



Turbofan motorlarının kestirimci bakımında makine öğrenimi algoritmaları performanslarının karşılaştırılması

Comparison of machine learning algorithms performance in predictive maintenance of turbofan engines

Osman Güler^{1,*} 

¹ TUSAŞ Şehit Hakan Gülşen Mesleki ve Teknik Anadolu Lisesi, 06890, Ankara Türkiye

Öz

Endüstri 4.0 kapsamında atılan önemli adımlardan birisi kestirimci bakım çalışmalarıdır. Bu sayede makine ve ekipman ömrünü uzatılmakta, çalışma verimliliği artırılmaktadır. Özellikle havacılık sanayii alanında uçuş güvenliği hayati önem taşıdığından dolayı, uçakların ve uçak motorlarının kestirimci bakım çalışmaları önemlidir. Bu çalışmada, turbofan motorlarının kalan faydalı ömrünü tahmin etmek için 10 farklı makine öğrenmesi algoritmaları kullanılmış ve sonuçları karşılaştırılmıştır. Eğitimler için NASA tarafından sunulan turbofan motorların belirli koşullar altında çalışma durumlarını gösteren CMAPSS veriseti kullanılmıştır. Çalışma sonuçları makine öğrenmesi modellerinin genel olarak birbirlerine yakın performans elde ettiğini göstermektedir. Yapılan deneyler sonucunda LDA algoritmasının en başarılı algoritma olduğu görülmüştür.

Anahtar kelimeler: Makine öğrenmesi, Kestirimci bakım, NASA Turbofan veri seti, Uçak motoru, Kalan faydalı ömür

1 Giriş

Günümüzde endüstriyel alanlarda maliyeti azaltmak, verimliliği ve üretim kapasitesini artırmak, makine ve ekipman ömrünü uzatmak için kestirimci bakım yaygın olarak kullanılan bir bakım stratejisidir. Kestirimci bakımın etkin olarak kullanıldığı alanlardan biri de havacılık sektörü ve uçak motorları bakımındır. Uçuşlarda meydana gelebilecek motor arızaları, ölümle sonuçlanabileceği için, uçak motorlarının arızaların önlenmesi ve bakımın doğru zamanda yapılması çok önemlidir.

Geleneksel uçak bakım yöntemlerinde, özel olarak eğitilmiş teknisyenler tarafından belirli zaman aralıklarında veya belirli bir motor çalışma saatine göre rutin bakım planlanmakta ve arıza durumunda bakım onarım faaliyetleri yapılmaktadır. Uçaklar gelişen teknoloji ile birlikte uçuş donanımlarının durumları, teşhisleri ve olası arızaları hakkında sürekli bilgi toplayan sensörlerle donatılmıştır [1]. Bu sensörlerden düzenli olarak gelen veriler sayesinde sorunları doğru bir şekilde tahmin etmek, bakım yöntemlerini kolaylaştırmıştır ve bakım faaliyetlerinin daha etkin bir şekilde planlanmasını sağlamıştır [2]. Kestirimci bakım, geleneksel periyodik bakım yönetimlerinin yerini

Abstract

One of the important steps taken within the scope of Industry 4.0 is predictive maintenance studies. In this way, machine and equipment life is extended and working efficiency is increased. Predictive maintenance studies of aircraft and aircraft engines are important, especially since flight safety is of vital importance in the aviation industry. In this study, 10 different machine learning algorithms were used to predict the remaining useful life of turbofan engines and their results were compared. For the trainings, the CMAPSS dataset, which shows the working conditions of turbofan engines under certain conditions, presented by NASA was used. The results of the study show that machine learning models generally achieve similar performance to each other. As a result of the experiments, it was seen that the LDA algorithm was the most successful algorithm.

Keywords: Machine learning, Predictive maintenance, NASA Turbofan dataset, Aircraft engine, Remaining useful life

alamaz belki ama bakım görevleri için bir zamanlama aracı sağlayarak daha güvenilir hale getirebilir [3]. Uçağın motor koşullarına ilişkin veriler sensör ile okunarak, motorun kalan faydalı ömrü (Remaining Useful Life-RUL) tahmin edilebilir, motorun ne zaman bozulacağını veya arızalanacağını kullanıcıya bildirilebilir [4].

Genel olarak kestirimci bakım çalışmaları planlı bakım ve plansız bakım olarak iki şekilde yapılmaktadır [5]. Aynı şekilde uçak motorları için kestirimci bakım çalışmaları çeşitli teknikler ve araçlar kullanılarak iki alanda gerçekleştirilebilir [6]. Birincisi, motorların çalışma verileri ve performansları izlenerek, bu veriler ile motorların bakıma alınma zamanları tahmin edilebilir. İkincisi, motor parçalarının durumu takip edilerek, önceden belirlenmiş bir zaman aralığında veya deforme olması durumunda değiştirilmesi sağlanabilir.

Uçak motoru RUL tahmini üzerine yapılmış olan birçok çalışma bulunmaktadır. Literatürde yapılan çalışmalar incelendiği zaman, kestirimci bakım ile uçak motoru üzerinde bulunan sensörlerden gelen verilerin, yapay zekâ teknikleri kullanılarak analiz edildiği görülmektedir. Çalışmalarda genel olarak Ulusal Havacılık ve Uzay Dairesi

* Sorumlu yazar / Corresponding author, e-posta / e-mail: hanciosman@hotmail.com (O. Güler)

Geliş / Received: 16.03.2023 Kabul / Accepted: 29.10.2023 Yayınlanma / Published: 15.01.2024

doi: 10.28948/ngumuh.1266541

(National Aeronautics and Space Administration-NASA) tarafından havacılık endüstrisinde motor bakımını geliştirmek ve uçak güvenliğini artırmak amacıyla sunulan Ticari Modüler Havacılık Tahrik Sistemi Simülasyonu (Commercial Modular Aero-Pulsion System Simulation – C-MAPSS) veri setinin kullanıldığı görülmüştür. C-MAPSS veriseti, uçak turbofan motorlarının performansını izleme ve kestirimci bakım tahmini için yaygın olarak kullanılan önemli bir kaynaktır. Makine öğrenmesi, derin öğrenme, nesne algılama, veri oluşturma ve bulanık mantık teknikleri araştırmacılar tarafından kullanılan çeşitli yöntemlerdir.

Kızrak vd. [6], C-MAPSS veri setini kullanarak uçak motorlarının RUL tahmini üzerine çalışmışlardır. Çalışmalarında yapay bir yinelemeli sinir ağı (RNN) mimarisi olan Uzun-Kısa Süreli Bellek (LSTM) yapısı kullanmışlar ve sonuçta en yüksek %98,876 sınıflandırma başarımı elde etmişlerdir.

Abbas vd. [7], C-MAPSS veri setini kullanarak, gizli Markov modeline dayalı derin pekiştirmeli öğrenme ile uçak motorlarının RUL tahmin eden yeni bir hiyerarşik yaklaşım önerdiler. Önerilen yaklaşımın performansı değerlendirmek için sonuçlar, temel modellerle ve Bayes filtrelemeye dayalı derin pekiştirmeli öğrenme ile yapılan çalışmalarla karşılaştırılmış ve sonuçların daha iyi performans gösterdiği belirtilmiştir.

Dangut vd. [8], heterojen yapıda olan uçak merkezi bakım sistemi veri setindeki dengesiz sınıflandırma probleminin üstesinden gelmek için Dengeli Kalibrasyonlu Hibrit Topluluk Tekniği adlı yeni bir yaklaşım önermişlerdir. Önerilen yaklaşımın diğer benzer yöntemlerden daha iyi performans gösterdiğini belirtilmiştir.

Xu vd. [9], kılavuzlu dalga (GW) tabanlı evrimsel sinir ağı (CNN) yöntemine dayalı bir yorulma çatlağı teşhis yöntemi önermişlerdir. GW özellikleri, çok kanallı GW sinyallerinden elde edilmiş, yorulma çatlamasını teşhis etmek için tasarlanmış bir CNN uygulanmıştır. Uçak bağlantı elemanı olan biyel kolu üzerinde yapılan yorulma testleri sonucunda %98,98 eğitim doğruluk oranı ve %94,92 test doğruluk oranı elde etmişlerdir.

Vollert vd. [10], C-MAPSS veri seti üzerine yapılan makine öğrenmesi tabanlı RUL tahmini üzerine yapılan araştırmaları incelemişlerdir. Sık kullanılan modelleri belirleyerek, model performansını karşılaştırmalı olarak değerlendirmişlerdir.

Bruneo vd. [11], turbofan motorların RUL tahmin etmek için LSTM ağı kullanan bir model önermişlerdir. Çalışma da LSTM ağına kullanılan hiperparametre değerleri değiştiği zaman, LSTM performansının da değiştiğini göstermişlerdir. Elde edilen sonuçları literatürde bulunan sonuçlarla karşılaştırmışlardır.

Düdükcü vd. [12], LSTM ve WaveNet ile C-MAPSS veri setini kullanarak turbofan motorlarının RUL tahmin eden bir model önermişlerdir. LSTM testlerinden elde edilen ortalama kare hatası (MSE) değerleri FD001 için 11.02 ve FD003 için 26.89'dur. WaveNet testlerinden elde edilen MSE değerleri FD001 ve FD003 için sırasıyla 10.85, 20.71'dir. Sonuçta, önerilen karar seviyesi füzyon sisteminin kestirimci bakım için umut verici olduğunu belirtmişlerdir.

Mathew vd. [13], NASA'nın Prognostik Veri Havuzundaki turbofan motoru verileri ile uçağın turbofan motorunun RUL tahmin etmek için mevcut makine öğrenimi algoritmalarını karşılaştırmıştır.

Khan vd. [14], kestirimci bakım üzerine hava taşıtlarının hidrolik sistemi ve motoru üzerine yapılan çalışmaları özetleyen bir derleme çalışması yapmışlar ve sonuçta kestirimci bakımın ve büyük veri kümeleri için veri ön işleme tekniklerinin önemini vurgulamışlardır.

Girgin vd. [15] uçak motorlarının RUL tahmin etmek için öznitelik odaklı çerçeve yaklaşım önermişlerdir. Çalışma kapsamında farklı makine öğrenmesi ile eğitimler yapmışlar ve radyal tabanlı fonksiyon ve Destek Vektör Regresyonu algoritmasının diğer algoritmalarından daha başarılı sonuç verdiğini belirtmişlerdir.

Pillai vd. [16] özellik oluşturma ve RUL tahminini ayıran iki aşamalı Evrimsel Bileşik Özelliklere (MLE + CCF) sahip Çok Kayıplı Kodlayıcı yaklaşım önermişlerdir. Çalışma sonucunda endüstrilerdeki kestirimci bakım uygulamaları için önerilen modelin uygunluğunu doğrulamışlardır.

Siddique vd. [17], RUL tahmin etmek için kullanılan akıllı sensörlerin ve sistemlerin siber saldırılara maruz kalabileceği için bu tarz saldırıların etkisini kapsamlı bir şekilde analiz etmişler ve derin öğrenme özellikli kestirimci bakım modelleri için yeni bir savunma tekniği önermişlerdir.

Bu çalışmada, uçak motorlarının arızasını önlemek amacıyla, turbofan motorlarının bakıma gitmeden önce kalan faydalı kullanım ömrünü tahmin etmek için 10 farklı makine öğrenmesi algoritması ile eğitimler yapılmış ve sonuçları karşılaştırılmıştır. Çalışma kapsamında NASA tarafından sunulan C-MAPSS veriseti kullanılmıştır. C-MAPSS veriseti üzerinde farklı makine öğrenme algoritmalarının kullanılması, motor arızası tahmini konusundaki araştırmalar için çok sayıda avantaj sunar. Bu algoritmaların performansının karşılaştırılması ve analizi, endüstriyel sistemlerin güvenilirliği ve bakımını iyileştirmek için önemlidir. C-MAPSS veri seti, farklı motorlar, çalışma koşulları ve arıza senaryolarını içerdiği için, turbofan motorlarının çeşitli faktörlere nasıl tepki verdiğini ve bakım ihtiyaçlarını tahmin etmeye yardımcı olur. Ayrıca, sensör verileri ve motorların kullanım ömrü tahminleri gibi değerli bilgiler içerir, bu da makine öğrenimi ve veri analizi uygulamaları için büyük bir potansiyel sunar. Çalışmanın ikinci bölümünde kullanılan veriseti ve makine öğrenmesi algoritmaları hakkında bilgiler verilmiştir. Üçüncü bölümde makine öğrenmesi algoritmaları ile yapılan deneysel sonuçlar sunulmuştur. Dördüncü bölümde araştırma sonuçları tartışılmış ve çalışma değerlendirilerek sonlandırılmıştır.

2 Materyal ve metod

2.1. Veriseti

Çalışma kapsamında NASA tarafından C-MAPSS simülatörü ile oluşturulan veri seti kullanılmıştır. Sağlanan veriler, bir dizi uçuş boyunca nominal ve hatalı motor bozulmasını simüle etmek için tasarlanmış yüksek doğruluk oranlı sistem düzeyinde bir motor simülasyonundan alınmıştır [18,19]. C-MAPSS veriseti, farklı çalışma koşullarını temsil eden FD001, FD002, FD003 ve FD004

olmak üzere dört farklı alt veri setini içerir. Her alt veri seti, farklı sayıda motor ve farklı çalışma koşullarını içerir. FD001 veriseti 100 motora ait eğitim ve test verisini, FD002 veriseti 260 motora ait eğitim ve 259 motora ait test verisini, FD003 veriseti 100 motora ait eğitim ve test verisini, FD004 veriseti 249 motora ait eğitim ve 248 motora ait test verisini içerir. Toplamda, veri setinde 559 farklı turbofan motora ait veriler bulunmaktadır. C-MAPSS veriseti, motorların farklı deniz seviyesi irtifalarında, Mach sayılarında ve sıcaklık aralıklarında nasıl davrandığını simüle eder. Ayrıca farklı arıza senaryolarını içerir. Örneğin, yüksek basınç kompresörü (High-Pressure Compressor - HPC) bozulmaları gibi motorlardaki arızaların etkilerini simüle eder. C-MAPSS veriseti, motorlardan alınan çeşitli sensör ölçümlerini de içermektedir. Bu sensör verileri, motorların performansını ve sağlığını izlemek için kullanılır. Her motor için, motorun RUL bilgisi de bulunmaktadır. Bu, motorların ne zaman bakıma ihtiyaç duyabileceğini tahmin etmek için önemlidir.

C-MAPSS veriseti, turbofan motorlarının tahmini bakımı ve motor sağlığının izlenmesi için değerli bir kaynaktır çünkü gerçekçi veriler sağlar, farklı arıza senaryoları içerir, geniş veri miktarına ve çeşitliliğine sahiptir. Bu veriseti, motorların daha güvenli, verimli ve maliyet etkin bir şekilde işletilmesine katkıda bulunur. Bu veriseti, motorların sağlığını izlemek, arızaları önceden tahmin etmek ve bakımı optimize etmek için kullanılan kestirimci bakım

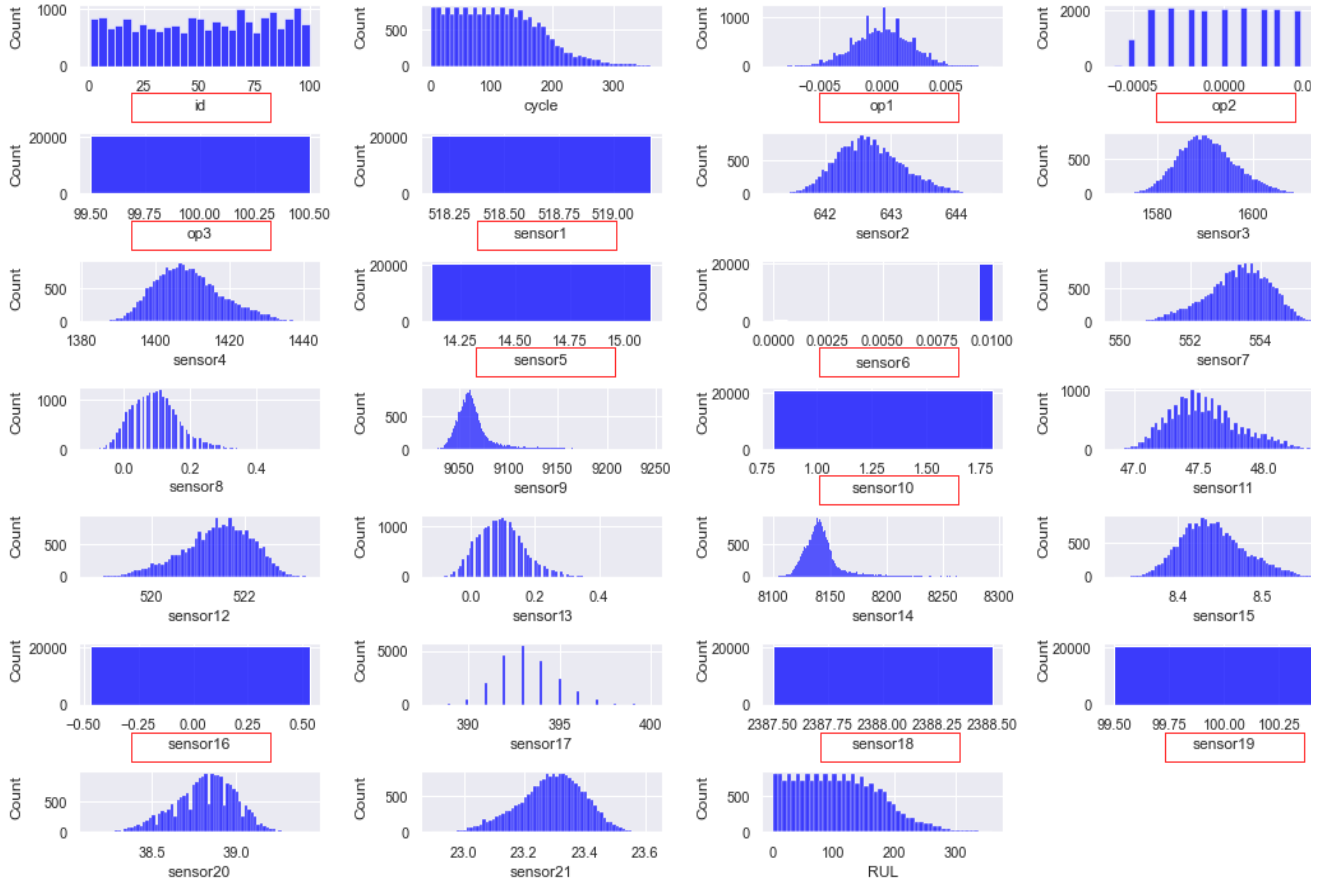
sistemlerinin geliştirilmesine imkân sağlar, araştırma, geliştirme ve endüstri uygulamaları için uygun yapıdadır.

Aşağıdaki **Tablo 1**'de C-MAPSS veri setine ait bilgiler verilmiştir. Hata Modunun 1 olması HPC arızasını ifade ederken, Hata Modunun 2 olması ise HPC Bozulması ve Fan Bozulması durumlarını ifade etmektedir. Simülasyon yazılımı, deniz seviyesinden 40.000 fite kadar irtifalarda, 0 ila 0.90 Mach sayısında ve -60 ila 103 F arasındaki ortam sıcaklıklarında motor çalışmasına izin veren bir atmosferik model içerir. Çalışma koşulları deniz seviyesini ifade etmektedir.

Tablo 1. C-MAPSS veriseti bilgileri

	FD001	FD002	FD003	FD004
Çalışma Koşulları	1	6	1	6
Hata Modu	1	1	2	2
Eğitim Seti Motor Sayısı	100	260	100	249
Test Seti Motor Sayısı	100	259	100	248

Bu çalışmada, turbofan motorlarının RUL tahmini için C-MAPSS veri setinin FD001 alt verisi kullanılmıştır. Bu veriseti, 100 motora ait verileri içermektedir. Veri setine ait sensörlerin ölçüm değerlerine ait grafikler **Şekil 1**'de gösterilmiştir.



Şekil 1. Sensör ölçüm değerleri

Şekilde verisetine ait, birim numarası (identification number, id), zaman (cycle), operasyonel ayar1 (op1), operasyonel ayar2 (op2), operasyonel ayar3 (op3) verileri ile 1' den 21'e kadar numaralandırılmış sensörlere ait veriler ve RUL bilgisi görülmektedir. id, op1, op2 ve op3 parametreleri turbofan motorlara ait herhangi bir bakım, arıza, RUL verisi içermediği ve sonuçlara bir katkı sağlamadığı için çalışma sırasında verisetinden çıkarılmıştır. Sensör ölçüm değerleri incelendiği zaman sensör1, sensör5, sensör6, sensör10, sensör16, sensör18 ve sensör19 sensörlerinin simülasyon süresince sabit değer ürettiği, hiçbir değişiklik göstermediği görülmektedir. Bu sensörlere ait veriler, veri seti hakkında bilgi sağlamadığı ve eğitim sonuçlarına anlamlı katkı sunmadığı için eğitimler sırasında veri setinden çıkarılmıştır.

2.2. Makine öğrenmesi algoritmaları

C-MAPSS veriseti üzerinde turbofan motorların kestirimci bakım tahmini için Lojistik Regresyon, K-En Yakın Komşu, Destek Vektörü Makineleri, Karar Ağaçları, Rastgele Orman, Adaptive Boosting, Aşırı Gradyan Artırma, Naive Bayes, Stokastik Gradyan İniş ve Doğrusal Diskriminant Analizi algoritmaları kullanılmıştır. Bu algoritmalar farklı öğrenme yaklaşımlarını temsil eder. C-MAPSS veriseti oldukça karmaşıktır ve birçok değişken içerir. Bu tür karmaşık verileri işlemek ve analiz etmek, verisetinin iç yapısını anlamak ve en iyi sonuçları alabilmek için farklı algoritmaların öğrenme yeteneklerini değerlendirmek önemlidir. Bazı algoritmalar daha iyi genelleme yapabilirken diğerleri daha karmaşık ilişkileri yakalama yeteneğine sahip olabilir. Bu nedenle bu çalışmada 10 farklı makine öğrenmesi algoritması ile çalışılmış ve sonuçları karşılaştırılmıştır.

2.2.1. Lojistik regresyon (Logistic regression - LR)

Lojistik regresyon analizi, özellikle (evet- hayır, var-yok vb.) ikili sınıflandırma problemlerinde ve bir olayı tahmin etmek için kullanılan istatistiksel bir tekniktir. Maksimum olasılık tahmini ile olası sonuçları açıklayan olasılıkların bir lojistik işlevi aracılığıyla modellendiği doğrusal bir modeldir [20].

2.2.2. K-En yakın komşu (K-Nearest neighbor -KNN)

KNN algoritması, sınıflandırılması istenilen verinin bulunduğu noktanın daha önceden eğitilmiş ve sınıflandırılmış noktalara olan uzaklığı hesaplayarak, en yakın komşunun dâhil olduğu sınıfa göre tahmin oluşturur [21]. Giriş, en yakın komşuları paylaştığı sınıfa atanır.

2.2.3. Destek vektörü makineleri (Support vector machine - SVM)

SVM makine öğrenmesi alanında ikili sınıflandırma için yaygın olarak kullanılan bir algoritmadır. SVM, iki farklı sınıf arasında doğrusal bir sınır belirler ve sınır her sınıftaki en yakın veri noktalarına olan mesafesi maksimum olacak şekilde yönlendirilir [22]. En yakın veri noktaları destek vektörleri olarak bilinir.

2.2.4. Karar ağaçları (Decision tree -DT)

Karar ağaçları, bir ağaç yapısı şeklinde, düğümlerin bir veri kümesi özelliklerini, dalların karar kurallarını ve

yaprakların düğümün sonucunu temsil ettiği bir sınıflandırıcıdır [23]. Karar düğümü ve yaprak düğümü olmak üzere iki çeşit düğüm içerir. Karar düğümleri herhangi bir karar vermek için kullanılır ve birden fazla dala sahip olabilir, yaprak düğümler ise bu kararların çıktısıdır ve başka dal içermez [24].

2.2.5. Rastgele orman (Random forests - RF)

Rastgele orman algoritması, çıktının içerisindeki birkaç DT sınıflandırıcısı tarafından toplu olarak belirlendiği bir topluluk öğrenme algoritmasıdır [25]. Ormandaki ağaç sayısı arttığında, ormanlar için genelleme hatasındaki yanlılığı yakınsamaktadır.

2.2.6. Adaptive boosting (AdaBoost)

AdaBoost algoritması bir topluluk öğrenme modelidir ve modelin başarısını artırmak için zayıf öğreniciler üzerine odaklanır [26]. Adaboost algoritmasında doğru sınıflandırılmayan zayıf öğrenicilerin ağırlıklarını artırılarak daha güçlü bir model elde edilir.

2.2.7. Aşırı gradyan artırma (Extreme gradient boosting - XGBoost)

Xgboost algoritması ölçeklenebilir bir uçtan uca ağaç öğrenme algoritması içeren gradyan artırma çerçevesinin verimli ve ölçeklenebilir bir uygulamasıdır [27]. Regresyon, sınıflandırma ve sıralama gibi çeşitli problemlerin çözümünde etkin olarak kullanılabilir.

2.2.8. Naive bayes (NB)

Naive Bayes sınıflandırıcısı, özniteliklerin sınıfa göre koşullu olarak diğer özniteliklerin değerlerinden bağımsız olduğuna dair güçlü bir varsayım ile birlikte Bayes kuralını kullanan basit bir öğrenme algoritmasıdır [28]. Sınıf koşullu bağımsızlık adını alan bu varsayım, hesaplamaları basitleştirmek için kullanılır [29].

2.2.9. Stokastik gradyan iniş (Stochastic gradient descent - SGD)

Stokastik gradyan iniş (SGD) algoritması, gradyanı tam olarak hesaplamak yerine, bu gradyanı rastgele seçilmiş bir örnek temelinde tahmin eden yinelemeli bir metot kullanır [30].

2.2.10. Doğrusal diskriminant analizi (Linear discriminant analysis - LDA)

Popüler bir veri madenciliği algoritması olan Doğrusal Diskriminant Analizi, sınıflar arası varyansı en aza indiren ve sınıfların öngörülen ortalamaları arasındaki mesafeyi en üst düzeye çıkaran iz düşüm hiperdüzleminin bulunmasından oluşur [31].

3 Bulgular

Bu çalışmada turbofan motorların RUL tahmini için özellikle sınıflandırma çalışmalarında yaygın olarak kullanılan 10 farklı makine öğrenme algoritması kullanılmıştır. NASA C-MAPSS veriseti üzerinde LR, KNN, SVM, DT, RF, AdaBoost, XGBoost, NB, SGD ve LDA algoritmaları ile eğitimler gerçekleştirilmiştir.

Eğitimler sırasında algoritmaların elde ettiği doğruluk ve çapraz doğrulama sonuçları **Tablo 2**'de verilmiştir.

Tablo 2. Doğruluk ve çapraz doğrulama sonuçları

Algoritma	Doğruluk	Çapraz Doğrulama
LR	95.0 %	94.82%
KNN	94.0 %	94.09%
SVM	95.0 %	94.86%
DT	92.0 %	93.73%
RF	95.0 %	94.68%
AdaBoost	95.0 %	94.74%
XGBoost	95.0 %	94.88%
NB	93.0 %	94.87%
SGD	95.0 %	93.87%
LDA	95.0 %	94.93%

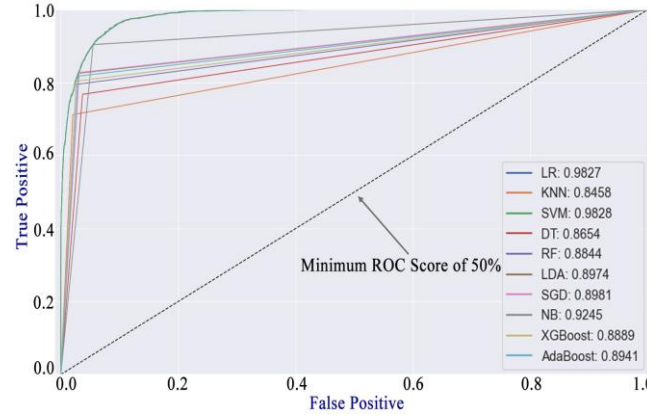
Tablo 2 incelendiği zaman, train FD001 veriseti üzerinde makine öğrenmesi algoritmalarının 92% ile 95% arasında doğruluk, 93.73% ile 94.93% arasında çapraz doğrulama sonucu elde ettiği görülmektedir. Genel olarak makine öğrenmesi algoritmalarının train_FD001 veriseti üzerinde başarılı olduğunu söyleyebiliriz. En başarılı ilk üç algoritmanın sırasıyla LDA, XGBoost ve SVM olduğu görülmektedir. LDA algoritması 95% doğruluk ve 94.93% çapraz doğrulama, XGBoost algoritması 95% doğruluk ve 94.88% çapraz doğrulama, SVM algoritması 95% doğruluk ve 94.86% çapraz doğrulama değerleri elde etmiştir. Makine öğrenmesi algoritmalarının eğitimler sırasında train_FD001 veriseti üzerinde başarılı olduğunu görmekteyiz. Modellerin performansını test etmek ve en başarılı modelleri bulmak için çeşitli performans metrikleri ile test_FD001 veriseti değerlendirmeler yapılmıştır. Test verilerini değerlendirmek için Doğruluk, Kesinlik, Duyarlılık, F1-Skoru, Eğri Altındaki Alan - Alicı Çalışma Karakteristikleri (AUC-ROC) performans metrikleri hesaplanmıştır. **Tablo 3**'te test_FD001 veriseti üzerinde yapılan performans değerlendirme sonuçları verilmiştir.

Tablo 3. Performans metrik sonuçları

Algoritma	Doğruluk	Kesinlik	Duyarlılık	F1 skor
LR	79.70 %	0.73	0.23	0.35
KNN	78.95 %	0.66	0.22	0.34
SVM	79.73 %	0.73	0.23	0.35
DT	78.93 %	0.67	0.22	0.33
RF	79.28 %	0.69	0.23	0.34
AdaBoost	78.41 %	0.59	0.30	0.39
XGBoost	79.35 %	0.67	0.26	0.37
NB	77.73 %	0.55	0.35	0.43
SGD	79.73 %	0.72	0.24	0.36
LDA	79.82 %	0.78	0.20	0.32

Test verileri üzerinde yapılan performans değerlendirmeleri incelendiği zaman, modellerin başarımlarının eğitim verisetine göre düştüğü görülmektedir. En yüksek doğruluk oranına sahip ilk üç algoritmanın sırasıyla LDA (79.82%),SVM (79.73%) ve SGD (79.73%), en yüksek kesinlik oranına sahip ilk üç algoritmanın sırasıyla LDA(0.78), SVM (0.73) ve LR (0.73), en yüksek duyarlılık oranına sahip ilk üç algoritmanın sırasıyla Naive Bayes(0.35), AdaBoost (0.30) ve XGBoost (0.26), en yüksek F1-skor oranına sahip ilk üç algoritmanın sırasıyla NB(0.43), AdaBoost (0.390) ve XGBoost (0.37) olduğu görülmektedir.

Makine öğrenmesi algoritmalarına ait sınıflandırma performansları göstermek için AUC-ROC eğrisi **Şekil 2**'de ve AUC-ROC skor değerleri **Tablo 4**'te verilmiştir. **Şekil 2** ve **Tablo 4**'de görüldüğü üzere en iyi sınıflandırma performansı gösteren ilk üç algoritma sırasıyla SVM, LR ve NB algoritmalarıdır.



Şekil 2. Auc-Roc grafiği

Tablo 4. Auc-Roc sonuçları

Algoritma	Auc Roc Skor
LR	0.9827
KNN	0.8458
SVM	0.9828
DT	0.8654
RF	0.8844
AdaBoost	0.8941
XGBoost	0.8889
NB	0.9245
SGD	0.8981
LDA	0.8974

Makine öğrenmesi algoritmalarının NASA-CMAPSS veriseti üzerinde turbofan motorlarının RUL tahmini performansını ölçmek için karmaşıklık matrisleri hesaplanmıştır. **Şekil 3**'te verilen karmaşıklık matrisleri incelendiği zaman en iyi performans gösteren ilk üç algoritmanın sırasıyla LDA, LR ve SVM algoritmaları olduğu görülmektedir.



Şekil 3. Makine öğrenmesi algoritmaları karmaşıklık matrisleri

4 Tartışma ve sonuçlar

Turbofan motorlarının kestirimci bakım yöntemleri ile RUL tahmini, uçuş güvenliği açısından arızaların önüne geçilmesi için önemli bir çalışma konusudur. Bu çalışmada, NASA tarafından sunulan CMAPSS veriseti üzerinde turbofan motorların RUL tahmini için 10 farklı makine öğrenmesi algoritmaları kullanılmış ve bu algoritmaların performans değerlendirmesi sunulmuştur.

Çalışma kapsamında sınıflandırma çalışmalarında aygın olarak kullanılan LR, KNN, SVM, DT, RF, AdaBoost, XGBoost, NB, SGD ve LDA algoritmaları ile eğitimler

yapılmıştır. Yapılan eğitimler sonucunda doğruluk oranı ve çapraz doğrulama sonuçlarına göre sırasıyla LDA, XGBoost ve SVM algoritmaları en iyi performansı göstermiştir. Modelin test verileri üzerindeki performansını ölçmek için çeşitli deneyler yapılmıştır. LDA, SVM ve SGD algoritmaları en yüksek doğruluk oranını, NB, AdaBoost ve XGBoost algoritmaları en yüksek duyarlılık oranını, NB, AdaBoost ve XGBoost algoritmaları en yüksek F1-Skor değerlerini elde eden algoritmalarlardır. AUC-ROC eğrileri incelendiği zaman en iyi sınıflandırma performansı gösteren ilk üç algoritma sırasıyla SVM, LR ve Naive Bayes algoritmaları olduğu görülmektedir. Karmaşıklık matrisleri

incelendiği zaman en iyi performans gösteren ilk üç algoritmanın ise sırasıyla LDA, LR ve SVM algoritmaları olduğu görülmektedir.

Makine öğrenmesi algoritmalarının turbofan motorlarının RUL tahmini için CMAPSS veri seti üzerindeki performansları karşılaştırıldığı zaman, genel olarak tüm modellerin birbirlerine çok yakın oranlarda performans gösterdiği görülmektedir. En başarılı ve kararlı iki algoritmaların LDA ve SVM algoritmaları olduğu söylenebilir.

Bu çalışma kapsamında sadece makine öğrenmesi algoritmaları kullanılmıştır. Literatürde yapılan çalışmalar incelendiği zaman turbofan motorlarının RUL tahmini için özellikle LSTM algoritmalarının yoğun olarak kullanıldığı görülmektedir. Çalışmayı genişletmek için LSTM, derin öğrenme, transfer öğrenme vb. algoritmalar ile deneyler gerçekleştirilip, sonuçları karşılaştırılabilir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %4

Kaynaklar

- [1] D. Rengasamy, H.P. Morvan and G.P. Figueredo, Deep learning approaches to aircraft maintenance, repair and overhaul: A review. 21st International Conference on Intelligent Transportation Systems, pp. 150-156, IEEE, 2018.
- [2] K.T. Nguyen and K. Medjaher, A new dynamic predictive maintenance framework using deep learning for failure prognostics. Reliability Engineering & System Safety, 188, 251-262, 2019. <https://doi.org/10.1016/j.ress.2019.03.018>
- [3] I. Mallidis, V. Yakavenka, A. Konstantinidis and N. Sariannidis, A goal programming-based methodology for machine learning model selection decisions: a predictive maintenance application. Mathematics, 9(19), 2405, 2021. <https://doi.org/10.3390/math9192405>
- [4] A.P. Hermawan, D.S. Kim and J.M. Lee, Predictive maintenance of aircraft engine using deep learning technique. International Conference on Information and Communication Technology Convergence (ICTC), pp. 1296-1298, IEEE, 2020. <http://dx.doi.org/10.1109/ICTC49870.2020.9289466>
- [5] S. Savaş, K. Duraklar, O.A. Çınar, M. Koç, A. Turan, U. Uslu, A.S. Doğanay, O.G. Özceyhan, M.Y. Destan and H. Duşbudak, Güneş enerjisi sistemlerinde yenilikçi ve akıllı bakım onarım. Journal of Information Systems and Management Research, 4(2), 35-49, 2022.
- [6] M.A. Kızrak and B. Bolat, Uçak motoru sağlığı için uzun-kısa süreli bellek yöntemi ile öngörücü bakım. Bilişim Teknolojileri Dergisi, 12(2), 103-109, 2019. <https://doi.org/10.17671/gazibtd.495730>
- [7] A.N. Abbas, G. Chasparis and J.D. Kelleher, Interpretable hidden markov model-based deep reinforcement learning hierarchical framework for predictive maintenance of turbofan engines. arXiv preprint arXiv:2206.13433, 2022. <https://doi.org/10.48550/arXiv.2206.13433>
- [8] M.D. Dangut, Z. Skaf and I.K. Jennions, Handling imbalanced data for aircraft predictive maintenance using the BACHE algorithm. Applied Soft Computing, 123, 108924, 2022. <https://doi.org/10.1016/j.asoc.2022.108924>
- [9] L. Xu, S.F., Yuan, J. Chen and Q. Bao, Deep learning based fatigue crack diagnosis of aircraft structures. In Proceedings of the 7th Asia-Pacific Workshop on Structural Health Monitoring, 2018.
- [10] S. Vollert and A. Theissler, Challenges of machine learning-based RUL prognosis: A review on NASA's C-MAPSS data set. In 2021 26th IEEE International Conference on Emerging Technologies and Factory Automation, pp. 1-8, IEEE, 2021, September. <http://dx.doi.org/10.1109/ETFA45728.2021.9613682>
- [11] D. Bruneo and F. De Vita, On the use of LSTM networks for predictive maintenance in smart industries. In 2019 IEEE International Conference on Smart Computing (SmartComp), pp. 241-248, IEEE, 2019. <https://doi.org/10.1109/SMARTCOMP.2019.00059>
- [12] H.V. Dütükçü, M. Taşkıran and N. Kahraman, LSTM and WaveNet implementation for predictive maintenance of turbofan engines. In 2020 IEEE 20th International Symposium on Computational Intelligence and Informatics, pp. 000151-000156, IEEE, 2020.
- [13] V. Mathew, T. Toby, V. Singh, B.M. Rao and M.G. Kumar, Prediction of remaining useful lifetime (RUL) of turbofan engine using machine learning. In 2017 IEEE International Conference on Circuits and Systems (ICCS), pp. 306-311, IEEE, 2017.
- [14] K. Khan, M. Sohaib, A. Rashid, S. Ali, H. Akbar, A. Basit and T. Ahmad, Recent trends and challenges in predictive maintenance of aircraft's engine and hydraulic system. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 43, 1-17, 2021. <http://dx.doi.org/10.1007/s40430-021-03121-2>
- [15] K.Ç. Girgin and C. Zalluhoğlu, Öznitelik odaklı sensor verisi bazlı uçak motorları geriye kalan faydalı ömür tahminleme. Avrupa Bilim ve Teknoloji Dergisi, 37, 21-27, 2022. <https://doi.org/10.31590/ejosat.1125433>
- [16] S. Pillai and P. Vadakkepat, Two stage deep learning for prognostics using multi-loss encoder and convolutional composite features. Expert Systems with Applications, 171, 114569, 2021. <http://dx.doi.org/10.1016/j.eswa.2021.114569>
- [17] A. Siddique, R.K. Kundu, G.R. Mode and K.A. Hoque, RobustPdM: designing robust predictive maintenance against adversarial attacks. arXiv preprint arXiv:2301.10822, 2023. <https://doi.org/10.48550/arXiv.2301.10822>
- [18] D.K. Frederick, J.A. Decastro and J.S. Litt. Users guide for the commercial modular aero-propulsion system simulation (c-mapss). Tech. Rep. NASA/TM2007-215026, 2007.

- [19] A. Saxena, K. Goebel, D. Simon and N. Eklund, Damage propagation modeling for aircraft engine run-to-failure simulation. In 2008 international conference on prognostics and health management, pp. 1-9, IEEE, 2008. <http://dx.doi.org/10.1109/PHM.2008.4711414>
- [20] H.A. Gohel, H. Upadhyay, L. Lagos, K. Cooper and A. Sanzetenea, Predictive maintenance architecture development for nuclear infrastructure using machine learning. Nuclear Engineering and Technology, 52(7), 1436-1442, 2020. <https://doi.org/10.1016/j.net.2019.12.029>
- [21] Ö.Ç. Yavuz, E. Karaman and C. Yeşilyaprak, Makine öğrenmesi algoritmalarıyla astronomik gözlem kalitesi tahminine yönelik karar destek sistemi geliştirilmesi ve uygulanması. Trends in Business and Economics, 36(3), 289-303, 2022. <http://doi.org/10.5152/TBE.2022.1049957>
- [22] A.B. Andre, E. Beltrame and J. Wainer, A combination of support vector machine and k-nearest neighbors for machine fault detection. Applied Artificial Intelligence, 27(1), 36-49, 2013. <http://dx.doi.org/10.1080/08839514.2013.747370>
- [23] F. Arena, M. Collotta, L. Luca, M. Ruggieri and F.G. Termine, Predictive maintenance in the automotive sector: A literature review. Mathematical and Computational Applications, 27(1), 2, 2022. <https://doi.org/10.3390/mca27010002>
- [24] S.R. Safavian and D. Landgrebe, A survey of decision tree classifier methodology. IEEE transactions on systems, man, and cybernetics, 21(3), 660-674, 1991.
- [25] Z.M. Çınar, A. Abdussalam Nuhu, Q. Zeeshan, O. Korhan, M. Asmael and B. Safaei, Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. Sustainability, 12(19), 8211, 2020.
- [26] Y. Freund and R.E. Schapire, A decision-theoretic generalization of on-line learning and an application to boosting. Journal of computer and system sciences, 55(1), 119-139, 1997. <https://doi.org/10.1006/jcss.1997.1504>
- [27] T. Chen and C. Guestrin, Xgboost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, pp. 785-794, 2016.
- [28] G.I. Webb, E. Keogh and R. Miikkulainen, Naïve Bayes. Encyclopedia of machine learning, 15, 713-714, 2010.
- [29] S. Savaş, Naïve Bayes Sınıflandırıcısı. Teori ve Uygulamada Makine Öğrenmesi, (69-92), Nobel Akademik Yayıncılık, Ankara, 2022.
- [30] L. Bottou, Large-scale machine learning with stochastic gradient descent. In Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers, pp. 177-186, Physica-Verlag HD, 2010. https://doi.org/10.1007/978-3-7908-2604-3_16
- [31] P. Xanthopoulos, P.M. Pardalos and T.B. Trafalis, Linear discriminant analysis. Robust data mining, 27-33, 2013. <http://dx.doi.org/10.1007/978-1-4419-9878-1>

