme ekipmanları da kullanılabilir. Bu çözümde platform üzerinde yüksek miktarda kablo kullanılmakta olup, sonuç olarak fazla kablolara sebep olmaktadır. Sistem üzerinde değişiklik yapılma ihtiyacı olması durumunda mimaride büyük değişikliklerin yapılması gerekmektedir [21]. Örnek bir Dağıtık Analog Mimari Şekil 15’te gösterilmiştir.



Şekil 15. Dağıtık Analog Mimari Örneği [21]


Dijital haberleşme arayüzleri ile kontrol ekipmanlarının teknolojik gelişimi ve bu sistemlerin uçaklarda kullanılabilir olmasıyla birlikte aviyonik mimaride dijitalleşme süreci başlamıştır. Dağıtık Dijital Mimari’de fark yaratan en büyük değişiklik dijital haberleşme arayüzlerinin (örn. Tornado 64 kbit/s) kullanılması ile birçok farklı alt sistemin birbirleriyle haberleşebilir hale gelmiş olmasıdır [21]. Bu çözüm, kaynak ve alıcılar arasındaki kablolara azaltarak platform ağırlığının düşürülmesinde önemli bir rol oynamıştır. Ek olarak, kullanılan

arayüzlerin standartlaşmasıyla birlikte sistem üzerindeki değişikliklerin kolay bir şekilde ele alınması sağlanmıştır. Örnek bir Dağıtık Dijital Mimari örneği Şekil 16’da verilmiştir.



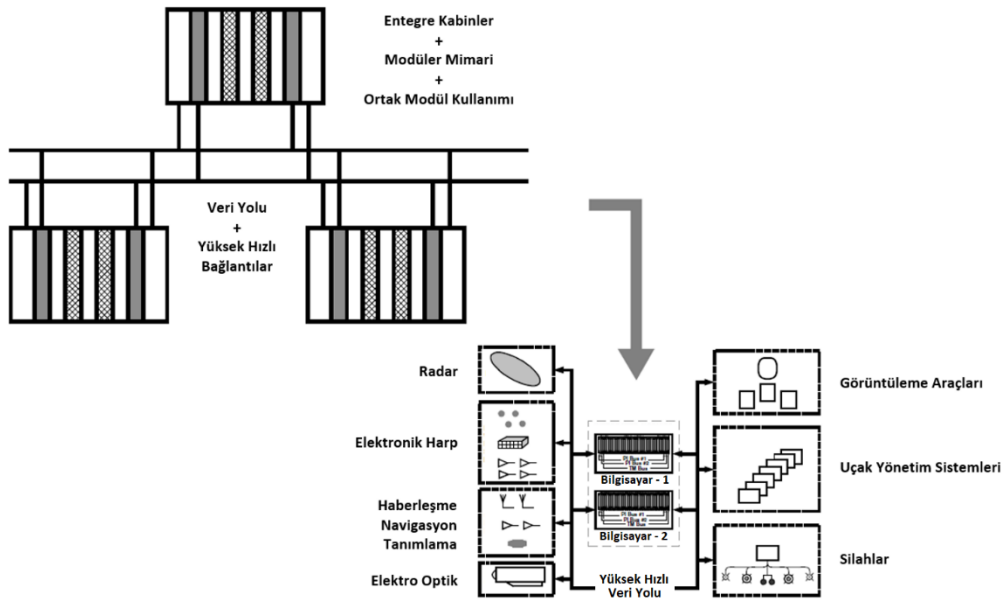
Şekil 16. Dağıtık Dijital Mimari Örneği [21]

MIL-STD-1553 “Interface Standard for Digital Time Division Command/Response Multiplex Data Bus” askeri dijital haberleşme arayüzünün kullanılabilir hale gelmesi ile birlikte kaynak ve alıcılar arasında yüksek hızlı (1 Mbit/s) iletişim sağlanabilmektedir. Ayrıca teknolojik gelişmeler ile daha hızlı hesap yapan kontrolcüler üretilmeye başlanmıştır. Söz konusu gelişmelerin uygulanması ile Federe Dijital Mimari’ler ortaya çıkmıştır. Bu mimaride fark yaratan en büyük değişiklik platform üzerinde bulunan alt sistemlerin kendi kontrolcülerini kullanmaya başlayarak diğer sistemlerden bağımsız hale gelmesidir [21]. Bu şekilde farklı alt sistemler kendine ait ekipman, donanım ve yazılım kullanmaya başlamış ve böylece sistemler arası hata izolasyonu sağlanmıştır. Sistemler arası farklılaşma ise farklı tipte donanımların tasarlanmasına ve bu ürünlerin lojistik olarak idame edilmesinde zorluklara sebep olmuştur. Örnek bir Federe Dijital Mimari örneği Şekil 17’de verilmiştir.



Şekil 17. Federe Dijital Mimari Örneği [21]

Teknolojik gelişmeler ve bu teknolojilerin uçaklara entegre edilmesi ile farklı sistemler tarafından gerçekleştirilen fonksiyonlar merkezi ve modüler bir sistem üzerinde toplanarak modern bir yaklaşım olan Entegre Modüler Mimari ortaya çıkmıştır [21]. Bu mimarinin temel kazancı federe mimarilerin sağlamış olduğu hata izolasyonu ile merkezi mimarinin sağlamış olduğu hafiflik ve maliyet avantajlarını birleştirerek hava aracı tasarımını kolaylaştırmaktır. Bu çözümde farklı kritiklik seviyelerine sahip yazılımlar tek bir kontrolcü üzerinde yedekli olarak çalışabilmektedir. Yani, kritik seviye bir yazılımın herhangi bir sebepten dolayı işlevsiz hale gelmesi durumunda farklı bir yazılım bölümü üzerinde yazılımın yeniden başlatılması ile gerçekleştirilen fonksiyonun sürekliliği sağlanabilmektedir. Örnek bir Entegre Modüler Mimari örneği Şekil 18’de verilmiştir.



Şekil 18. Entegre Modüler Mimari Örneği [21]

Yukarıda verilmiş olan çözümler genel aviyonik mimari yaklaşımlarına yönelik bilgi vermekte olup, hava aracında uygulanacak çözüme göre Atış Kontrol ve Yük Yönetim Sistemi tasarımı gerçekleştirilmelidir. Beşinci nesil savaş uçaklarında güncel teknolojilerin yer almakta olduğu Entegre Modüler Mimari’ler kullanılmaya başlanmıştır. Bu şekilde günümüz teknolojilerine uygun yazılım ve donanım geliştirme çözümleri kullanılarak, ilerleyen dönemde yeni sistemlerin platforma kolay ve hızlı entegrasyonuna yönelik esnek bir yapı ortaya konmaktadır. Uçak üzeri sistemlerin birbirleri ile olan arayüzlerinin belirlenmesinin ardından, Atış Kontrol ve Yük Yönetim Sistemi’nin kontrol edeceği mühimmat ve ekipmanlar ile arayüzlerinin belirlenmesi gerekmektedir.

Mühimmatların farklı hava araçları tarafından kullanılabilmesi için platform-mühimmat arasındaki arayüzlerin ortaklaşma ihtiyacı ortaya çıkmıştır. Platformların farklı mühimmatlar ile çalışabilirliğini sağlamak için MIL-STD-1760 “Aircraft/Store Electrical Interconnection System” askeri standardı ortaya konarak elektriksel, sayısal ve fiziksel arayüzlere yönelik gereksinimler tanımlanmıştır. Bu standart hem platform hem de mühimmat tarafındaki arayüzlere yönelik bilgiler içerdiği için standarda uygun geliştirilmiş sistemlerin birbirleri ile entegrasyonları kolay bir şekilde yapılabilir.

MIL-STD-1760 standardı ile iki sistem arasında bulunan elektriksel bağlantıların tipleri (örn. güç, sayısal, ayrık), sayıları ve kullanılacak konnektör bilgileri belirlenmiştir. Ek olarak, sayısal haberleşme üzerinden gidecek olan mesajların kullanımına yönelik bir kılavuz oluşturulmuştur. Bu şekilde, platform ve mühimmat arasındaki uyum sağlanarak, bu sistemlerin birbirleri ile olan entegrasyonunda esneklik sağlanmıştır. İki sistem arasındaki arayüzlere ek olarak standartta mühimmatların güvenli bir şekilde taşınması ve bırakılmasına yönelik bilgilerde bulunmakta olup, kaza riski oluşturabilecek durumlara karşı hangi önlemlerin alınması gerektiği ile ilgili de çözüm önerileri verilmektedir.

Geleneksel silah entegrasyon yaklaşımına göre platform üzerinde bulunan yazılımın (OFP: Operational Flight Program) entegre edilecek olan mühimmatın sayısal arayüz bilgilerine göre modifiye edilmesi gerekmektedir. Güncellenmiş olan yazılımın platformda kullanılabilir hale gelmesi için test ve kalifikasyon gibi zaman ve maliyet bakımından masraflı süreçlere tabi tutulması gerekmektedir. Platform üzerinde yapılacak güncellemeler birçok alt sistemden gelen değişikliklerin toplanması ile ele alındığı için yazılım güncelleme süreci uzun zaman periyotlarında yürütülmektedir.

Söz konusu süreçleri kısaltmak, platform üstü yazılım değişikliklerini düşük seviyede tutmak ve maliyet etkin bir çözüm ortaya koymak için hızlı entegrasyon konseptleri ortaya konmuştur. Bu konseptlere Amerika Birleşik Devletleri'nin kendi kullanımı için oluşturup, diğer ülkelerle paylaşımı askeri ihraç lisansı ile kısıtladığı Evrensel Silahlanma Arayüzü (UAI: Universal Armament Interface) ve NATO'nun üzerinde çalışmakta olduğu Mantıksal Yük Arayüz Yapısı (LSIF: Logical Store Interface Framework) örnek verilebilir. Söz konusu yaklaşımlar ile ilgili çalışmalar halen devam ettiği için konseptlerin detaylarına yönelik bilgilere ulaşılamamaktadır. İlgili çalışmaların tamamlanıp askeri standart haline gelmesi, Atış Kontrol ve Yük Yönetim Sistemi ve mühimmatların ilgili standartta verilmiş bilgilere göre tasarlanması ile platform-mühimmat arasındaki entegrasyon geleneksel yöntemlere göre daha hızlı ve verimli bir şekilde ele alınabilecektir.

7. SONUÇ ve DEĞERLENDİRMELER

Çalışma kapsamında yeni nesil savaş uçaklarında uygulanan silah sistemi tasarım yaklaşımları incelenmiştir. Yapılan değerlendirmede söz konusu tasarım yaklaşımlarında uygulanması önerilen çözümler ile bu çözümlerin temel özellikleri göz önünde bulundurulmuştur. Önerilen çözümlerin eski nesil uçaklarda uygulanmış yöntemlere göre farkları ortaya konarak tasarım yaklaşımlarının kıyaslaması yapılmıştır. Eski nesil savaş uçaklarının sahip oldukları teknolojiler ve silah sistemi yeteneklerinin güncel harekât ihtiyaçlarını sağlamak konusunda yetersiz kaldığı belirlenmiştir. Söz konusu ihtiyaçları karşılamak adına gelişen teknoloji ve modern tasarım çözümlerinin yeni nesil savaş uçaklarına uygulanması ile savaş ortamındaki üstünlüğün sağlanabileceği değerlendirilmiştir.

Beşinci nesil savaş uçaklarının en belirgin ayırt edici özelliği olan düşük görünürlüğü sağlamak için uçak üzerinde taşınacak olan mühimmatların uçak gövdesi içerisinde dahili silah yuvalarında taşınması gerekmektedir. Söz konusu silah yerleşimini mümkün kılabilmek için uygulanabilecek yan yana, arka arkaya, düşey ekseninde sıralanmış ve dönerli silah yerleşim çözüm alternatiflerinin teknik özellikleri ve bu yaklaşımların birbirlerine göre üstünlükleri karşılaştırmalı olarak incelenmiştir. Yerleşim yöntemi belirlenirken mühimmat yükleme ve mühimmatın uçaktan güvenli ayrılması için dikkat edilmesi gereken hacimlerin belirlenmesine yönelik yaklaşımlardan bahsedilmiştir. Sonuç olarak, her ne kadar dahili silah yuvası tasarımında farklı tasarım yaklaşımları ve bu tasarım yaklaşımlarının birbirlerine göre üstünlükleri bulunsada seçilecek olan yöntemin uçak tasarım kısıtlarına göre belirlenmesi gerektiği görülmüştür.

Beşinci nesil savaş uçaklarında düşük görünürlük avantajının korunması için mühimmatların dahili silah yuvalarında taşınması tercih edilse de radar tehditlerinin düşük olduğu görevlerde daha fazla sayıda mühimmat taşımak veya harici yakıt tankı kullanarak menzil artırımı yapmak adına harici yük taşıma isteklerinin tasarıma dahil edildiği görülmüştür. Söz konusu ekipmanların yerleşimini mümkün kılmak için tasarım ve yerleşimde dikkat edilmesi gereken hususlar incelenmiştir. Beşinci nesil uçakların sahip olduğu görünürlük avantajını kaybetmemek için harici yük taşımada düşük görünürlüğe sahip ekipmanların kullanılması gerektiği değerlendirilmiştir.

Dahili ve harici taşıma yapılırken kullanılan taşıma ve bırakma ekipmanlarının neler olduğu ve bu ekipmanların birbirlerine göre farkları karşılaştırmalı olarak incelenmiştir. Özellikle dahili silah yuvasında kullanılacak taşıma ve bırakma ekipmanlarının en az yer kaplayacak ve kullanılacağı platformun mekanik yapısına özel olacak şekilde tasarlanması

gerektiği değerlendirilmiştir. Dahili silah yuvasından mühimmat atışı yapılırken mühimmatın hızlı bir şekilde uçaktan uzaklaştırılabilmesi için güvenli ayrılma analizlerinin taşıma ve bırakma ekipmanlarının tasarım süreci ile paralel yürütülmesinin olası ihtiyaçların erken safhada fark edilerek, gerekli düzeltmelerin tasarıma uygulanması adına kritik öneme sahip olduğu değerlendirilmiştir.

Teknolojik gelişmelerin yeni nesil savaş uçaklarına uygulanması ile birlikte önceki nesillerde daha yüksek harekât avantajı sağlayan top sistemleri yeni nesil savaş uçaklarının gelişmiş sensörlere sahip olması, akıllı mühimmatların kullanımı ve düşük görünürlük özelliğinden dolayı top atışının angajman mesafesi bakımından etkin menzillerinin dışında kalarak avantajını kaybetmiştir. Fakat özellikle kullanıcıların geçmiş alışkanlıkları bakımından yakın hava desteği gibi bazı görevlerde kullanmak üzere yeni nesil savaş uçaklarında da top sisteminin bulunmasını tercih ettikleri görülmektedir. Beşinci nesil savaş uçaklarında top sisteminde bulunan namlu ve tahliye yolları gibi uçak dışına açılan bölümlerin uçağın ana yapısı içerisine gizlenerek, platformun görünürlük avantajının korunması gerekmektedir. Bu bakımdan diğer sistemlerde olduğu gibi top sisteminin tasarım ve yerleşim çalışmaları da uçak tasarım kısıtlarına göre ilerletilmesi gerekmektedir.

Silah sisteminin kontrolünü sağlayarak başarılı bir angajman gerçekleştirmek için ihtiyaçları karşılayan etkin bir Atış Kontrol ve Yük Yönetim Sistemi tasarlanması gerekmektedir. Teknolojik gelişmeler ve bu gelişmelerin hava araçlarına uygulanması ile farklı yaklaşımlara sahip aviyonik tasarım çözümleri ortaya konmuştur. Söz konusu aviyonik mimarilerinin teknik özellikleri ve bu çözümlerin birbirlerine göre üstünlükleri karşılaştırmalı olarak incelenmiştir. Her ne kadar aviyonik mimarilerin birbirlerine göre avantajları bulunsa da beşinci nesil savaş uçaklarında modern teknolojilerin tercih edildiği Entegre Modüler Mimari’ler kullanılmaktadır. Bu şekilde ilerleyen dönemde gelebilecek yeni sistemlerin kolay ve hızlı entegrasyonuna yönelik esnek bir yapının oluşturulması tercih edilmektedir. Ayrıca güncel teknolojilerle uyumlu yazılım ve donanım tasarım ortamlarının kullanılması ile hızlı çözümler ortaya konulabilmekte, özellikle geliştirme süreçleri kısaltılarak maliyet etkin entegrasyon konseptleri oluşturulabilmektedir.

Sonuç olarak, artan harekât ihtiyaçlarını karşılayabilmek ve savaş ortamında hava üstünlüğü sağlamak için farklı kabiliyet ve özelliklere sahip savaş uçakları nesiller boyunca geliştirilmiştir. Özellikle teknoloji alanındaki gelişmeler ve bu gelişmelerin hava araçlarına uygulanması ile farklı yeteneklere sahip platformların tasarlanmasına olanak sağlanmıştır. Söz konusu hava araçlarının modern silah sistemleri ile donatılması için fonksiyonların doğru bir

şekilde belirlenmesi ve bu fonksiyonların etkin bir şekilde kullanılabilmesi için uçak tasarımının başlangıcından itibaren dikkate alınması gereken tasarım yaklaşım çözümlerinin detayları ortaya konmuştur. Önerilen tasarım çözümlerinin yeni nesil savaş uçakları silah sistemi tasarımında değerlendirmeye alınması ve uygulanması ile etkin operasyon gücüne sahip savaş uçaklarının tasarlanması sağlanacaktır.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması yoktur.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

KAYNAKLAR

- [1] Wikipedia. (2024, Haz. 8). *Askerî uçak* [Online]. Available: https://tr.wikipedia.org/wiki/Askerî_uçak
- [2] G. Martinic, “Jet fighter aircraft - five 'generations' later, and still counting..”, *Naval Engineers*, Apr. 2015.
- [3] K. A. Rigby, *Aircraft Systems Integration of Air-Launched Weapons*. John Wiley&Sons, Ltd., 2013.
- [4] J. W. Hamstra, *The F-35 Lightning II: From Concept to Cockpit*. American Institute of Aeronautics and Astronautics, Inc., 2019.
- [5] E. Helfrich. (2023, Mar. 24). *F-35 Closer To Carrying Six AIM-120 Missiles Internally* [Online]. Available: <https://www.twz.com/adapter-for-f-35-internal-carriage-of-six-aim-120-missiles-is-progressing>
- [6] R. E. Dix and R.C. Bauer, *Experimental and Theoretical Study of Cavity Acoustics*. Arnold Engineering Development Complex, 2000.
- [7] D. Bacci, “Transonic Aero-Acoustics of Weapon Bays”, PhD. dissertation, Dept. Centre for Defence Eng., Cranfield Univ., Shrivenham, Swindon, 2017.
- [8] T. Rogoway. (2019, Ara. 1). *China’s J-20 Stealth Fighter Stuns By Brandishing Full Load Of Missiles At Zhuhai Air Show* [Online]. Available: <https://www.twz.com/24841/chinas-j-20-stealth-fighter-stuns-by-brandishing-full-load-of-missiles-at-zhuhai-air-show>

- [9] Z. Probst, “Design and Flight Test Of A Weapons-Cavity Acoustics And Store Separation Test Bed”, MSc. dissertation, Dept. Aeronautical Eng., Air Univ., Alabama, AL, 2016.
- [10] D. Bacci, A.J. Saddington and D.Bray, “The Effect of Angle of Attack on the Aeroacoustic Environment Within The Weapon Bay of a Generic UCAV”, *Aerospace Science and Technology*, vol. 93, 105315, Oct 2019.
- [11] Marvineng. (2024). *F-35 Air-to-Ground Pylon* [Online]. Available: https://marvineng.com/product_category/complex-systems/
- [12] Marvineng. (2024). *F-35 AAE Management & Sustainment* [Online]. Available: <https://marvineng.com/story/f-35-ame/>
- [13] S.B. Moore, “Wind-Tunnel Systems and Techniques for Aircraft/Stores Compatibility Studies”, *J. Aircraft*, vol. 8, no 12, Dec 1971.
- [14] Marvineng. (2024). *LAU-128 Missile Rail Launcher* [Online]. Available: https://marvineng.com/product_category/launch-systems/
- [15] Defenceturk. (2020, Ağu. 29). *ABD, Japonya'ya AIM-120C-8 satışına onay verdi* [Online]. Available: <https://www.defenceturk.net/abd-japonyaya-aim-120c-8-satisina-onay-verdi>
- [16] Marvineng. (2024). *BRU-32B/A Ejector Release Unit* [Online]. Available: https://marvineng.com/product_category/ejector-racks/
- [17] R. Phillips. Force Base. (2008, Jun. 17). *STEM facility conducts F-35 lanyard risk reduction test* [Online]. Available: <https://www.eglin.af.mil/News/Article-Display/Article/393053/stem-facility-conducts-f-35-lanyard-risk-reduction-test/>
- [18] D. M. Hayward, A. K. Duff and C. Wagner, “F-35 Weapons Design Integration,” in *Conf. Aviation Technology, Integration, and Operations*, Atlanta, GA, 2018, pp. 1-22.
- [19] M. Janošek and A. Svoboda, “Performance of Aircraft Cannons in Terms of Their Employment in Air Combat”, *Advances in Military Technology*, vol. 2, no 2, pp. 33-44, Mar 2022.
- [20] Wikipedia. (2024, Eyl. 12). *M61 Vulcan* [Online]. Available: https://en.wikipedia.org/wiki/M61_Vulcan
- [21] I. Moir and A. G. Seabridge, *Military Avionics Systems*. John Wiley&Sons, Ltd. 2006.