



T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



YÜKSEK LİSANS TEZİ

TEMEL BİLEŞENLER ANALİZİ VE YAPAY SİNİR AĞLARI KULLANILARAK
TURBOFAN MOTORUNUN KALAN FAYDALI ÖMÜR TAHMİNİ

MOHAMEDALFATEH TAGALSIR MAROOF SAEED


DANIŞMAN

Dr. Öğr. Üyesi Rana ORTAÇ KABAOĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

Haziran, 2022



Aileme ithaf ediyorum...

BÜTÇE DESTEKLERİ

Temel Bileşenler Analizi ve Yapay Sinir Ağları Kullanılarak Turbofan Motorunun Kalan Faydalı Ömür Tahmini

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.



TEŐEKKÜR

Yapmış olduđum bu tez alıőmasında sahip olduđu bilgi, birikim ve tecrübesiyle bana yol gösteren ve elinden gelen tüm desteđi veren deđerli hocam Yrd. Do. Dr. Rana OTRA KABAOLU'na teőekkür eder, saygılarımı sunarım.

Eđitim hayatım boyunca maddi ve manevi desteđini hi esirgemeyen deđerli aileme ve bu tez alıőmasını hazırlarken her türlü fedakarlıđı yapan sevgili aileme teőekkürü bir bor bilirim.

Haziran 2022

MOHAMEDALFATEH TAGALSIR MAROOF SAEED

İÇİNDEKİLER

Sayfa No

TEŞEKKÜR	iv
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ	ix
KISALTMA LİSTESİ	x
ÖZET	xi
ABSTRACT	xiii
1. GİRİŞ	1
1.1. BAKIM YAKLAŞIMLARI.....	4
1.1.1. Koruyucu Bakım	4
1.1.2. Önleyici Bakım	5
1.1.3. Şartlara Dayalı Bakım	5
1.1.4. Kestirimci Bakım	5
2. YAPAY ZEKA VE MAKİNE ÖĞRENMESİ	7
2.1. MAKİNE ÖĞRENMESİ	7
2.1.1. Denetimli Öğrenme	8
2.1.2. Denetimsiz Öğrenme.....	9
2.1.3. Pekiştirmeli Öğrenme.....	9
2.2. DERİN ÖĞRENME.....	9
2.2.1. Yapay Sinir Ağları	11
2.3. TEMEL BİLEŞENLER ANALİZİ (TBA)	13
2.3.1. TBA ile İlgili Adımlar	14
3. MODEL KURULMASI	15
3.1. KULLANILAN TEKNOLOJİLER	15
3.2. VERİ KÜMESİ AÇIKLAMASI.....	16
3.3. VERİ ÖN İŞLEME	21
3.4. VERİ DÖNÜŞÜMÜ	22
3.5. BOYUTSAL KÜÇÜLTME	23
3.6. KULLANILAN MODELLER	24

4. TARTIŞMA VE SONUÇ	26
4.1. PERFORMANS DEĞERLANDİRMESİ	26
4.1.1. Birinci veri seti (FD001).....	27
4.1.2. İkinci veri seti (FD002)	32
4.1.3. Üçüncü veri seti (FD003)	37
4.2. LİTERATÜRLE KARŞILAŞTIRMA:.....	44
5. SONUÇ VE ÖNERİLEN	46
5.1. SONUÇ:.....	46
5.2. ÖNERİLEN:	47
KAYNAKÇA	48



ŞEKİL LİSTESİ

Şekil 1.1:Koruyucu bakım (Kaynak:Mathworkth).....	4
Şekil 1.2:Önleyici Bakım (kaynak:mathworkth).....	5
Şekil 1.3:Kestirimci Bakım (kaynak:mathworkth).....	6
Şekil 2.1:Makine Öğrenmesi Teknikleri	8
Şekil 2.2:Yapay Sinir Ağının Genel Yapısı.....	11
Şekil 2.3:İki Gizli Katmanlı Derin Sinir Ağı Yapısı	13
Şekil 3.1:C-MAPSS'de simüle edilen motorun basitleştirilmiş şeması.....	16
Şekil 3.2:İlk verinin (FD001) eğitim veri setinin ilk 20 satırı.	18
Şekil 3.3:5 motorun maksimum çevrimi.	19
Şekil 3.4:İlk motor arızalanana kadar altı sensör ölçümü.....	20
Şekil 3.5:Bileşenlerin yüzde açıklaması.....	23
Şekil 3.6:Bileşenlerin çubuklarla temsili.....	23
Şekil 4.1:FD001'de ÇKA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	27
Şekil 4.2:ÇKA test seti için tahmini ve gerçek KFÖ.....	27
Şekil 4.3:FD001'de UKSB için eğitim aşamasındaki eğitim ve doğrulama kayıpları.	28
Şekil 4.4:UKSB test seti için tahmini ve gerçek KFÖ.	28
Şekil 4.5:FD001'de ESA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	29
Şekil 4.6:ESA test seti için tahmini ve gerçek KFÖ.....	29
Şekil 4.7:FD001'de TSA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	30
Şekil 4.8:TSA test seti için tahmini ve gerçek KFÖ.....	30
Şekil 4.9:FD001 için modellerin OKH değerleri.....	31
Şekil 4.10:FD001 için modellerin KOKH değerleri.....	32
Şekil 4.11:FD001 için modellerin OMH değerleri.....	32

Şekil 4.12:FD002'de ÇKA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	33
Şekil 4.13:ÇKA test seti için tahmini ve gerçek KFÖ.....	33
Şekil 4.14:FD002'de ESA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	34
Şekil 4.15:ESA test seti için tahmini ve gerçek KFÖ.....	34
Şekil 4.16:FD002'de TSA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	34
Şekil 4.17:TSA test seti için tahmini ve gerçek KFÖ.....	35
Şekil 4.18:FD002'de UKSB, için eğitim aşamasındaki eğitim ve doğrulama kayıpları.	35
Şekil 4.19:UKSB test seti için tahmini ve gerçek KFÖ.	36
Şekil 4.20:FD002 için modellerin OKH değerleri.....	37
Şekil 4.21:FD002 için modellerin OMH değerleri.....	37
Şekil 4.22:FD002 için modellerin KOKH değerleri.....	37
Şekil 4.23:FD003'de ÇKA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	38
Şekil 4.24:ÇKA test seti için tahmini ve gerçek KFÖ.....	38
Şekil 4.25:FD003'de UKSB, için eğitim aşamasındaki eğitim ve doğrulama kayıpları.	39
Şekil 4.26:UKSB test seti için tahmini ve gerçek KFÖ.	39
Şekil 4.27:FD003'de TSA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	40
Şekil 4.28:TSA test seti için tahmini ve gerçek KFÖ.....	40
Şekil 4.29:FD003'de ESA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.....	41
Şekil 4.30:ESA test seti için tahmini ve gerçek KFÖ.....	41
Şekil 4.31:FD003 için modellerin OKH değerleri.....	42
Şekil 4.32:FD003 için modellerin OMH değerleri.....	43
Şekil 4.33:FD003 için modellerin KOKH değerleri.....	43
Şekil 4.34:KOKH grafikleri.	44
Şekil 4.35:Önerilen metot, literatüre [4] ile KOKH grafiklerinin karşılaştırması.....	45

TABLO LİSTESİ

Tablo 3.1: Veri kümesinin açıklaması [30].	17
Tablo 3.2: Her veri kümesindeki örnek sayısı.	21
Tablo 3.3: Her veri kümesinin seçili bileşenlerinin sayısı.	24
Tablo 3.4: Kullanılan Yapay Sinir Ağları modeli.	25
Tablo 4.1: Kullanılan hiper-parametrelerinin değerleri.	26
Tablo 4.2: İlk veri kümesi (FD001) için tüm modellerin OKH, KOKH ve OMH değerleri.	31
Tablo 4.3: İkinci veri kümesi (FD002) için tüm modellerin OKH, KOKH ve OMH değerleri.	36
Tablo 4.4: Üçüncü veri kümesi (FD002) için tüm modellerin OKH, KOKH ve OMH değerleri.	42
Tablo 4.5: KOKH değerleri.	43
Tablo 4.6: Önerilen metot ile literatür karşılaştırması.	45

KISALTMA LİSTESİ

Kısaltmalar	Açıklama
KFÖ	: Kalan Faydalı Ömür
OKH	: Ortalama Kare Hata
KOKH	: Karesal Ortalama Hare Hata
OKH	: Ortalama Mutlak Hata
MÖ	: Makine Öğrenmesi
TBA	: Temel Bileşenler Analizi
ÇKA	: Çok Katmanlı Algılayıcı
UKSB	: Uzun Kısa Süreli Bellek
TSA	: Tekrarlayan Sinir Ağı
ESA	: Evrimsel Sinir Ağı
GA	: Genetik Algoritması

ÖZET

YÜKSEK LİSANS TEZİ

TEMEL BİLEŞENLER ANALİZİ VE YAPAY SİNİR AĞLARI KULLANILARAK TURBOFAN MOTORUNUN KALAN FAYDALI ÖMÜR TAHMİNİ

MOHAMEDALFATEH TAGALSIR MAROOF SAEED

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

Danışman: Dr. Öğr. Üyesi Rana ORTAÇ KABAOĞLU

Reaktif ve önleyici bakım teknikleri gibi geleneksel bakım teknikleri zaman kaybına, maliyet ve güvenlik sorunlarına neden olduğundan, kestirimci bakım (cihaz arızasının meydana gelmeden önce tahmin edilmesine bağlı bir bakım yaklaşımıdır) tercih edilir. Ayrıca, ekipmana takılan sensörlerin ölçümleri kullanılarak tahmin yapılır. Ayrıca IoT (Internet of Things - Nesnelerin İnterneti) kullanımlarının artması, bakımın tahmine dayalı analitik olarak adlandırılan bir veri analitiği sorunu olarak görülmesini sağlar. Başka bir deyişle, bu verilerin doğru işlenmesi, yüksek doğrulukta bir arıza ortaya çıkmadan tahmini sağlayacak bir sistem oluşturulmasını sağlayabilir.

Bu çalışmada, temel bileşenler analizi (TBA) algoritması ve yapay sinir ağları kullanılarak uçak motoru turbo fanın kalan faydalı ömrünü (KFÖ) tahmin etmek için NASA tarafından sağlanan bir Turbofan Motor Bozulma Simülasyon Veri Kümeleri kullanılmıştır. Girdi sayısını azaltmak için TBA kullanılmıştır. TBA'nın çıktısı dört farklı sinir ağına beslenmiş ve sonuçları en yüksek performansı sağlayan en iyi modeli seçmek için karşılaştırılmıştır. Sonuç olarak, çok katmanlı algılayıcı modeli (ÇKA) en iyi performansa sahiptir. Önerilen yöntem

literatüre göre daha az girdi kullanılmasına rağmen 2 veri setinde daha iyi performans göstermiştir.

Haziran 2022 , [64 sayfa.]

Anahtar kelimeler:[Yapay sinir ağıları, Temel bileşenler analizi, Kalan ömür tahmini, kestirimci bakım]



ABSTRACT

[**M.Sc. THESIS**]

Prediction of Remaining Useful Lifetime of Turbofan Engine using PCA and Artificial Neural Networks

MOHAMEDALFATEH TAGALSIR MAROOF SAEED

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Electrical and Electronics Engineering

Electrical and Electronics Engineering

Supervisor : Assist. Prof. Dr. Rana ORTAÇ KABAOĞLU

Because traditional maintenance techniques such as reactive and preventive maintenance techniques result in lost time, cost, and safety issues, predictive maintenance (i.e., a form of maintenance that relies on predicting equipment failure before it occurs) is preferred. In addition, the prediction is based on the measurements of the sensors installed in the devices. Additionally, the increasing use of IoT (Internet of Things) means that maintenance is viewed as a data analysis problem known as predictive analytics. In other words, processing this data correctly can result in the implementation system providing a highly accurate failure prediction before it occurs.

In this study, turbofan engine simulation data sets provided by NASA are used to predict the remaining useful life-time (RUL) for the aircraft engine turbofan using Principal Component Analysis (PCA) algorithm and artificial neural networks. PCA is used to reduce the number of inputs. The PCA output is fed to four different neural networks and their results are compared to select the best model with the highest performance. As a result, the Multilayer Perceptron (MLP) model has the highest performance. Although the proposed method used fewer inputs compared to the literature , it performs better on 2 datasets.

June2022, [64 pages.]

Keywords: [Artificial Neural Networks, Principle Components Analysis, Remaining useful life-time, Predictive Maintenance}]



1. GİRİŞ

Son yıllarda kestirimci bakım, maliyeti ve zamanı düşürmesi gibi avantajları nedeniyle araştırmacılar tarafından ilgi görmeye başlamıştır. Arıza maliyetli olacağı ve insan hayatını riske atabileceği için makinenin bakımı kritik bir faaliyettir, bu nedenle arıza meydana gelmeden bakım yapmak bu maliyetlerden kaçınmanın en iyi yoludur. Bununla birlikte, makinenin bakımını planlamak, gereksiz bakımlar yaparak veya periyodik bakımların yanı sıra hala çalışma kabiliyetine sahip parçaları değiştirerek daha fazla maliyete neden olabilir. Kestirimci (öngörücü) bakım, ekipmana takılan sensörlerden toplanan verilerin analizine dayalı olarak arıza oluşmadan önce bakımın ne zaman yapılabileceğini tahmin etmekle ilgilidir. Karşılaştırıldığında, yukarıda bahsedilen iki bakım yönteminden farklı olarak, öngörücü bakım zamandan tasarruf sağlayıp gereksiz bakımlardan kaçınabilmektedir. Öngörücü bakım yapmanın iki yolu vardır. Birincisi, sonraki n-adımda başarısızlık olasılığını tahmin eden sınıflandırma yaklaşımıdır. İkincisi de Kalan Faydalı Ömür (KFÖ) olarak adlandırılan ve bir sonraki başarısızlıktan önce kalan süreyi tahmin eden bir regresyon yaklaşımıdır [1]. Konu hakkında yapılan ve aşağıda detaylandırılan önceki çalışmalardan özetle şu sonuçlar çıkarılabilir; kestirimci bakım modelleri verilere bağımlılıklar nedeniyle farklı sorunlardan muzdarip olabilmektedir. Ayrıca özel ve genel çözümler tartışılmaktadır. Performans iyileştirmesinin, gelişmiş algoritmalar uygulanarak sağlanabilmesine rağmen yeni problemler yarattığı sonucuna da varılmaktadır. Önceki çalışmalardan olan Nieto ve arkadaşlarının çalışması, regresyon problemleri için başarıyla kullanılan destek vektör makineleri (DVM) ile parçacık sürü optimizasyonu (PSO) tekniğini birleştiren hibrit bir model önermektedir [2]. Bu optimizasyon tekniği, regresyon doğruluğunu önemli ölçüde etkileyen, DVM eğitim prosedürünü belirleyen çekirdek parametresini içermektedir. Bu tahmine dayalı modelin ana avantajlarından biri, motorun önceki çalışma durumları hakkında bilgi gerektirmemesidir. Bu çalışma, tahminde maliyetleri düşürmek amacıyla diğer ölçülen kalite değişkenlerinden KFÖ tahmini için en iyi modele karşılık gelen hiper parametreleri başarıyla optimize etmek için PSO tekniğinin kullanıldığı hibrit PSO–RBF–DVM tabanlı bir model geliştirmiştir. (RBF; radyal tabanlı fonksiyon) Öte yandan, RNN (Recurrent Neural Networks- Tekrarlayan Sinir Ağları), uçak motorları için faydalı yaşam süresini tahmin etmek için bir derin öğrenme yöntemi olarak önerilmiştir. Ne yazık ki,

içeriye bakıldığında tüm katmanların aynı ağırlıkları paylaştığı ve çok uzun süre bilgi depolamayı öğrenmeyi zorlaştıran çok derin bir ileri beslemeli ağ bulunur. Arıza türünü tahmin etmenin yanı sıra, sistemi daha karmaşık ve hiper arıza senaryolarını uyarlamayı zorlaştıran çeşitli arıza modları için birden fazla tahminci eğitmek de gerekmektedir. Karşılaştırıldığında, LSTM (Long / Short Term Memory- Uzun / Kısa Süreli Bellek), uzun vadeli bağımlılıkları öğrenebilen önemli bir RNN dalıdır. Bu nedenle Yuan ve arkadaşları, KFÖ'ü ve her bir arızanın olasılığını aynı anda tahmin edebilen birden fazla yaygın arıza ve daha fazla arıza için model oluşturmak amacıyla LSTM'yi kullanmayı önermiştir [3]. Anormallik dedektörü DVM, hataları etiketlemek için kullanılır. Yazarlar, sonuçları standart RNN, GRU LSTM (GRU; Gated Recurrent Unit- Kapılı Tekrarlayan Hücre) ve AdaBoost-LSTM ile karşılaştırmıştır. Sonuç olarak, önerilen yöntem gelişmiş performans göstermiştir.

Mathew ve arkadaşlarının önerdiği yaklaşım, sensörler tarafından yakalanan geçmiş verileri analiz ederek motorun kalan faydalı ömrünü tahmin etmeye dayanmaktadır [4]. Yazarlar, geçmiş verileri on farklı makine öğrenimi algoritmasına dayandırmaktadır. Çalışmada NASA veri deposundan alınan veri seti kullanılmıştır. Modellerin doğruluğu, modellerin tahmini KFÖ ile gerçek KFÖ'ün karşılaştırılmasıyla hesaplanmıştır, on makine öğrenimi modelinin tümü arasında en yüksek doğruluğu elde eden model seçilmiştir. Sonuçta, random forest (rastgele orman), en yüksek doğruluğu elde eden makine öğrenme modeli olmuştur.

Kestirimci bakımın ana amacı, maliyeti ve çabayı azaltmak için arıza oluşmadan önce bakımı planlayabilmektir. Ma ve arkadaşlarının çalışması, kestirimci bakım stratejisinin verilere bağımlı olduğu temel zayıflığını çözmek için önerilen yaklaşımları içerir [5]. Kısaca kestirimci bakım, verilerdeki gürültüden bağımsız olarak motora takılan sensörlerden toplanan verilere önemli ölçüde bağlıdır, karmaşık korelasyonlara sahip çok sensörlü verilerden faydalı bozulma özellikleri çıkarmak, doğruluğu azaltır ve bozulma değerlendirmesinin uygulanmasını engeller. Bu sorunları çözmek amacıyla, özneliğin denetimsiz kendi kendine öğrenilmesi için birden çok doğrusal olmayan bilgi işleme katmanından yararlanma maksadıyla derin öğrenme önerilmiştir. Bu nedenle, Ma ve arkadaşları, birden fazla sensör motorundan performans düşüşünü otomatik olarak çıkarmak ve çok katmanlı kendi kendine öğrenme yoluyla birden çok özelliği birleştirmek için yığınlanmış SAE (sparse autoencoder- seyrek otomatik kodlayıcı) kullanmıştır. KFÖ'ü tahmin etmek için yazarlar lojistik regresyon ve ek olarak, öznelik çıkarma ve tahmin performansının derin öğrenmenin hiper-parametrelerinden kaynaklanabileceği herhangi bir

etkiyi önlemek için de grid arama yöntemi kullanmışlardır. Veri seti NASA veri deposundan alınmıştır. Belirtildiği gibi, bir tür derin öğrenme modeli olan SAE, yalnızca sistemin gelişme eğilimini yakalamakla kalmaz, aynı zamanda gürültüye karşı da yeterince sağlamdır [5]. Özetle makale, önerilen yöntemin faydalı yaşam süresini tahmin etmede etkili olduğunu ve yüksek tahmin doğruluğu elde ettiğini kanıtlamaktadır. Evrişimli Sinir Ağı ve Uzun-Kısa Süreli Bellek gibi denetimli öğrenme teknikleri kullanılarak, prognostik sağlık ve yönetim uygulamalarında yüksek doğrulukta tahmin elde etmek için farklı Derin öğrenme yaklaşımları önerilmiştir, bunlar hala büyük bir etiketli veri kümesine bağımlı oldukları gibi bazı sorunlarla karşı karşıyadır. Gerçek hayatta yüksek kalite etiketli eğitim verilerinin elde edilmesi hem zorlayıcı hem de zaman alıcı olabilir. Bu nedenle Ellefsen ve arkadaşlarının çalışması, denetimsiz ve denetimli (yarı denetimli) öğrenmenin kombinasyonu ve azaltılmış miktarda etiketlenmiş eğitim verisiyle bile yüksek KFÖ tahmin doğruluğu sağlama potansiyeline sahiptir [6]. Yazarlar, eğitim prosedüründeki çeşitli hiper-parametre miktarını ayarlamak ve her katmanın belirli bir görevi olan beş farklı katman kombinasyonu için Genetik Algoritma (GA) yaklaşımını uygulamışlardır. Önerilen yarı denetimli derin mimari ile, eğitim verilerinin tamamen etiketlendiği son çalışmalara kıyasla umut verici sonuçlar elde etmişlerdir. Ancak, her bir alt küme için ortalama eğitim süresi 60 saat sürmüştür.

Özet olarak, önerilen yaklaşımlar, yüksek doğrulukta tahmin elde etmek için modellerin performansını iyileştirmek amacıyla çözümler sunar. Ancak tahmine dayalı bakım, verilerdeki gürültüden bağımsız olarak motora takılan sensörlerden alınan verilere önemli ölçüde bağlıdır ve faydalı bozulma özelliklerini çıkarır. Karmaşık korelasyonlara sahip çok duyuşal verilerden elde edilmesi doğruluğu azaltır. Bu sorunu çözmek için derin öğrenme önerilir. Buna rağmen bozulma değerlendirmesi uygulanamayabilir. Büyük miktarda veri, modelin öğrenme aşamasında kabul edilemez bir şekilde çok zaman kaybına neden olur. Bu büyük miktardaki veriyi azaltmak için boyut küçültme tekniği uygulanabilir.

Bu çalışmada, öğrenme aşamasının süresini azaltmak için bir boyut indirgeme tekniği olarak Temel Bileşenler Analizi (TBA- principal component analysis) algoritması ve daha sonra kalan faydalı ömür tahmin modeli olarak yapay sinir ağları kullanılmıştır.


1.1. BAKIM YAKLAŞIMLARI

Son yıllarda teknolojinin gelişmesiyle birlikte sanayi ve diğer ilgili alanlarda bakıma verilen önem hızla büyümeye ve ilgili yöntemler gelişmeye başlamıştır. Bakım, bir ögeyi yaşam döngüsü boyunca gerekli işlevi yerine getirebileceği bir durumda tutmayı veya geri yüklemeyi amaçlayan tüm teknik, yönetsel ve idari faaliyetleri birleştiren bir stratejidir. Bakım eylemlerinin amacı yalnızca arızaları en aza indirmek veya bir elemanın ömrünü uzatmak değil, aynı zamanda bakımla ilgili operasyonel maliyetleri en aza indirmektir [7]. Bakım maliyetleri, tüm üretim veya üretim tesislerinin toplam işletme maliyetlerinin önemli bir parçasıdır [8].

Genel olarak, literatüre girmiş dört farklı bakım stratejisi vardır:

1.1.1. Koruyucu Bakım


Koruyucu bakım veya reaktif yönetim, arıza meydana geldikten sonra makine veya ekipman için bakım eylemi gerçekleştiren bir tekniktir. Ancak, aslında yönetimin “bakım gerektirmeyen” bir yaklaşımıdır. Aynı zamanda en pahalı bakım yönetimi yöntemidir. Ekipmanın plansız arızalanması durumunda tamir edilmesi ve yedek parça beklenmesi gibi durumlar doğrudan fabrikalara ekstra maliyet ve zaman kaybına neden olmaktadır. Şekil 1.1 koruyucu bakımı göstermektedir.



Şekil 1.1:Koruyucu bakım (Kaynak:Mathworkth).

1.1.2. Önleyici Bakım

Zararı önlemek için arıza oluşmadan önce ekipman üzerinde düzenli bakım yapan bir tekniktir. Önleyici bakımla ilgili en büyük zorluk, bakımın ne zaman yapılacağını belirlemektir. Arızanın ne zaman meydana geleceği bilinmediğinden, planlamada, özellikle de güvenlik açısından kritik ekipmanı çalıştırmada ihtiyatlı olunmalıdır. Ancak bakımı çok erken planlayarak, hala kullanılabilir olan makine ömrünü boşa harcamak da maliyetleri artırmaktadır. Şekil1.2 önleyici bakım göstermektedir.



Şekil 1.2:Önleyici Bakım (kaynak:mathworkth).

1.1.3. Şartlara Dayalı Bakım


Bu bakım yöntemi, yalnızca gerçekten gerekli olduklarında hayata geçirilen sürekli bir makine veya ekipman izlemeye veya bunların işlem sağlığına dayanır. Bakım eylemleri yalnızca, işlemin bir veya daha fazla bozulma koşulundan sonra işlemle ilgili eylemler gerçekleştirildiğinde yapılır. Genellikle önceden planlanmaktadır [9].

1.1.4. Kestirimci Bakım

Kestirimci bakım, bir makinenin arızalanma süresini tahmin eden bir tekniktir. Öngörülen arıza süresinin bilinmesi, ekipman için bakım planlaması yapmak için en uygun zamanı bulmaya yardımcı olur. Kestirimci bakım yalnızca bir yakıt arızasını öngörmekle kalmaz, aynı

zamanda karmaşık bir makinedeki sorunları belirler ve hangi parçaların düzeltilmesi gerektiğini belirlemeye yardımcı olur. Ekipman bakım gereksinimlerinin tahmini, işletmelerin arıza meydana gelmeden önce ekipman bakımını planlamasına yardımcı olur. Şekil 1.3 kestirimci bakımı göstermektedir.

Kestirimci bakım, periyodik bakım durumunda olduğu gibi gereksiz bakım faaliyetlerini yapma ihtiyacını ortadan kaldırdığı için çok fazla zaman ve enerji tasarrufu sağlayabilmektedir [10] [11].



Şekil 1.3:Kestirimci Bakım (kaynak:mathworkth).

Günümüzde sensörler fabrikalarda ekipmanlara eklenmekte, bu sensörler büyük miktarda veri toplamakta ve bu veriler, bulut sunucuları da dahil olmak üzere büyük depolama cihazlarında saklanmaktadır. Sensör verilerinin davranışı, bir ekipman arızasına neyin yol açabileceğine karar vermek için yararlı bilgiler içerir. Dolayısıyla, bakım kararı artık tahmine dayalı ve analitik olarak adlandırılan bir veri analitiği sorununa dönüştürmektedir [12] [13]. Son dönemlerde, veriler teknolojik açıdan büyük önem kazanmıştır.

Herhangi bir bakım stratejisinin ekipman arıza oranlarını en aza indirmesi, ekipman durumunu iyileştirmesi, ekipmanın ömrünü uzatması ve bakım maliyetlerini düşürmesi gerekir. Kestirimci bakım (PdM - Predictive Maintenance), bu özelliklere ulaşma yeteneğine sahip diğer bakım stratejileri arasında en umut verici stratejilerden biri olduğu ortaya çıkmıştır [14]. Bu nedenle, bu strateji son zamanlarda birçok alanda uygulanmıştır. Kestirimci Bakım (PdM - Predictive Maintenance), endüstrilerin dikkatini çekmiş, dolayısıyla varlıkların kullanımını ve yönetimini optimize etme yeteneği nedeniyle I4.0 çağında uygulanmıştır [15], [16].

2. YAPAY ZEKA VE MAKİNE ÖĞRENMESİ


2.1. MAKİNE ÖĞRENMESİ

Makine öğrenmesi yapay zekanın bir alt dalı olarak tanımlanmaktadır. Yeni öğrenme algoritmalarının geliştirilmesi, çevrimiçi verilerdeki ve işlem gücündeki artış, makine öğrenmesi alanının gelişmesini hızlandırmıştır [17]. Makine öğrenmesi, bir girdi vektörü ile bir sonuç arasındaki ilişkiyi belirlemeye çalışır. Bu öğrenme türü, probleme ait verilerden yola çıkarak modelleme işlemi yapmaktadır. Ayrıca, veriler içindeki kalıpları çıkararak sınıflandırma, kümeleme ve tahmin gibi farklı işlemleri gerçekleştirebilir.

Geleneksel makine öğrenmesi, özellik çıkarma ve model seçimi süreçlerini ayrı şekilde gerçekleştirmektedir. Her süreç adım adım oluşturulmaktadır. Modeli oluşturan bireylerin seçimine göre özelliklerin belirlenmesi uzman alan bilgisi gerektirir. Özellikler ham verilerin farklı bir alana (istatistiksel, frekans ve zaman-frekans alanı vb.) dönüştürülmesiyle elde edilir. Özellikler makine öğrenmesi modeline girmeden önce özelliklerden ilgisiz olanların çıkarılması işlemi yapılır.

Teknolojinin gelişmesiyle birlikte veriler çok daha rahat toplanabilir ve saklanabilir duruma gelmiştir. Toplanan verilerin büyüklüğü nedeniyle, verilerin klasik yöntemlerle analiz etmek noktasında yetersiz kalılabilmektedir. Bilgisayarların işlem güçlerinin artmasıyla toplanan bu verilerin işlenmesi kolaylaşmıştır. Bu gelişmeler ışığında makine öğrenmesi çok daha önemli hale gelmeye başlamıştır.

Makine Öğrenimi (ML), bilgisayarların herhangi bir açık program olmadan mevcut verilerden kendi kendine öğrenmesini sağlamaktadır. Bu makineler, geçmiş öğrenmelerine dayalı olarak yeni verilere tepki verebilir. Tahmin, Makine Öğreniminin önemli uygulamalarından biridir [18]. Üç ML kategorisi vardır. "Denetimli Öğrenme", "Denetimsiz Öğrenme" ve "Pekiştirmeli Öğrenme" olarak kategorize edilmektedir. Şekil 2.1 makine öğrenimi tekniklerini göstermektedir.



Şekil 2.1: Makine Öğrenmesi Teknikleri

2.1.1. Denetimli Öğrenme

Denetimli öğrenme, her eğitim örneğini karşılık gelen hedef değeriyle birlikte gerektiren bir makine öğrenimi tekniğidir. Daha basit bir ifadeyle, her eğitim örneği hem girdi hem de çıktı değerleri olarak gelir. Eğitim sürecinden sonra model, yeni bir girdi için hedef değer anlamına gelen çıktı değerini tahmin eder. Yüksek doğrulukta bir makine öğrenimi modeli oluşturmanın önemli adımlarından biri, bu modeli eğitmek için verileri doğru bir şekilde hazırlamaktır. Denetimli Öğrenme, ortaya çıkan sorunlara göre "Sınıflandırma" ve "Regresyon (Bağlanım)" olmak üzere ikiye ayrılır. Sınıflandırma görevinde, veri setindeki hedef / çıktı değerleri sınıflardan yani kategorilerden oluşur. Böylece eğitim sürecinde modeller, girdi değerlerinin tanımlı sınıflara ait olduğu bilgiler üzerine eğitilir. Sonuç olarak, modeller herhangi bir yeni girdi değerinin herhangi bir sınıfa ait olduğuna dair tahminlerde bulunur. Genel olarak, ikili ve çok sınıflı sınıflandırma olmak üzere iki tür sınıflandırma problemi vardır. İkili sınıflandırmada, iki sınıf etiketine sahip sınıflandırma görevleri ele alınır. E-posta spam algılama görevleri, ikili sınıflandırma görevlerine örnek olabilir. Bu modellerin çıktıları "spam" veya "spam değil" şeklindedir. Ancak ikili sınıflandırmanın aksine, çok sınıflı sınıflandırmada veri kümeleri ikiden fazla sınıfa ait örnekleri içerir. Örnek olarak, yüz tanıma sistemlerinde yüz sınıflandırma görevi. Bu sistemlerde Modeller, binlerce yüz arasında fotoğrafın hangi yüze ait olduğunu tahmin edebilir.

Regresyon görevleri de Denetimli Öğrenme yöntemidir. Sınıflandırma ve regresyon arasındaki temel fark, regresyonda sayısal değerler, sınıflandırmada ise kategorik değerler olan tahminler yapılmasıdır [19]. Denetimli Öğrenme görevleri için birçok popüler makine öğrenimi

algoritması vardır. Bunlardan bazıları Lojistik Regresyon, K-En Yakın Komşular, Karar Ağaçları, Destek Vektör Makinesi, Naif Bayes, Rastgele Orman vb.dir.

2.1.2. Denetimsiz Öğrenme

Denetimli öğrenmenin aksine, denetimsiz öğrenme, eğitim sürecinde etiketleri olmayan eğitim verilerini gerektirir. Denetimli öğrenmenin aksine, denetimsiz öğrenmedeki modellerin kullanıcılar tarafından denetlenmesine gerek yoktur. Bu öğrenme tekniği, modellerin daha önce tanımlanmamış yapıları ve bilgileri kendi kendilerine öğrenmelerine izin verir. Denetimsiz Öğrenme, aynı zamanda kümeleme sorunu olarak da bilinir. Bu tür kümeleme problemlerinde veri seti, veri setindeki değerler arasındaki benzerlikler dikkate alınarak gruplara ayrılır. Her farklı gruptaki veriler aynı özelliklere sahiptir. Bu şekilde yeni gelen verinin özellikleri dikkate alınır ve bu veriler ona en yakın olduğu kümelere atanır. Kümeleme, pazar bölümlenme analizi, bitkileri biyolojideki özelliklerine göre gruplama, twitter'daki davranışlara göre insanları sınıflandırma gibi birçok gerçek dünya problemünde kullanılmaktadır.

2.1.3. Pekiştirmeli Öğrenme

Eylemlerin bazı ödül veya cezalarla ilişkilendirildiği bir deneme-yanılma ve kontrol-teorik öğrenme yöntemi, pekiştirmeli öğrenme olarak adlandırılır. Makine ve çevre arasındaki etkileşim, öğrenmeyle sonuçlanır. Öğrenme ortamından alınan geri bildirimler karar vermeyi destekler. Kümülatif deneyime ve sonraki ödüllere göre değişiklikler yapılır. Herhangi bir eylemin gücü, bir eylemin gerçekleştirilme sayısı ile belirlenir. Böyle bir modelin unsurları strateji, eleştirme, teşvik ve modeldir. Ortak bilginin sömürülmesi ve tanımlanamayan alanların değerlendirilmesi, öğrenme sırasında takas edilir. İki alt kümesi şunlardır; modelden bağımsız ve modele dayalı yöntem. Modelsiz öğrenme, Q-6 öğrenme, Derin Q-Network ve Derin Q-öğrenmeden oluşur. Başlıca uygulamalar uçak kontrolü, robotik, otomasyon vs. [20].

2.2. DERİN ÖĞRENME

Makine öğrenmesinin bir dalı olan derin öğrenme, insan beyninin işleyişinden ilham alan yapısıyla son yıllarda araştırmacıların daha fazla üzerinde durduğu bir alan haline gelmiştir. Bu mimari, algoritmanın birden fazla soyutlama seviyesindeki özelliklerini otomatik olarak

öğrenmesini sağlamaktadır. Ham verilerin girdi olarak doğrudan kullanılabilirdiği yöntemde özelliklerin çıkarılması için insan uzmanlığına ihtiyaç duyulmamaktadır.

Yapay zekâda bir atılım olarak derin öğrenme; konuşma tanıma, görüntü yenileme, doğal dil işleme (örneğin çeviri, anlama, test soruları ve cevapları), çok modlu görüntü metni ve oyunların (örn. Alphago) çeşitli uygulamalarında olağanüstü performans göstermektedir. Otomatik özellik öğrenme ve yüksek hacimli modelleme yetenekleri ile derin öğrenme büyük veri çağında akıllı üretim için gelişmiş bir analiz aracı sağlamaktadır.

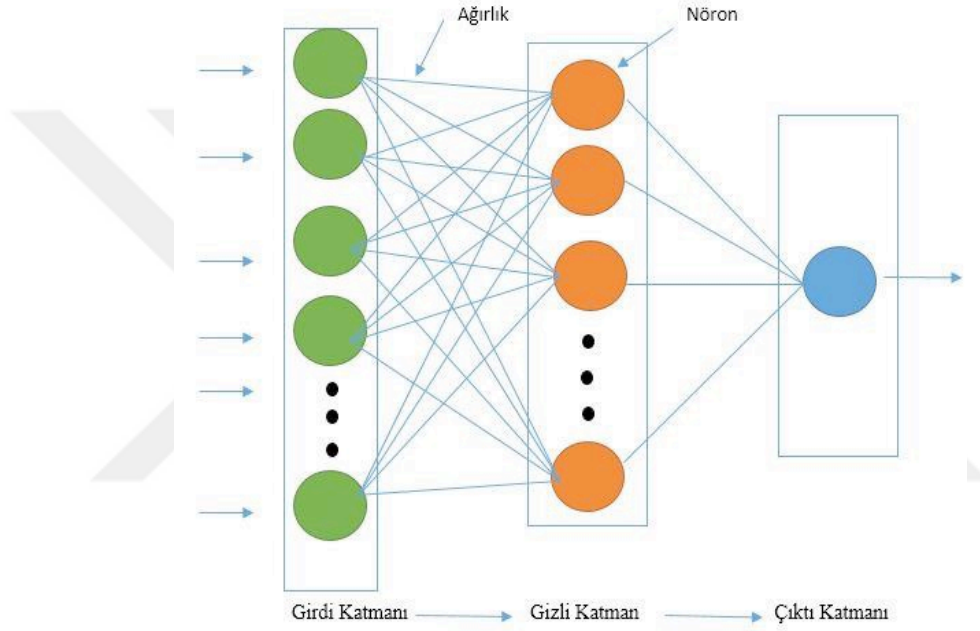
Yapay sinir ağları birden fazla katman geliştirdiğinde derin öğrenme başlar. Birkaç nöron katmanında çalışmak, derin öğrenme ve veri madenciliğine doğru atılan ilk adımdır. Perseptron, çok katmanlı ağlarda 1986'da Rumelhart, Hinton ve Williams tarafından Gradient iniş adı verilen bir geri yayılım tekniği ile geliştirildiğinde yararlı olmaya başlamıştır. Geriye yayılım; sinir ağının öğrenmesinde daha düşük hataya sahip olduğu, doğru ağırlıkları tahsis etmeyi amaçlayan algoritmalar topluluğudur. Geri yayılım içinde en fazla kullanılan yöntemlerinden biri olan Stokastik Gardiyan İnişi (SGİ- Stochastic Gradient Descent SGD), kısmi türevler için hesap kavramlarını zincir kuralları olarak kullanıp hesaplama hata oranını en aza indirmeyi amaçlayan bir algoritmadır [21].

Derin öğrenme yöntemleri çok katmanlı yapıları nedeniyle büyük verileri işleme ve gizli bilgileri çıkarma yeteneğine sahiptir. Buna bağlı olarak yüksek oranda doğrusal olmayan işlemler gerçekleştirebilir. Büyük verinin ortaya çıkmasıyla derin öğrenme, büyük miktarlarda denetimsiz verilerin yer aldığı senaryolar için kullanılmıştır. Büyük veri analizi için etkili bir araç olan derin öğrenme tekniği, büyük miktarlarda etiketlenmemiş eğitim verileri ile başarılı sonuçlar vermiştir.

Geleneksel makine öğrenmesi yöntemleri ham verileri işleme konusunda yetenekli değildir. Bir makine öğrenmesi modeli oluşturulurken ham verileri girdi setine dönüştürürken alan ve özellik mühendisliği bilgisi gerekmektedir. Derin öğrenme bir modelin ham verilerle beslenmesine ve algılama veya sınıflandırma için gerekli gösterimleri otomatik olarak keşfetmesine izin vermektedir [22].

2.2.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA) kavramı, beynin biyolojik sinir ağlarından ilham almaktadır. İnsan beyninin düşünme ve problem çözme süreçleri araştırmacılar için her zaman cazip bir konu olmuştur. YSA'lar insan beyninde bilgi işlemeyi ve bilgi edinimini taklit ederek öğrenmelerini sağlayacak matematiksel algoritmalar geliştirmeyi amaçlar [23]. Beyin, karmaşık problemleri çözmek için birbirine bağlı nöronları kullanır. YSA yapay nöronlar kullanarak giriş sinyalleri ile bir çıkış sinyali arasındaki ilişkiyi modellemek için aralarında bağlantı kurar. Birbirine bağlı nöronlar, problemi çözmenin temelini oluşturan yapı taşlarıdır, Şekil 2.2'da temel bir YSA modeli gösterilmektedir.



Şekil 2.2:Yapay Sinir Ağının Genel Yapısı

Makine öğrenmesi alanında, yapay sinir ağı biyolojik sinir ağının bilgisine adapte olmaya çalışır. Yapay sinir ağı, nöronlar arasındaki bağlantılar üzerinde, ağırlıkları belirleme yöntemi ve aktivasyon fonksiyonu ile karakterize edilir [24]. Giriş vektörünün boyutuna eşit olan bir girdi katmanı ile bir çıktı katmanı olan yapı en basit halidir. Nöronlar arasındaki bağlantıların farklı ağırlıkları vardır. Farklı ağırlıktaki girişler toplamının matematiksel formülasyonu aşağıda gösterilmiştir.

$$y = \sum_{i=1}^k (w_i + b) \quad (2.1)$$

Burada k, giriş sayısını; w, ağırlığını; x, giriş değerini ve b, bias terimini ifade etmektedir.

Daha sonra net toplam bir çıkış değeri sağlayan doğrusal olmayan bir aktivasyon fonksiyonu ile işlenir.

$$f(y) = f\left(\sum_{i=1}^k w_i x_i + b\right) \quad (2.2)$$

Doğrusal olmayan aktivasyon fonksiyonu (f), ağırlık girişlerinin toplamını düğümün çıkışına dönüştürür. Sigmoid veya lojistik fonksiyon düğüm çıkışını 0 ile 1 arasında kısıtlayan transfer fonksiyonudur.

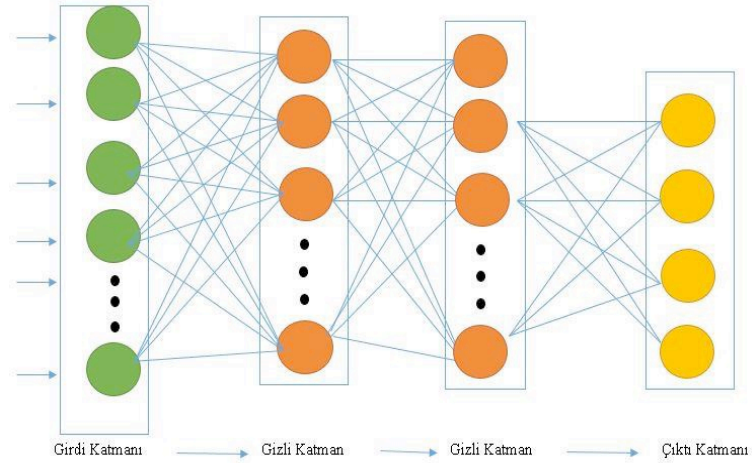
Standart bir sinir ağı, her biri gerçek değerli aktivasyonlar dizisi üreten nöron adı verilen birçok basit bağlı işlemciden oluşur. Giriş nöronları çevreyi algılayan sensörler aracılığıyla aktif hale gelirken diğer nöronlar daha önce aktif olan nöronların ağırlıklı bağlantıları ile aktif hale gelir [25].

Genel bir yapay sinir ağının eğitimi, geri yayılım algoritması kullanılarak gerçekleştirilir. Geri yayılım algoritması bilinen en yaygın yöntemdir. Denetimli öğrenmede ağı bir dizi girdi dahil edildikten sonra çıktı ile gerçek değer karşılaştırılır. Ağırlıkların değerini ayarlamak için normalize edilmiş ortalama kare hatası (OKH) kullanılarak ağı üzerinde geriye doğru yayılır. Bu işlem kabul edilebilir bir OKH değerine ulaşmaya kadar tekrarlanır. YSA başarılı bir şekilde eğitildikten sonra test verileri için kullanılma hazır hale gelmiş olur [26].

$$OKH = \frac{1}{n} \sum_{i=1}^n (y_i^{\wedge} - y_i)^2 \quad (2.3)$$

Bağlantı mimarisine göre YSA'lar ileri beslemeli ağlar ve geri beslemeli ağlar olarak ikiye ayrılır. Çok katmanlı algılayıcı denilen en yaygın ileri beslemeli ağı ailesinde nöronlar, aralarında tek yönlü bağlantıları olan katmanlar halinde düzenlenir [27].

Derin sinir ağlarının yapısı, daha karmaşık ve doğrusal olmayan ilişkileri modellemek için giriş ve çıkış katmanları arasındaki gizli katmanlar ekleyerek geleneksel sinir ağlarının genişletilmesi prensibine dayanmaktadır. Giriş katmanından çıkış katmanına akan tipik bir ileri besleme ağı, iki ve ikiden fazla gizli katmanın bulunduğu yapılardır. Gizli katmanlardaki nöron sayısını seçmek için herhangi bir kriter yoktur. Bu parametreler farklı ayarlandığında sınıflandırma doğruluğunun performansını etkileyecektir. Derin sinir ağı (DSA), birçok alanda başarılı sınıflandırma veya regresyon için yaygın olarak kullanılan bir mimaridir. Şekil 2.3, DSA'lar için tipik mimariyi göstermektedir.



Şekil 2.3:İki Gizli Katmanlı Derin Sinir Ağı Yapısı

2.3. TEMEL BİLEŞENLER ANALİZİ (TBA)

Büyük veri kümeleri giderek daha yaygın hale gelmektedir ve genellikle yorumlanmaları zordur. Temel bileşen analizi (TBA- Principle component analysis), bu tür veri kümelerinin boyutlarını azaltmak, yorumlanabilirliği artırmak, ancak aynı zamanda bilgi kaybını en aza indirmek için kullanılan bir tekniktir. Bunu, varyansı artırdıkça maksimize eden yeni ilintisiz değişkenler oluşturarak yapar. Bu tür yeni değişkenlerin bulunması, temel bileşenler, bir özdeğer / özvektör problemini çözmeye indirgenir ve yeni değişkenler önceden değil, eldeki veri kümesi tarafından tanımlanır, dolayısıyla TBA'yı uyarlanabilir bir veri analizi tekniği haline getirmektedir [28]. Temel bileşenler olan bu yeni değişkenlerin görselleştirilmesi ve istatistiksel analizi, numuneler arasındaki benzerlikleri ve farklılıkları bulmaya yardımcı olabilir. İlk birkaç bileşene en büyük katkı sağlayan önemli orijinal değişkenler de keşfedilebilmektedir.

Matematiksel olarak TBA, değişkenler arasındaki simetrik kovaryans matrisini kullanır. $N \times N$ boyutundaki kare matrisler için, N öz değeri olan N özvektör belirlenebilir. Bileşenler bu kare matrisin özvektörleridir ve en büyük özdeğere sahip özvektör ilk temel bileşendir. En değişken bileşenlerin en önemli olanlar olduğu varsayılırsa, veri kümelerindeki örnekler arasındaki mesafeleri ve farklılıkları görselleştirmek için ilk bileşenler birbirine göre çizilebilir.

Önemli bileşenlere en çok katkıda bulunan değişkenleri keşfederek, biyolojik anahtar süreçler hakkında içgörüler elde etmek mümkündür. Veri kümesinin, binlerce orijinal değişkenin aksine, veri kümesindeki toplam varyansın %90'ından fazlasını içeren on veya daha az temel bileşene sahip olması nadir değildir.

2.3.1. TBA ile İlgili Adımlar

1. Verileri standartlaştırması. (Ortalama = 0 ve varyans = 1)
2. Boyutların kovaryans matrisini hesaplanması.
3. Özvektörleri ve özdeğerleri kovaryans matrisinden elde etmesi (korelasyon matrisi veya hatta tekil değer ayrışımı da kullanabilmektedir)
4. Özdeğerleri azalan sırada sıralaması ve en büyük k özdeğerine karşılık gelen en üst k özvektörlerini seçmesi (k, yeni özellik alt uzayı $k \leq d$ 'nin boyutlarının sayısı olur, d, orijinal boyutların sayısıdır).
5. Seçilen k özvektörlerinden projeksiyon matrisini W oluşturması.
6. Yeni k-boyutlu özellik alt uzayı Y'yi elde etmek için orijinal veri seti X'i W yoluyla dönüştürmesi

3. MODEL KURULMASI

3.1. KULLANILAN TEKNOLOJILER

Bu tez çalışmasında, Jupyter notebook aracılığıyla derin öğrenme için ön işleme ve tensorflow için gerekli olan numpy, pandas, matplotlib, sklearn ve seaborn gibi python programlama dili ve kütüphaneleri kullanılarak uygulamalar geliştirilmiştir.

Jupyter Notebook web tabanlı bir teknolojidir ve yazılan kodu bağımsız hücrelere yazmaya olanak tanır. Ayrıca Jupiter Notebook kullanarak veri temizleme, istatistiksel modelleme, veri görselleştirme, ML vb. işlemler kolaylıkla uygulanabilir.

Python programlama dili, C++, JavaScript, C# ve Java gibi diğer programlama dilleri gibi genel amaçlı bir dildir. Ancak son yıllarda python'un diğer dillere göre avantajları, ona olan ilgiyi daha da artırmıştır. Bu özelliklerden bazıları; daha kolay ve esnek olmak, veri bilimi alanında diğer rakiplerinden daha standart olmak, hemen hemen tüm işletim sistemlerinde çalışmak, çok sayıda kütüphaneye sahip olmak ve özgür olmaktır.

Numpy, Sayısal Python olarak bilinen çekirdek kitaplıktır. Numpy kütüphanesi, çok boyutlu diziler ve matrisler üzerinde matematiksel işlemlerin kolayca yapımına yardımcı olur.

Pandas, arka uç kaynak kodu C veya Python ile yazılmış ve yüksek düzeyde optimize edilmiş performans sağlayan verilerin analizinde kullanılan en popüler python kütüphanelerinden biridir.


Seaborn, matplotlib tabanlı, yaygın olarak kullanılan bir veri görselleştirme kütüphanesidir. Seaborn kütüphanesi üst düzey, kullanışlı ve kolay yorumlanabilir grafikler çizmeyi sağlar.

Scikit-learn, çeşitli Makine öğrenmesi (ML- Machine Learning), ön işleme, çapraz doğrulama ve görselleştirme algoritmalarını uygulamak için tek bir çerçeve kullanan açık kaynaklı bir Python kitaplığıdır.

TensorFlow, Google tarafından sağlanan bir makine ve derin öğrenme çerçevesidir. TensorFlow, çerçeve ile ön uç API oluşturma sağlamak için python kullanan ve bu uygulamaları yüksek performanslı C++ ile yürüten açık kaynaklı bir kütüphanedir.

3.2. VERİ KÜMESİ AÇIKLAMASI

Bu çalışmada kullanılan veri seti, gerçekçi ticari turbofan motorunu simüle eden C-MAPSS (Commercial Modular Aero-Propulsion System Simulation) olarak NASA tarafından sağlanmıştır. Yazılım MATLAB® ve Simulink® ortamında [29] kodlanmıştır. Şekil 3.1 motor simülasyonunun temel parçalarını göstermektedir.



Şekil 3.1: C-MAPSS'de simüle edilen motorun basitleştirilmiş şeması

Dört veri seti vardır ve operasyonel ayarlarına göre birbirlerinden farklılık gösterirler. Her veri kümesinin depoda eğitim, test ve KFÖ kümeleri vardır. Bu çalışmada deneyler için üç veri setleri (FD001, FD002, FD003) kullanılmıştır. Her veri seti, her bir farklı motor için kimlikler, 21 farklı sensör ölçümü, makinelerin üç ortam koşulunu ve bir çevrim olarak çalışma süresini tanımlayan verileri içerir. Tablo 3.1. veri kümesinin açıklamasını içerir ve daha iyi anlaşılmasına yardımcı olur [29].

Tablo 3.1: Veri kümesinin açıklaması [30].

Parametre	Açıklama	Birim
ID	Motorun kimliği	-
Çevrim	Zaman, çevrim şeklinde	-
operasyonel ayarlar 1	Rakım	-
operasyonel ayarlar 2	Mach sayısı	-
operasyonel ayarlar 3	Gaz kelebeği çözücü açısı	-
Sensör ölçümü 1	Fan girişindeki toplam sıcaklık	°R
Sensör ölçümü 2	Alçak basınçlı kompresör çıkışındaki toplam sıcaklık	°R
Sensör ölçümü 3	Yüksek basınçlı kompresör çıkışındaki toplam sıcaklık	°R
Sensör ölçümü 4	Alçak Basınç Türbin çıkışındaki toplam sıcaklık	°R
Sensör ölçümü 5	Fan Girişindeki Basınç	psia
Sensör ölçümü 6	Baypas Kanalındaki Toplam Basınç	psia
Sensör ölçümü 7	Yüksek basınçlı kompresör çıkışındaki toplam basınç	psia
Sensör ölçümü 8	Fiziksel fan hızı	rpm
Sensör ölçümü 9	Fiziksel çekirdek hızı	rpm
Sensör ölçümü 10	Motor basınç oranı (P50/P2)	-
Sensör ölçümü 11	Yüksek basınçlı kompresör çıkışındaki duruk basınç	psia
Sensör ölçümü 12	Yakıt akış oranı	pps/psi
Sensör ölçümü 13	Düzeltilmiş fan hızı	rpm
Sensör ölçümü 14	Düzeltilmiş çekirdek hızı	rpm
Sensör ölçümü 15	Baypas Oranı	-

Sensör ölçümü 16	Bumer yakıt-hava oranı	-
Sensör ölçümü 17	Kanama Entalpisi	-
Sensör ölçümü 18	İstenilen fan hızı	rpm
Sensör ölçümü 19	İstenilen düzeltilmiş fan hızı	rpm
Sensör ölçümü 20	Yüksek Basınçlı Türbin soğutma sıvısı tahliyesi	lbm/s
Sensör ölçümü 21	Alçak Basınç Türbini soğutma sıvısı tahliyesi	lbm/s

Eğitim veri seti (çalışmadan arızaya veri kümesi), motorların zaman serisinin başlangıcında normal şekilde çalışmaya başladığı ve daha sonra motor arızasına kadar bozulma gösterdiği anlamına gelen veri setidir. Üç veri kümesinin her biri için, veri kümelerini test etmek için eğitim, test ve ayrılmış (KFÖ) kayıtları bulunur.

Şekil 3.2 motorun kimliğini, çevrimlerini, çalışma ayarlarını ve 21 sensör ölçümünü içeren ilk veri seti FD001'in eğitim setinin ilk 20 satırını göstermektedir. Her satır örneği temsil eder ve her sütun özelliği temsil etmektedir.

Motor No	Çevrim	OpAyrn1	OpAyrn2	OpAyrn3	SensörÖlçümü1	SensörÖlçümü2	SensörÖlçümü3	SensörÖlçümü4	SensörÖlçümü5	...	SensörÖlçümü13	Sensör
0	1	1	-0.0007	-0.0004	100.0	518.67	641.82	1589.70	1400.60	14.62	...	2388.02
1	1	2	0.0019	-0.0003	100.0	518.67	642.15	1591.82	1403.14	14.62	...	2388.07
2	1	3	-0.0043	0.0003	100.0	518.67	642.35	1587.99	1404.20	14.62	...	2388.03
3	1	4	0.0007	0.0000	100.0	518.67	642.35	1582.79	1401.87	14.62	...	2388.08
4	1	5	-0.0019	-0.0002	100.0	518.67	642.37	1582.85	1406.22	14.62	...	2388.04
5	1	6	-0.0043	-0.0001	100.0	518.67	642.10	1584.47	1398.37	14.62	...	2388.03
6	1	7	0.0010	0.0001	100.0	518.67	642.48	1592.32	1397.77	14.62	...	2388.03
7	1	8	-0.0034	0.0003	100.0	518.67	642.56	1582.96	1400.97	14.62	...	2388.03
8	1	9	0.0008	0.0001	100.0	518.67	642.12	1590.98	1394.80	14.62	...	2388.05
9	1	10	-0.0033	0.0001	100.0	518.67	641.71	1591.24	1400.46	14.62	...	2388.06
10	1	11	0.0018	-0.0003	100.0	518.67	642.28	1581.75	1400.64	14.62	...	2388.01
11	1	12	0.0016	0.0002	100.0	518.67	642.06	1583.41	1400.15	14.62	...	2388.02
12	1	13	-0.0019	0.0004	100.0	518.67	643.07	1582.19	1400.83	14.62	...	2388.08
13	1	14	0.0009	-0.0000	100.0	518.67	642.35	1592.95	1399.16	14.62	...	2388.00
14	1	15	-0.0018	-0.0003	100.0	518.67	642.43	1583.82	1402.13	14.62	...	2388.08
15	1	16	0.0006	0.0005	100.0	518.67	642.13	1587.98	1404.50	14.62	...	2388.07
16	1	17	0.0002	0.0002	100.0	518.67	642.58	1584.96	1399.95	14.62	...	2388.04
17	1	18	-0.0031	-0.0001	100.0	518.67	642.62	1591.04	1396.12	14.62	...	2388.07
18	1	19	0.0032	-0.0003	100.0	518.67	641.79	1587.56	1400.35	14.62	...	2388.03
19	1	20	-0.0037	0.0001	100.0	518.67	643.04	1581.11	1405.23	14.62	...	2388.02

20 rows x 27 columns


Şekil 3.2: Birinci verinin (FD001) eğitim veri setinin ilk 20 satırı.

(FD001) Eğitim veri seti, 100 motorun arızaya kadar çalışma bilgilerini içerir. Şekil 3.3'te gösterildiği gibi motorların arızası farklı zamanlarda olmaktadır. İlk 5 motorun maksimum çevrimini aynı şekilde göstermektedir.

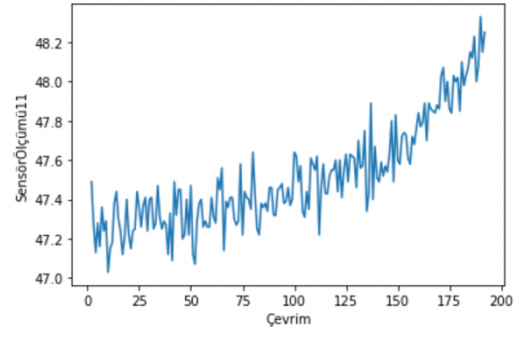
Motor No	Maksimum Çevrimini
0	192
1	287
2	179
3	189
4	269

Şekil 3.3:5 motorun maksimum çevrimi.


Şekil 3.4 (a,b,c,d,e,f), FD001 veri setinde ilk motor için seçilen sensörün zaman içindeki ölçümlerini gösterir. Bazı sensörler sensör 19 ve sensör 5 gibi okumaktadır, tıpkı düz bir çizgi gibi ve baştan sona değişmemeleri, arıza hakkında herhangi bir bilgi taşımadıkları anlamına gelmektedir. Öte yandan sensör 11, sensör 14'ün aksine zamanla artmış, sensör 20 ve sensör 21 zamanla azalmıştır. Sonuç olarak, modelimiz için oldukça önemli olan zamanla azalan veya artan sensör ölçümlerinin aksine, zamanla değişmeyen sensör ölçümlerinin, motor arızası hakkında hiçbir bilgisi yoktur.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 3.4: Birinci motor arızalanana kadar altı sensör ölçümü.

3.3. VERİ ÖN İŞLEME

Daha önce bahsedildiği gibi FD001, FD002, FD003 ve FD004 olarak adlandırılan dört veri seti bulunmaktadır. Her veri kümesinde ayrı ayrı eğitim ve test veri kümesi bulunur. Tablo 3.2, eğitim ve test veri kümesi olarak her bir veri kümesindeki örnek sayısını gösterir.

Tablo 3.2: Her veri kümesindeki örnek sayısı.

Veri Kümesi	Eğitim veri seti	Test veri seti	Toplam
FD001	20631	13096	33727
FD002	53759	33991	87750
FD003	24720	16596	41316
FD004	61249	41214	102463

Hem eğitim hem de test setleri motor No, çevrim, operasyonel ayarlar ve sensör ölçümlerini içerir. Bu çalışmada denetimli öğrenme kullanılmıştır. Hedefimiz veri setlerimizde olmayan motorun kalan faydalı ömrünü elde etmek olduğundan, kalan faydalı ömür sütununu (hedef) oluşturmak için aşağıdaki denklem (1) kullanılmıştır.

$$FKÖ_i = Maksimum_{çevrim(i)} - Çevrim_i \quad (3.1)$$

Burada $Maksimum_{\text{çevrim}(i)}$ arızadan önce ulaşılan motorun (i) maksimum devridir ve Çevrim_i i anında mevcut devirdir. Özellik olarak KFÖ eklendikten sonra motor kimliği, motor arızası hakkında herhangi bir bilgiye sahip olmadığı ve KFÖ tahminini etkilemediği için çıkarıldı.

3.4. VERİ DÖNÜŞÜMÜ

Kullanılan veri kümesindeki öznitelik değerleri birbirinden çok farklıdır ve bu durumda modelin doğruluğunu önemli ölçüde etkileyebilir ve yanılıya neden olabilir, bu nedenle veri dönüşümü yüksek tahmin doğruluğu elde etmek için çok önemlidir. Bu çalışmada, verileri [0-1] ölçeğine yeniden ölçeklendirmek için Minimum-Maksimum normleştirme tekniği kullanılmıştır. Aşağıdaki denklemi (2) kullanan Minimum-Maksimum dönüşüm tekniği:

$$x'_i = \frac{x_i - \min(x)}{\text{maks}(x) - \min(x)} \quad (3.2)$$

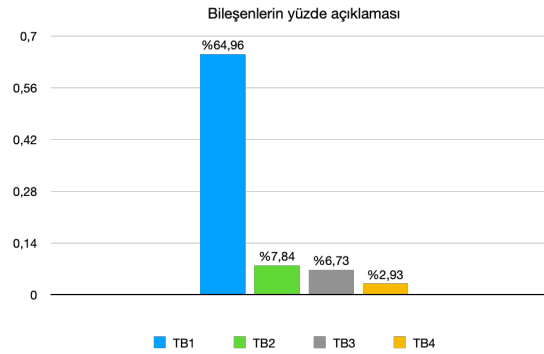
Burada x_i mevcut girdidir, $\min(x)$ ve $\text{maks}(x)$ x 'nin minimum ve maksimum değerleridir ve x'_i , mevcut x_i girdisine karşılık gelen normleştirilmiş değeridir.

3.5. BOYUTSAL KÜÇÜLTME

Bu çalışmada boyut indirgeme için TBA (Temel Bileşenler Analizi) algoritması kullanılmıştır. Doğrusal okuma yapan sensörler elenip öznelik seçimi yapıldıktan sonra orijinal verinin açıklanmasında düşük kayıpla yüksek varyans elde etmek için TBA algoritması uygulanmıştır. Orijinal veri setinin %80'ini açıklayan bileşenler seçilmiştir. Şekil 3.5 ve Şekil 3.6, FD001 veri kümesi ve çubuk gösterimi için her bir bileşen tarafından orijinal veri açıklamasının yüzdesini gösterir.

	Temel Bileşenleri	Yüzde
0	TB1	64.96
1	TB2	7.84
2	TB3	6.73
3	TB4	2.93

Şekil 3.5: Bileşenlerin yüzde açıklaması.



Şekil 3.6: Bileşenlerin çubuklarla temsili.

TBA algoritması diğer FD002, FD003 veri kümelerine de uygulanmıştır. Tablo 3.3, her veri kümesi için seçilen bileşenlerin sayısını göstermektedir.

Tablo 3.3:Her veri kümesinin seçili bileşenlerinin sayısı.

Veri kümesi	Seçili bileşenlerinin sayısı
FD001	4
FD002	15
FD003	4

3.6. KULLANILAN MODELLER

Bu çalışmada, KFÖ tahmini yapmak için dört yapay sinir ağı modeli kullanılmıştır. Tüm veri kümeleri, ön işleme uygulandıktan sonra her modele uygulanmıştır. Aşağıdaki tablo 3.4, sinir ağının modelini ve mimarisini içerir:

Tablo 3.4:Kullanılan Yapay Sinir Ağları modeli.

Model Türü	Gezli katmalarda kullanılan Aktivasyon fonksiyonu	Çıktılarda kullanılan Aktivasyon fonksiyonu
Çok Katmanlı Algılayıcı (ÇKA)	relu	Doğrusal
Evrişimsel Sinir Ağları (ESA)	relu	Doğrusal
Tekrarlayan Sinir Ağı (TSA)	relu	Doğrusal
Uzun kısa süreli bellek (UKSB)	relu	Doğrusal

Deneysel sonuçlar bir sonraki bölümde tartışılmaktadır.

4. TARTIŞMA VE SONUÇ

Bu bölümde deneysel sonuçlar tartışılmaktadır. Turbo fan motorunun kalan faydalı ömrünü (KFÖ) tahmin etmek için bir önceki bölümde açıklanan üç veri setine dört yapay sinir ağı modeli uygulanmıştır. Sinir ağının regresyon görevlerindeki performansını değerlendirmek için çeşitli yöntemler vardır. Bu çalışmada, model performansını değerlendirmek için Kök Ortalama Kare Hata (KOKH- Root Mean Square Error- RMSE), Ortalama Kare Hata (OKH- Mean Squared Error - MSE) ve Ortalama Mutlak Hata (OMH- Mean Absolute Error -MAE) kullanılmıştır.

4.1. PERFORMANS DEĞERLANDİRMESİ

Hiper-parametrelerin ayarlanması çok zordur, bu nedenle optimum parti boyutunu, gizli katman sayısını, aktivasyon fonksiyon tipini, en iyi öğrenme oranı değerini ve her bir katmandaki nöron sayısını ayarlamak için arama ızgarası tekniği kullanılmıştır. Öte yanda optimize edici ve kayıp fonksiyonu gibi diğer hiper-parametreler manuel olarak ayarlanmıştır. Ayrıca, model eğitim verilerine fazla uymaya başladığında eğitimi durdurmak için erken durdurma tekniği kullanılmıştır. Tablo 4.1 kullanılan hiper-parametrelerin değerlerini göstermektedir.

Tablo 4.1:Kullanılan hiper-parametrelerinin değerleri.


	Parti Boyu- tunu	Aktivasyon Fonksiyonu	Öğrenme oranı	Kayıp Fonk- siyonu	Optimize edici
FD001	16	Relu,linear	0.0001	OKH	ADAM
FD002	16	Relu,linear	0.001	OKH	ADAM
FD003	16	Relu,linaer	0.0001	OKH	ADAM

4.1.1. Birinci veri seti (FD001)

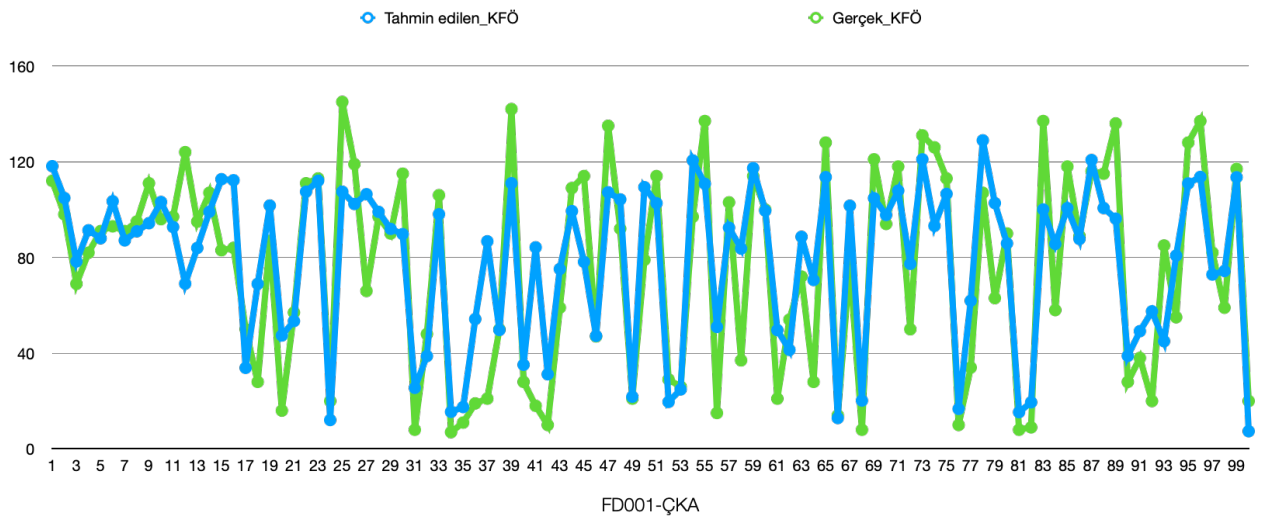
Bu veri seti için dört sinir ağı uygulanmış ve sonuçlarını karşılaştırılmıştır. Temel Bilişenler Analizi (TBA) kullanılarak 21 girdi kullanılmak yerine 80 % veri setini temsil eden sadece 4 girdiyi kullanarak aşağıda açıklanan sonuçlar elde edilmiştir.

4.1.1.1. Çok Katmanlı Algılayıcı (ÇKA)

Bu model, üç farklı veri seti ile beslenip sonuçlar her bir veri seti için ayrı şekilde tartışılmıştır. Bu veri setinde (FD001) model, 6 gizli katmana sahiptir ve her birinin ardından bırakma katmanı eklenmiştir. Şekil 4.1, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilmiş ve sonuç Tablo 4.2’de gösterilmiştir, ayrıca Şekil 4.2 test veri seti için tahmin edilen ve gerçek KFÖ’ü göstermektedir.



Şekil 4.1:FD001'de ÇKA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.2:ÇKA test seti için tahmini ve gerçek KFÖ.

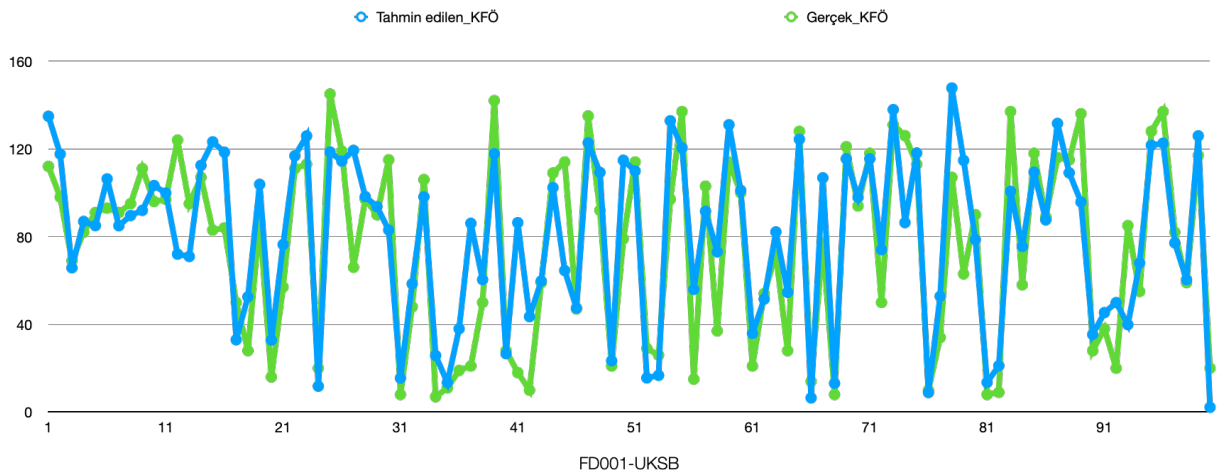
Modelin performansı değerlendirilirken, OKH 522.69, OMH 17.60, KOKH ise 22.86 olarak elde edilmiştir.

4.1.1.2. Uzun kısa süreli bellek (UKSB)

Model, 2 UKSB katmanı ve 2 yoğun şekilde bağlı katman ile oluşturulmuştur. Her UKSB katmanından sonra bir bırakma katmanı vardır. Şekil 4.3, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilmiş ve sonuç Tablo 4.2'da gösterilmiştir. Ayrıca Şekil 4.4, test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.3:FD001'de UKSB için eğitim aşamasındaki eğitim ve doğrulama kayıpları.

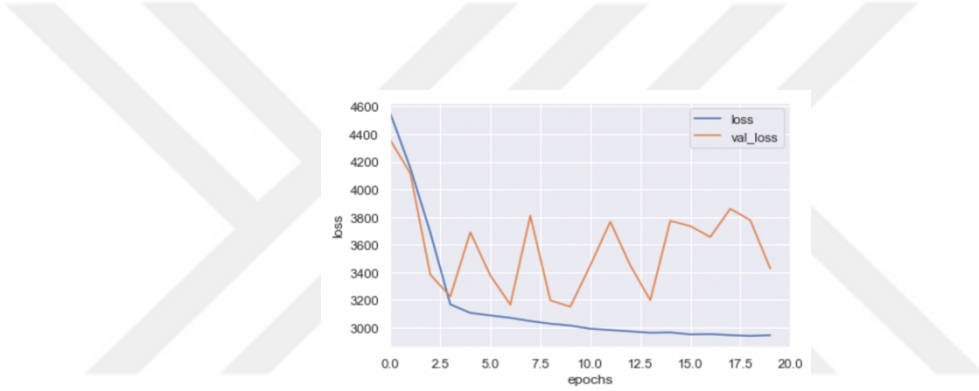


Şekil 4.4:UKSB test seti için tahmini ve gerçek KFÖ.


İlk veri setinde (FD001) UKSB için performans değerlendirmesi hesaplanmıştır ve sonuç olarak OKH 523.59, OMH 17.00 ve KOKH 22.88 olarak bulunmuştur.

4.1.1.3. Evrişimsel Sinir Ağları (ESA)

Bu model evrişimsel sinir ağı, 2 evrişim katmanı ve yoğun şekilde bağlı 2 katmandan oluşturulmuştur. Her katmandan sonra bir bırakma katmanı vardır. Şekil 4.5, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilip sonuç Tablo 4.2’de gösterilmiştir. Ayrıca Şekil 4.6, test veri seti için tahmin edilen ve gerçek KFÖ’ü göstermektedir.



Şekil 4.5:FD001'de ESA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.6:ESA test seti için tahmini ve gerçek KFÖ.


Bu model için OKH 558.65, KOKH 23.63 ve OMH 18.34 olarak elde edilmiştir.

4.1.1.4. Tekrarlayan Sinir Ağı (TSA)

Bu model 2 TSA katmanı ve yoğun şekilde bağlı bir katmandan oluşturulmuştur ve diğer modeller gibi bırakma katmanları vardır. Şekil 4.7 eğitim aşamasındaki eğitim ve doğrulama kayıplarını göstermektedir. Test aşamasında model değerlendirilip sonuç Tablo 4.2’de gösterilmiştir. Ayrıca Şekil 4.8 test veri seti için tahmin edilen ve gerçek KFÖ’ü göstermektedir.



Şekil 4.7:FD001'de TSA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.8:TSA test seti için tahmini ve gerçek KFÖ.

Sonuç olarak model performansına bakıldığında OKH 703.45, KOKH 26.52 ve OMH 20.30 olarak bulunmuştur.

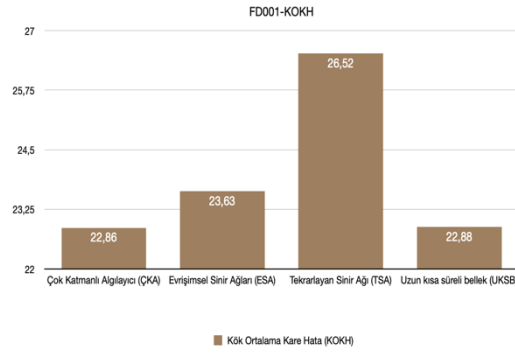
21 sensör ölçümü içeren uçak motorunun kalan faydalı ömrünü (KFÖ) tahmin etmek için tüm modellerde sadece 4 girdi kullanıldığını belirtmek çok önemlidir. Tablo 4.2. ilk veri seti için sinir ağı modellerinin OKH, KOKH ve OMH değerlerini göstermektedir. Grafik seti (4.9,4.10,4.11) ise, ilk veri setindeki tüm sinir ağıları performansı için OKH, KOKH ve OMH karşılaştırmasını içermektedir.

Tablo 4.2:İlk veri kümesi (FD001) için tüm modellerin OKH, KOKH ve OMH değerleri.

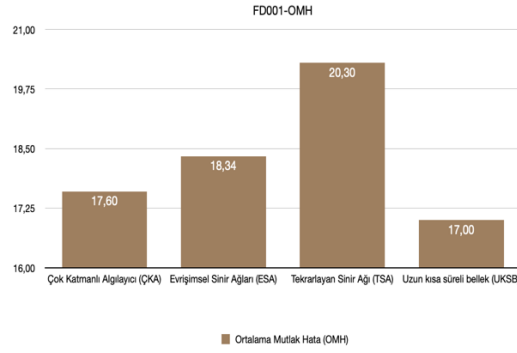
	OKH	KOKH	OMH
Çok Katmanlı Algılayıcı (ÇKA)	522.69	22.86	17.60
Evrişimsel Sinir Ağları (ESA)	558.65	23.63	18.34
Tekrarlayan Sinir Ağı (TSA)	703.45	26.52	20.30
Uzun kısa süreli bellek (UKSB)	523.59	22.88	17.00



Şekil 4.9:FD001 için modellerin OKH değerleri.



Şekil 4.10:FD001 için modellerin KOKH değerleri.




Şekil 4.11:FD001 için modellerin OMH değerleri.

4.1.2. İkinci veri seti (FD002)


Bu veri seti için dört sinir ağı uygulanmış ve sonuçlarını karşılaştırılmıştır. Temel Bilişenler Analizi (TBA) kullanılarak 21 girdi kullanılmak yerine 15 girdiyi kullanarak aşağıda açıklanan sonuçlar elde edilmiştir.

4.1.2.1. Çok Katmanlı Algılayıcı (ÇKA)

Bu veri setinde (FD002) model, 2 gizli katmana sahip ve her birinin ardından bırakma katmanı eklenmiştir. Şekil 4.12, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilmiş ve sonuç Tablo 4.3'te gösterilmiştir, ayrıca Şekil 4.13 test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.12:FD002'de ÇKA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.13:ÇKA test seti için tahmini ve gerçek KFÖ.


Modelin performansını değerlendirilmiştir, buna göre OKH 1538.73'e, OMH 31.32'ye, KOKH 39.22'ye eşittir.

4.1.2.2. Evrimsel Sinir Ağları (ESA)

Bu model evrimsel sinir ağı, 4 evrişim katmanı ve yoğun şekilde bağlı 2 katmandan oluşturulmuştur. Her katmandan sonra bir bırakma katmanı vardır. Şekil 4.14, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilip sonuç Tablo 4.3'te gösterilmiştir. Ayrıca Şekil 14.15, test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.14:FD002'de ESA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.15:ESA test seti için tahmini ve gerçek KFÖ.


Bu model için OKH 1623.95, KOKH 40.30 ve OMH 30.69 olarak hesaplanmıştır.

4.1.2.3. *Tekrarlayan Sinir Ağı (TSA)*

Bu model 2 TSA katmanı ve yoğun şekilde bağlı bir katmandan oluşturulmuştur ve diğer modeller gibi bırakma katmanları vardır. Şekil 4.16 eğitim aşamasındaki eğitim ve doğrulama kayıplarını göstermektedir. Test aşamasında model değerlendirilip sonuç Tablo 4.3'te gösterilmiştir. Ayrıca Şekil 14.17s test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.16:FD002'de TSA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.17:TSA test seti için tahmini ve gerçek KFÖ.


Sonuç olarak, model performansında OKH 1428.99, KOKH 37.80 ve OMH 30.16 olarak hesaplanmıştır.

4.1.2.4. Uzun kısa süreli bellek (UKSB)

Model, 3 UKSB katmanı ve bir yoğun şekilde bağlı katmandan oluşturulmuştur. Her UKSB katmanından sonra bir bırakma katmanı vardır. Şekil 14.18, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilmiş ve sonuç Tablo 4.3'te gösterilmiştir. Ayrıca Şekil 14.19 test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.18:FD002'de UKSB, için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.19:UKSB test seti için tahmini ve gerçek KFÖ.

İkinci veri setinde (FD002) UKSB için performans değerlendirmesi yapılmıştır, buna göre; OKH 1305.48, OMH 27.50 ve KOKH 36.13'dir.

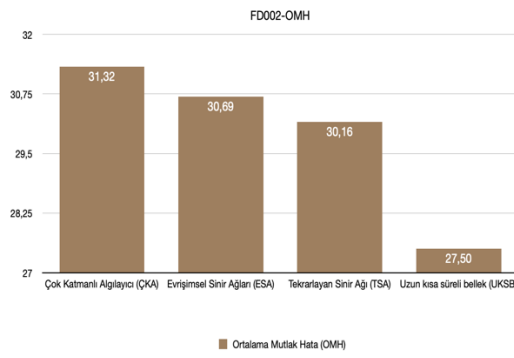
21 sensör ölçümü içeren olan uçak motorunun kalan faydalı ömrünü (KFÖ) tahmin etmek için tüm modellerde 15 girdi kullanılmıştır. Tablo 4.3. ikinci veri seti için sinir ağı modellerinin OKH, KOKH ve OMH değerlerini gösterir. Grafik seti (4.20,4.21,4.22) ise, ikinci veri setindeki tüm sinir ağıları performansı için OKH, KOKH ve OMH karşılaştırmasını içermektedir.

Tablo 4.3:İkinci veri kümesi (FD002) için tüm modellerin OKH, KOKH ve OMH değerleri.


	OKH	KOKH	OMH
Çok Katmanlı Algılayıcı (ÇKA)	1538.73	39.22	31.32
Evrişimsel Sinir Ağları (ESA)	1623.95	40.30	30.16
Tekrarlayan Sinir Ağı (TSA)	1428.99	37.80	30.16
Uzun kısa süreli bellek (UKSB)	1305.48	36.13	27.50



Şekil 4.20:FD002 için modellerin OKH değerleri.



Şekil 4.21:FD002 için modellerin OMH değerleri.




Şekil 4.22:FD002 için modellerin KOKH değerleri.

4.1.3. Üçüncü veri seti (FD003)

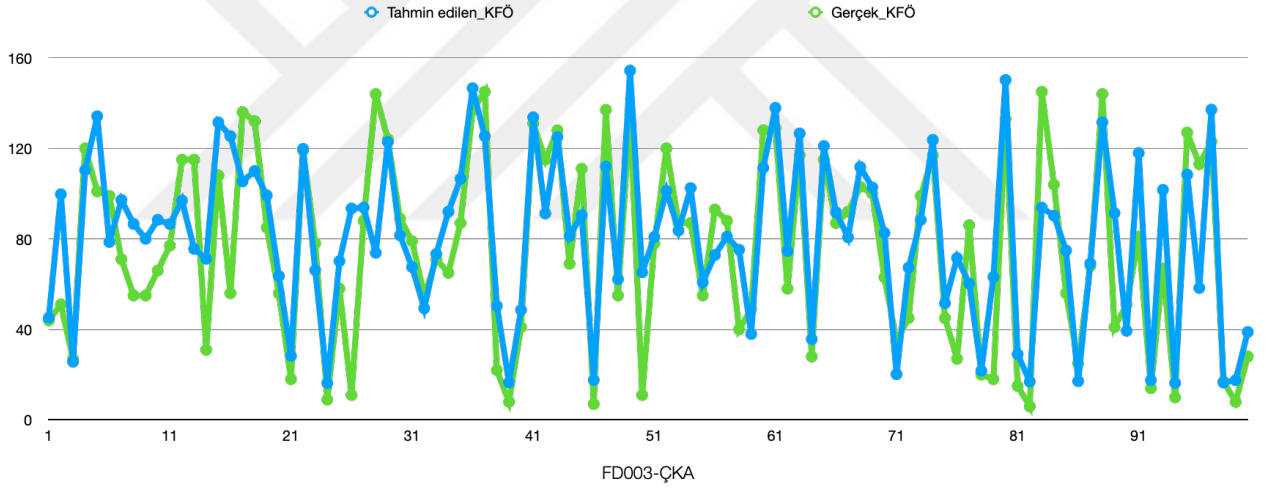
Bu veri seti için dört sinir ağı uygulanmış ve sonuçları karşılaştırılmıştır. Temel Bilişenler Analizi (TBA) kullanılarak 21 girdi kullanılmaktansa 4 girdiyi kullanarak aşağıda açıklanan sonuçlar elde edilmiştir.

4.1.3.1. Çok Katmanlı Algılayıcı (ÇKA)

Bu veri setinde (FD002) model, 2 gizli katmana sahiptir ve her birinin ardından bırakma katmanı eklenmiştir. Şekil 4.23, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilmiş ve sonuç Tablo 4.4'te gösterilmiştir, ayrıca Şekil 4.25 test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.23:FD003'de ÇKA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.24:ÇKA test seti için tahmini ve gerçek KFÖ.

Modelin performansı değerlendirilmiş, OKH 601.84, OMH 18.31, KOKH 24.53 olarak elde edilmiştir.

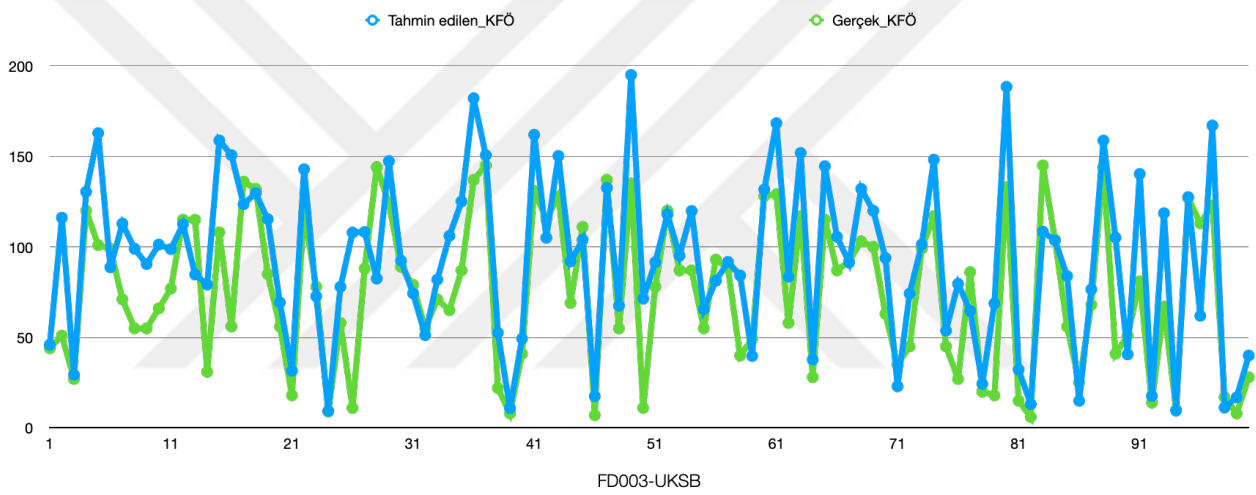
4.1.3.2. Uzun kısa süreli bellek (UKSB)

Model, 2 UKSB katmanı ve bir yoğun şekilde bağlı katmandan oluşturulmuştur. Her UKSB katmanından sonra bir bırakma katmanı vardır. Şekil 4.25, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilmiş ve sonuç Tablo 4.4'te

gösterilmiştir. Ayrıca Şekil 4.26 test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.25:FD003'de UKSB, için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.26:UKSB test seti için tahmini ve gerçek KFÖ.


İkinci veri setinde (FD002) UKSB için performans değerlendirmesi yapılmıştır; sonuç olarak OKH 1019.22, OMH 23.95 ve KOKH 31.93'dir.

4.1.3.3. Tekrarlayan Sinir Ağı (TSA)

Bu model, 2 TSA katmanı ve yoğun şekilde bağlı bir katmandan oluşturulmuştur ve diğer modeller gibi bırakma katmanları vardır. Şekil 4.27 eğitim aşamasındaki eğitim ve doğrulama kayıplarını göstermektedir. Test aşamasında model değerlendirilip sonuç Tablo 4.4'te gösterilmiştir. Ayrıca Şekil 4.28 test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.27:FD003'de TSA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.28:TSA test seti için tahmini ve gerçek KFÖ.


Sonuç olarak model performansı OKH 833.87, KOKH 28.87, OMH 21.86 olarak gerçekleşmiştir.

4.1.3.4. Evrimsel Sinir Ağları (ESA)

Bu model evrimsel sinir ağı, 3 evrişim katmanı ve yoğun şekilde bağlı 2 katmandan oluşturulmuştur. Her katmandan sonra bir bırakma katmanı vardır. Şekil 4.29, eğitim aşamasındaki eğitim ve doğrulama kayıplarını gösterir. Test aşamasında model değerlendirilip sonuç Tablo 4.4'te gösterilmiştir. Ayrıca Şekil 4.30, test veri seti için tahmin edilen ve gerçek KFÖ'ü göstermektedir.



Şekil 4.29:FD003'de ESA için eğitim aşamasındaki eğitim ve doğrulama kayıpları.




Şekil 4.30:ESA test seti için tahmini ve gerçek KFÖ.

Bu model için OKH 1083.65, KOKH 32.92 ve OMH 24.72 olarak elde edilmiştir.


21 sensör ölçümü içeren uçak motorunun kalan faydalı ömrünü (KFÖ) tahmin etmek için tüm modellerde 4 girdi kullanılmıştır. Tablo 4.4. üçüncü veri seti için sinir ağı modellerinin OKH, KOKH ve OMH değerlerini gösterir. Grafik seti (4.31,4.32,4.33) ise, üçüncü veri setindeki tüm sinir ağları performansı için OKH, KOKH ve OMH karşılaştırmasını içermektedir.

Tablo 4.4:Üçüncü veri kümesi (FD002) için tüm modellerin OKH, KOKH ve OMH değerleri.


	OKH	KOKH	OMH
Çok Katmanlı Algılayıcı (ÇKA)	601.84	24.53	18.31
Evrişimsel Sinir Ağları (ESA)	1083.65	32.92	24.72
Tekrarlayan Sinir Ağı (TSA)	833.87	28.87	21.86
Uzun kısa süreli bellek (UKSB)	1019.22	31.93	23.95



Şekil 4.31:FD003 için modellerin OKH değerleri.



Şekil 4.32:FD003 için modellerin OMH değerleri.




Şekil 4.33:FD003 için modellerin KOKH değerleri.

Tablo 4.5, üç veri kümesi üzerindeki tüm modellerin KOKH değerlerini gösterir, tabloya göre ÇKA tüm modeller üzerinde en iyi ortalamaya sahiptir, ayrıca şekil 4.34 KOKH grafiklerini göstermektedir.

Tablo 4.5:KOKH değerleri.

	FD001	FD002	FD003	Ortalama
Çok Katmanlı Algılayıcı (ÇKA)	22.86	39.22	24.53	28.87
Evrişimsel Sinir Ağları (ESA)	23.63	40.30	32.92	32.28
Tekrarlayan Sinir Ağı (TSA)	26.52	37.80	28.87	31.06
Uzun kısa süreli bellek (UKSB)	22.88	36.13	31.93	30.31




Şekil 4.34:KOKH grafikleri.

4.2. LİTERATÜRLE KARŞILAŞTIRMA:

[4]'deki yazarlar, derin öğrenme kullandıklarında ilk veri setinde KOKH 29.62'ye eşittir. Ancak yazarlar 10 farklı makine öğrenme algoritması kullanmışlardır ve en iyi sonuca KOKH'nin 24.95'e eşit olduğu rastgele orman algoritmasıyla ulaşmışlardır. Bu çalışmada önerilen yaklaşım 21 girdiden sadece 4'ünü kullanmasına rağmen en kötü model için 26.52, en iyi model için ise KOKH 22.86'ya eşit. Öte yandan, daha az girdi sayısı nedeniyle eğitim ve test aşamaları, 21 girdi kullanan modele kıyasla artık daha kısa zamanda gerçekleştirilmektedir. Tablo 4.6, önerilen yaklaşımın ve literatürde var olan çalışma için KOKH değerlerini göstermektedir. Ayrıca Şekil 4.35 önerilen metod, literatür ile KOKH grafiklerinin karşılaştırmasını göstermektedir.

Tablo 4.6:Önerilen metot ile literatür karşılaştırması.

	FD001	FD002	FD003	Ortalama
Derin Öğrenme [4]	29.62	42.41	46.82	39.62
Rastgele Orman [4]	24.95	29.64	30.55	28.38
Önerilen Metot	22.86	39.22	24.53	28.87



Şekil 4.35:Önerilen metot, literatüre [4] ile KOKH grafiklerinin karşılaştırması.

5. SONUÇ VE ÖNERİLEN

5.1. SONUÇ:

Bu çalışmada, turbo fan motorunun Faydalı Kalan Ömrünü (FKÖ) tahmin etmek için temel bileşen analizi (TBA) algoritmasıyla yapay sinir ağı yöntemi önerilmiştir. Önerilen yöntem, bir sonraki başarısızlıktan önce Faydalı Kalan Ömrün (FKÖ) tahmin edildiği bir regresyon yaklaşımıdır. Bu çalışmada NASA veri deposundan alınan üç uçak motoru Bozulma Simülasyon Veri Kümesi kullanılmıştır. Bu çalışmanın temel amacı, TBA algoritmasıyla yapay sinir ağı kullanılarak, motor arızası öncesi bakımın tamir edilmesi ve aynı zamanda giriş sayısının azaltılması için turbo fan motorunun faydalı kalan ömrü yüksek doğrulukla tahmin edebilecek bir yöntem önermektir.

İlk olarak veriler, eğitim veri kümesi için hiçbir etiketi olmayan denetimli öğrenmeye uygun olması amacıyla önceden işlenmiştir. Özelliklerin ölçeği birbirinden farklıdır ve bu da modellerimizde yanılığa neden olabilir. Bu nedenle, özelliği [0-1] aralığına yeniden ölçeklendirmek için Minimum-Maksimum dönüşüm yöntemi uygulanmıştır. Ayrıca verilerin boyutsallığını azaltmak için TBA algoritması uygulanmaktadır. TBA algoritmasının çıktısı, yapay sinir ağları modellerine uygun olacak şekilde işlenmiştir.

OMH, OKH ve KOKH, her veri kümesi için model performansını değerlendirmek için kullanılmıştır. Her bir veri setindeki modellerin performansına göre çok katmanlı algılayıcı (ÇKA) olan en iyi model seçilmiştir. [4] İle karşılaştırıldığında, önerilen modelimiz birinci ve üçüncü veri kümesinde [4]'de önerilen yöntemden daha iyi doğruluk sunmaktadır. Bu çalışmada önerilen yöntemde literatürde [4] önerilen yöntemden daha az girdi kullanılmasına rağmen, yöntemimizden sadece %0.98 daha iyidir. Öte yandan, daha az girdi kullanımı, daha hızlı eğitim ve test süresi anlamına gelmektedir.

5.2. ÖNERİLEN:

Özellikle uçak turbo fan motor verileri gibi veriler çok büyük ve hassas olduğunda modelin performansını artırabilecek birçok farklı veri ön işleme tekniği vardır. Ayrıca bazı sensörlerin ölçümlerinde motor arızası hakkında hiçbir bilgisi olmayan ve düz bir çizgi gösteren bazı sensörler vardır. Bu nedenle özellikleri seçme tekniğinin kullanılması tahmin güvenilirliğini artırabilir.

Gelecekteki çalışmalar, bazı hiperparametreleri belirlemek için ızgara arama tekniğini kullanıp hiperparametre ayarlama için çözümler bulmayı içerebilir. Hiperparametreler birbirini etkilediğinden, manuel olarak ayarlanan hiperparametreler, ızgara arama tekniği kullanılarak ayarlanan diğerlerini etkileyebilir. Onunla birlikte ızgara arama yöntemi, zaman ve kaynak tüketimidir. Bu çalışmada TBA algoritmasıyla denetimli öğrenme yöntemi önerilmiş olup, TBA algoritmasıyla yarı denetimli öğrenme yönteminin kullanılması tahmin doğruluğunu iyileştirebilir. Son olarak, aynı veri seti üzerinde uygulanabilecek ve çalışmamızla karşılaştırılabilecek çeşitli farklı boyut indirgeme teknikleri vardır.

KAYNAKÇA

- [1] Z. Li and Q. He, "Prediction of railcar remaining useful life by multiple data source fusion," *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 4, pp. 2226-2235, 2015.
- [2] Nieto, P. G., García-Gonzalo, E., Lasheras, F. S., & de Cos Juez, F. J. (2015). Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability. *Reliability Engineering & System Safety*, 138.
- [3] Yuan, M., Wu, Y., & Lin, L. (2016, October). Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. In *2016 IEEE international conference on aircraft utility systems (AUS)* (pp. 135-140). IEEE.
- [4] Mathew, V., Toby, T., Singh, V., Rao, B. M., & Kumar, M. G. (2017, December). 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».
- [5] Ma, J., Su, H., Zhao, W. L., & Liu, B. (2018). Predicting the remaining useful life of an aircraft engine using a stacked sparse autoencoder with multilayer self-learning. *Complexity*, 2018.
- [6] Ellefsen, A. L., Bjørlykhaug, E., Æsøy, V., Ushakov, S., & Zhang, H. (2019). Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture. *Reliability Engineering & System Safety*, 183, 240-251.
- [7] Fornlöf, V. (2016). Improved remaining useful life estimations for on-condition parts in aircraft engines (Doctoral dissertation, University of Skövde).
- [8] Mobley, R. K. (2002). *An introduction to predictive maintenance*. Elsevier.
- [9] Çınar, Z. M., Abdussalam Nuhu, A., Zeeshan, Q., Korhan, O., Asmael, M., & Safaei, B. (2020). Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. *Sustainability*, 12(19).
- [10] M. Canizo, E. Onievay, A. Condez, S. Charramendietax and S. Trujillo "Real-time predictive maintenance for wind turbines using big data frameworks," in *IEEE International Conference on Prognostics and Health Management (ICPHM)*, 2017.
- [11] G. A. Susto, A. Schirru, S. Pampuri, S. McLoone, A. Beghi and G. A. Susto, "Machine learning for predictive maintenance: A multiple classifier approach," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 3, pp. 812-820, 2015.
- [12] Yang, C., Chen, Q., Yang, Y., & Jiang, N. (2016, May). Developing predictive models for time to failure estimation. In *2016 IEEE 20th International Conference on Computer*

Supported Cooperative Work in Design (CSCWD) (pp. 133-138). IEEE.

- [13] Costello, J. J., West, G. M., & McArthur, S. D. (2017). Machine learning model for event-based prognostics in gas circulator condition monitoring. *IEEE Transactions on Reliability*, 66(4), 1048-1057.
- [14] Jezzini, A., Ayache, M., Elkhansa, L., Makki, B., & Zein, M. (2013, September). Effects of predictive maintenance (PdM), Proactive maintenance (PoM) & Preventive maintenance (PM) on minimizing the faults in medical instruments. In 2013 2nd International co.
- [15] Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- [16] Kumar, A., Chinnam, R. B., & Tseng, F. (2019). An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools. *Computers & Industrial Engineering*, 128, 1008.
- [17] Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- [18] Moyne, J., Samantaray, J., & Armacost, M. (2016). Big data capabilities applied to semiconductor manufacturing advanced process control. *IEEE transactions on semiconductor manufacturing*, 29(4), 283-291.
- [19] Baştanlar, Y., & Özuysal, M. (2014). Introduction to machine learning. *miRNomics: MicroRNA Biology and Computational Analysis*, 105-128.
- [20] Yan, J., Jiang, Y., Zheng, F., Yu, F. R., Gao, X., & You, X. (2020, June). Distributed edge caching with content recommendation in Fog-RANs via deep reinforcement learning. In 2020 IEEE International Conference on Communications Workshops (ICC Workshops).
- [21] Ziegler, M. Object Recognition with Convolutional Neural Networks.
- [22] Özkan, Y., Koçoğlu, F. Ö., & Erol, Ç. S. (2018). Prediction of Student Performance By Deep Learning Algorithm Öğrenci Performansının Yapay Zeka Derin Öğrenme Algoritması Ile Öngörülmesi. PREFACE OF THE EDITORS, 136.
- [23] Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- [24] Fausett, L. V. (2006). *Fundamentals of neural networks: architectures, algorithms and applications*. Pearson Education India.
- [25] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.

- [26] Paya, B. A., Esat, I. I., & Badi, M. N. M. (1997). Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. *Mechanical systems and signal processing*, 11(5), 751-765.
- [27] Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- [28] Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202.
- [29] Saxena, A., Goebel, K., Simon, D., & Eklund, N. (2008, October). Damage propagation modeling for aircraft engine run-to-failure simulation. In *2008 international conference on prognostics and health management* (pp. 1-9). IEEE.
- [30] Aydin, O., & Guldamlasioglu, S. (2017, April). Using LSTM networks to predict engine condition on large scale data processing framework. In *2017 4th International Conference on Electrical and Electronic Engineering (ICEEE)* (pp. 281-285). IEEE.