

KESTİRİMCİ BAKIM YAKLAŞIMIYLA BİR TURBOFAN MOTORUNUN ÇÖZÜMLENMESİ

ANALYSIS OF A TURBOFAN ENGINE VIA PREDICTIVE MAINTENANCE APPROACH

Gözde GÜNGÖR KANKAYA

Dr. Öğr. Üyesi Yakup Sabri ÖZKAZANÇ

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2022

ÖZET

ANALYSIS OF A TURBOFAN ENGINE VIA PREDICTIVE MAINTENANCE APPROACH

Gözde GÜNGÖR KANKAYA

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği
Danışman: Dr. Öğr. Üyesi Yakup Sabri ÖZKAZANÇ
Ocak 2022, 67 sayfa

Kestirimci bakım, sistemdeki sensörlerden toplanan fiziksel verilerin bir yazılım aracılığıyla işlenip değerlendirilmesinin ardından planlanan ve arızadan hemen önce gerçekleştirilen bakımdır. Beklenmedik arızaların sebep olduğu plansız duruş sürelerini kısaltmak ve verimliliği arttırmak için başvurulmuş kestirimci bakım yaklaşımı sayesinde üretimdeki kayıplar ve makinanın atıl kalma süresi azalır. Bu yöntem, zamana göre değil duruma göre uygulanan bir bakım yöntemi olduğu için yalnızca gerekli görüldüğü durumlarda uygulanması ile gereksiz bakım maliyetlerinin de önüne geçilmiş olur.

Bu çalışma, uçak motorlarının arıza meydana gelmeden önce bakıma alınmasını sağlamak, arızalardan dolayı ortaya çıkan bakım/onarım/parça değişiminin sebep olduğu büyük maddi kayıplara ve özellikle can kayıplarına engel olmak amacıyla uçak motorlarının arıza meydana getirmesine kadar kalan faydalı ömürlerini tahmin etmeyi amaçlar.

Bu çalışmada, 2008 yılında Uluslararası Prognostik ve Sağlık Yönetimi Konferansı'nda düzenlenen yarışma verileri kullanılmıştır. Eğitim setindeki turbofan motorlarından alınan

veriler kullanılarak makina öğrenmesi modelleri eğitilmiş, bu modeller kullanılarak doğrulama setinde bulunan motorların kalan faydalı ömürleri tahmin edilmiş ve modellerin performansları karşılaştırılmıştır.

Anahtar Kelimeler: Kestirimci Bakım, Kalan Faydalı Ömür, Makina Öğrenmesi



ABSTRACT

KESTİRİMCİ BAKIM YAKLAŞIMIYLA BİR TURBOFAN MOTORUNUN ÇÖZÜMLENMESİ

Gözde GÜNGÖR KANKAYA

Master of Science, Department of Electrical and Electronics Engineering

Supervisor: Assist. Prof. Dr. Yakup Sabri ÖZKAZANÇ

January 2022, 67 pages

The predictive maintenance is a maintenance method that is performed immediately before the malfunction and sufficient amount of maintenance as a result of the evaluation of physical data collected from the sensors in the system through a software. Thanks to the referenced predictive maintenance approach in order to increase efficiency and shorten the unplanned stop times caused by unexpected malfunctions, the losses in production and the duration of the inactivity of the machine decreases. This method prevents the implementation of unnecessary maintenance costs by implementing only in cases where necessary because it is a condition-based method not time-based method.

This study aims to estimate the remaining useful life of aircraft engines until they fail, in order to ensure that aircraft engines are taken into maintenance before the failure occurs, to prevent great financial losses and especially loss of life caused by maintenance / repair / replacement of parts due to failures.

In this study, the competition data organized in the International Prognostic and Health Management Conference in 2008 were used. Using the data from the turbofan engines in the training set, machine learning models are trained, using these models, the remaining useful life of the motors in the validation set were estimated and the performance of the predictive models were compared.

Keywords: Predictive Maintenance, Remaining Useful Life, Machine Learning



TEŞEKKÜR

Tez çalışmam boyunca değerli katkıları ve eleştirileriyle yol gösteren danışman hocam Dr. Öğr. Üyesi Yakup Sabri ÖZKAZANÇ'a saygı ve teşekkürlerimi sunarım.

Hayatım boyunca bugünlere gelmemde büyük pay sahibi olan ve haklarını hiçbir zaman ödeyemeyeceğim canım annem Canan GÜNGÖR, babam Necati GÜNGÖR, kardeşlerim Gizem GÜNGÖR ve Utku GÜNGÖR'e teşekkürü borç bilirim.

Son olarak, hayatımın her alanında olduğu gibi tez çalışmam sırasında da benden desteklerini esirgemeyen sevgili eşim Nazmi KANKAYA'ya sonsuz teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ.....	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	4
2.1. Bakım Türleri.....	4
2.1.1. Reaktif Bakım	4
2.1.2. Önleyici Bakım.....	5
2.1.3. Kestirimci Bakım.....	5
2.2. Kalan Faydalı Ömür.....	7
2.3. Makine Öğrenmesi.....	9
2.3.1. Denetimli Öğrenme	10
2.3.2. Denetimsiz Öğrenme.....	11
2.3.3. Pekiştirmeli Öğrenme	13
3. REGRESYON YÖNTEMLERİ	14
3.1. Doğrusal Regresyon.....	14
3.2. Regresyon Ağaçları.....	15
3.3. Birleştirilmiş Karar Ağaçları.....	16
3.4. Sinir Ağları.....	17
3.5. Gauss Süreç Regresyonu.....	19
3.6. Destek Vektör Regresyon Makinesi.....	20
4. TURBOFAN MOTORUN KALAN FAYDALI ÖMRÜNÜN KESTİRİMİ	23
4.1. Veri Kümesi Tanımı	23

4.2. Veri Ön İşleme	25
4.2.1. Veri Etiketleme	26
4.2.2. Çalışma Profillerinin Belirlenmesi	26
4.2.3. Veri Temizleme	30
4.2.4. Veri Standardizasyonu	31
4.3. Veri Kümesini Bölme	35
4.4. Temel Bileşen Analizi	36
4.5. Regresyon	37
5. SONUÇLAR	51
KAYNAKLAR	59
TEZ ÇALIŞMASI ORJİNALLİK RAPORU	68
ÖZGEÇMİŞ	69

ŞEKİLLER DİZİNİ

Şekil 2.1.	Öngörücü bakım stratejisi, ekipman arızalarını önlemek için erken uyarı yapmaya yarar [1].	6
Şekil 2.2.	Denetimli öğrenme akış şeması [2]	11
Şekil 2.3.	Denetimsiz öğrenme akış şeması [3]	12
Şekil 2.4.	Pekiştirmeli öğrenme akış şeması [4]	13
Şekil 3.1.	Doğrusal Regresyon Grafiği [5]	14
Şekil 3.2.	Regresyon Ağacı Akış Şeması [6]	16
Şekil 3.3.	Birleştirilmiş Karar Ağacı Akış Şeması [7]	17
Şekil 3.4.	Sinir Ağının Matematiksel Modeli [8]	18
Şekil 3.5.	Gauss Süreç Regresyonu Grafiği [9]	20
Şekil 3.6.	Destek Vektör Makinesinin Regresyon ve Sınıflandırma Problemlerinde Çalışma Yöntemi [10]	21
Şekil 3.7.	Doğrusal ve Doğrusal Olmayan Destek Vektör Regresyonunun Çalışma Yöntemi [10]	22
Şekil 4.1.	Simüle Edilen Turbofan Motorun Basitleştirilmiş Diyagramı [11]	25
Şekil 4.2.	Çalışma Koşulları	27
Şekil 4.3.	Sensör Değerleri	28
Şekil 4.4.	Operasyonel Ayarların Sensörler Üzerindeki Etkisi	29
Şekil 4.5.	Veri Kümesindeki Birimlerin Ömür İstatistiği	31
Şekil 4.6.	Standardizasyon öncesi ham verideki s2, s3, s20 ve s21 sensör ölçümleri	32
Şekil 4.7.	Standardizasyon sonrası verideki s2, s3, s20 ve s21 sensör ölçümleri	33
Şekil 4.8.	Standardize Edilen Sensör Ölçümleri	34
Şekil 4.9.	Her Bir Temel Bileşenin Açıkladığı Varyans Oranı	36
Şekil 4.10.	Temel Bileşenlerin Kümülatif Olarak Açıkladığı Varyans Oranı	37

ÇİZELGELER DİZİNİ

Tablo 2.1.	Bakım yöntemlerinin kısaca karşılaştırması	7
Tablo 4.1.	Veri Kümesi Parametreleri	24
Tablo 4.2.	Sensörlerin Aldığı Değerler	27
Tablo 4.3.	Belirli Çalışma Koşulları Altında Sensör Verilerindeki Belirsizlik Oranı.	35
Tablo 4.4.	Kullanılan Makina Öğrenmesi Modelleri.....	38
Tablo 4.5.	Eğitim İstatistikleri	40
Tablo 4.6.	Eğitim Setindeki Motorlar İçin Kalan Faydalı Ömür Tahminleri	41
Tablo 4.7.	Eğitim Setindeki Motorlar İçin Kalan Faydalı Ömür Tahminleri	42
Tablo 4.8.	Gerçek Kalan Faydalı Ömürler İle Tahmini Kalan Faydalı Ömürler Arasındaki İlişki	43
Tablo 4.9.	Gerçek Kalan Faydalı Ömürler İle Tahmini Kalan Faydalı Ömürler Arasındaki İlişki	44
Tablo 4.10.	Kestirim Hatası	45
Tablo 4.11.	Kestirim Hatası	46
Tablo 4.12.	Doğrulama Setindeki 199 Numaralı Motor İçin Tahmin Edilen RUL İle Gerçek RUL Grafikleri	48
Tablo 4.13.	Doğrulama Setindeki 199 Numaralı Motor İçin Tahmin Edilen RUL İle Gerçek RUL Grafikleri	49
Tablo 4.14.	Doğrulama Setindeki 199 Numaralı Motor İçin Tahmin Edilen RUL İle Gerçek RUL Grafikleri	50
Tablo 5.1.	Hata Tablosu	53
Tablo 5.2.	Deste Kestirim Tutarlılığı Tablosu	54

SİMGELER VE KISALTMALAR

Simgeler

ε	epsilon
ft	feet
M	mach
$^{\circ}F$	Fahrenhayt
$^{\circ}R$	Rankine
lbm/s	Pound Mass Per Second
pps/psi	Pound Per Second / Pounds Per Square Inch
psia	Pounds Per Square Inch Absolute
rpm	Revolutions Per Minute

Kısaltmalar

C-MAPSS	Commercial Modular Aero-Propulsion System Simulation
CNN	Convolutional Neural Network
DR	Doğrusal Regresyon
DVM	Destek Vektör Makinesi
DVR	Destek Vektör Regresyonu
GPR	Gaussian Process Regression
GPU	Graphics Processing Unit
GSR	Gauss Süreç Regresyonu
LSTM	Long Short Term Memory
MAE	Mean Absolute Error
PHM	Prognostics and Health Management
RMSE	Root Mean Square Error
RNN	Recurrent Neural Network
RUL	Remaining Useful Life
SA	Sinir Ağı

SD	S tandard D eviation
SVM	S upport V ector M achines
SVR	S upport V ector R egression
TPU	T ensor P rocessing U nit
WB	W eibull D istribution



TÜRKÇE - İNGİLİZCE TERİMLER SÖZLÜĞÜ

Aşırı Uyumlanma	: Overfitting
Birleştirilmiş Karar Ağaçları	: Ensemble of Trees
Dar Sinir Ağı	: Narrow Neural Network
Destek Vektör Makinesi	: Support Vector Machine
Destek Vektör Regresyonu	: Support Vector Regression
Doğrusal Destek Vektör Makinesi	: Linear SVM
Doğrusal Regresyon	: Linear Regression
Evrişimsel Sinir Ağı	: Convolutional Neural Network
Etkileşimli Doğrusal Regresyon	: Interactions Linear Regression
Güçlendirilmiş Ağaçlar	: Boosted Trees
Gauss Süreç Regresyonu	: Gaussian Process Regression
Geniş Sinir Ağı	: Wide Neural Network
Gradyan İnişi	: Gradient Descent
Grafik İşleme Birimi	: Graphics Processing Unit
Gürbüz Doğrusal Regresyon	: Robust Linear Regression
Hassas Ağaç	: Fine Tree
Hassas Gauss Destek Vektör Makinesi	: Fine Gaussian SVM
İki Katmanlı Sinir Ağı	: Bilayered Neural Network
İkinci Dereceden Destek Vektör Makinesi	: Quadratic SVM
Kaba Gauss Destek Vektör Makinesi	: Coarse Gaussian SVM
Kalın Ağaç	: Coarse Tree
Kübik Destek Vektör Makinesi	: Cubic SVM
Kalan Faydalı Ömür	: Remaining Useful Life
Karesel Üstel Gauss Süreç Regresyonu	: Squared Exponential GPR
Kademeli Doğrusal Regresyon	: Stepwise Linear Regression
Kök Ortalama Kare Hatası	: Root Mean Square Error
Makine Öğrenmesi	: Machine Learning

Mutlak Ortalama Hata	: Mean Absolute Error
Ortalama Ağaç	: Medium Tree
Ortalama Gauss Destek Vektör Makinesi	: Medium Gaussian SVM
Ortalama Sinir Ağı	: Medium Neural Network
Ön İşleme	: Pre-Processing
Rasyonel İkinci Dereceden	
Gauss Süreç Regresyonu	: Rational Quadratic GPR
Regresyon Ağaçları	: Regression Trees
Sıradan En Küçük Kareler	: Ordinary Least Squares
Sinir Ağları	: Neural Networks
Standart Sapma	: Standard Deviation
Tekrarlayan Sinir Ağı	: Recurrent Neural Network
Temel Bileşen Analizi	: Principal Component Analysis
Tensör İşleme Birimi	: Tensor Processing Unit
Torbalanmış Ağaçlar	: Bagged Trees
Uzun Kısa Süreli Bellek	: Long Short Term Memory
Üç Katmanlı Sinir Ağı	: Trilayered Neural Network
Üstel Gauss Süreç Regresyonu	: Exponential GPR
Z-Puanı Standardizasyonu	: Z-Score Standardization

1. GİRİŞ

Bakım (maintenance), maliyet ve güvenilirlik üzerindeki mühim etkileri sebebiyle endüstride son derece önemli bir etkinliktir. Bir cihazın beklenmedik bir arıza ile karşılaşması, işleri kesintiye uğratıp itibar kaybına sebep olabilir. Bu sebeple, beklenmedik kesintileri engellemek, güvenilirliği arttırmak ve işletme maliyetini kısmak için şirketlerin randımanlı bir bakım taktiği geliştirmesi oldukça önemlidir.

Bakım stratejileri, temelde en geleneksel olan Reaktif Bakım (Reactive Maintenance) ile başlamıştır. Daha sonra Önleyici Bakım (Preventive Maintenance) uygulanmaya başlamış ve ardından modern tekniklerin (nesnelerin interneti, yapay zeka vb.) gelişmesi ile birlikte yerini Kestirimci Bakım (Predictive Maintenance)'a bırakmıştır. Reaktif bakım, arıza meydana geldikten sonra arızayı onarmak üzere yapılan ciddi zaman ve maliyet kayıplarına sebep olan bakım türüdür. Önleyici bakım, arızayı önlemek için belli bir programa göre yapılmaktadır, bu sebeple gereksiz yere uygulandığı zamanlar olabilir. Bu durum yüksek bakım maliyetlerine yol açar. Kestirimci bakım, çevrimiçi bir sağlık tahminine dayanır ve zamanında yapılan müdahalelerdir. Durum izleme, arıza teşhisi, arıza tahmini ve bakım planlarını içeren kestirimci bakım kavramı uzun zamandır işlenmektedir [12] fakat son zamanlarda ortaya çıkan modern teknikler sayesinde geniş çapta erişilebilir, etkili ve ucuz bir hâl almıştır [13][14].

Kestirimci bakımı uygularken çok sayıda teknolojiden faydalanılmaktadır. Örneğin nesnelerin internetinden yararlanarak ekipmanlara yerleştirilen birçok sensörden çok miktarda veri toplanabilmektedir. Veri ön işleme için kullanılan büyük veri teknikleri sayesinde, daha önce sensörlerden toplanmış olan makine verileri, eyleme dönüştürülebilir bilgilere (veri temizleme, özellik çıkarma, gürültü azaltma vb.) dönüştürülebilmektedir. Buradan elde edilen bilgilerle bakım politikaları türetilip, arıza teşhisi ve prognozu için başvuru alan derin öğrenme yöntemleri ile birlikte karmaşık sistemlerde hata tespiti ve kalan faydalı ömür tahmini yapılabilmektedir. Karmaşık sistemlerde etkili kontrol sağlayan pekiştirmeli öğrenme (reinforcement learning) sayesinde, oldukça dinamik durumlarla başa çıkılabilmektedir. Grafik işleme birimi (GPU) ve tensör işleme birimi (TSU) gibi güçlü donanımların gelişmesiyle

birlikte derin öğrenme algoritmalarının eğitimi için gereken süre önemli ölçüde azaltılabilmektedir.

Bir üretim ortamında sensörlerin ve benzer araçların ortaya çıkışı ile kestirimci bakım yöntemleri gibi ekipmanların sağlık durumlarını ölçmek için prognostik yöntemler içeren bir terim olan Prognostik Sağlık Yönetimine (PHM) olan ilgi artmıştır. PHM'nin bir alanı olan kalan faydalı ömür tahmini, ekipmanın ileri dönemdeki performansını tahmin etmek ve işlevini yitirene kadar kalan çalışma süresini bulmak için tahmin yöntemlerini kullanan bir süreçtir [15].

Güvenirlilik bakımından bir hayli önem taşıyan alanlardan biri de havayolu endüstrisidir. Uçaklar için gerekli gücü üreten uçak motorları, sensörler ve otomatik kontrol eklenerek daha emniyetli hale getirilmektedir [16]. Karmaşık bir mekanığe sahip olan, yüksek basınç, sıcaklık ve hızlarda çalışan uçak motorlarında birçok arıza meydana gelme olasılığı bulunmaktadır [17]. Uçuş sırasında ortaya çıkan küçük bir arıza motorun çalışmasına engel olmayabilir fakat tespit edilmezse çok daha büyük yıkımlara sebep olabilir. Eğer uçaklardaki böyle arızaların önüne geçilmez ise kazalar ve yüksek bakım maliyetleri ortaya çıkabilir. Son yıllarda, arızaların önceden uyarılması, sistem ömrünün uzatılması ve aralıklı arızaların teşhis edilmesi için PHM odaklı uçak motorları üzerine araştırmalar yapılmıştır [18]. Uçak motorları PHM sisteminin odağı olan prognostik, olası arızaları önceden belirlemek, riskleri azaltmak ve yönetmek için gerekli bilgileri sağlamayı amaçlar [19]. PHM odaklı arıza teşhisi ve kalan faydalı ömür tahmini kapsamında yapılan çalışmalarda, sistemin dinamik modeline dayanan fizik tabanlı modeller, sistemin geçmiş operasyonel verilerine dayanan veri tabanlı modeller ve her iki yöntemin kombine edildiği hibrit modeller kullanılmıştır.

Bu çalışmada, uçaklarda oldukça kritik bir bileşen olan uçak motorlarının bakım takvimlerinin oluşturulup beklenmedik bir arızanın can kaybına sebebiyet vermemesi için veri tabanlı bir yöntem olan makine öğrenmesi algoritmaları kullanılarak motorların kalan faydalı ömürleri tahmin edilmeye çalışılmıştır. Bir uçuş motorunun ilk uçuşundan son uçuşuna kadar tüm bilgilerini içeren gerçek verilere sahip olmak oldukça zor olduğu için NASA tarafından yayınlanmış turbofan jet motoruna ait simülasyon verileri kullanılmıştır [20]. Bu doğrultuda,

veri kümesinde uçak motorlarının geçmiş tüm performans verileri yer aldığı için makine öğrenmesi alanında kullanılan yöntemlerden biri olan denetimli öğrenme (supervised learning) yöntemi kullanılmıştır.

Tez çalışmasının birinci bölümünde, kestirimci bakım ile ilgili genel bilgiler verilmiş ve özellikle havayolu endüstrisinde bu yöneme başvurma ne kadar önemli olduğuna değinilmiştir. İkinci bölümde, bakım türleri ve veriye dayalı makine öğrenmesi yöntemleri hakkında temel bilgilere ve uçak motorları için yapılan kalan faydalı ömür tahmin çalışmalarını içeren literatüre yer verilmiştir. Üçüncü bölümde, tez çalışması kapsamında kullanılan regresyon algoritmaları tanıtılmıştır. Dördüncü bölüm turbofan jet motoru verileri kullanılarak deneylerin yapıldığı ve sonuçların değerlendirildiği bölümdür. Beşinci ve son bölümde, tez çalışmanın sonuçları farklı açılardan değerlendirilmiştir.

2. LİTERATÜR TARAMASI

2.1. Bakım Türleri

Bakım, maliyet ve güvenilirlik üzerindeki etkileri sebebiyle endüstride önemli bir etkinliktir. Bakım stratejileri, en geleneksel olarak Reaktif Bakım ile başlamıştır. Daha sonra Önleyici Bakım uygulanmaya başlamış ve ardından modern tekniklerin (nesnelerin interneti, yapay zeka vb.) gelişmesi ile birlikte yerini Kestirimci Bakım'a bırakmıştır.

2.1.1. Reaktif Bakım

Reaktif bakım, önleyici bakımın yapılmaması sonucu ortaya çıkan plansız bakım türü olarak tanımlanabilir. Hata oluştuğundan sonra ekipmanın normal çalışma temposuna en kısa sürede dönebilmesi amacıyla hatayı gidermek için bu bakım türüne başvurulur. Bu yöntemi kullanan tesisler, ekipman arızalandıkça kadar bakım için herhangi bir kaynak harcamazlar. En pahalı bakım yöntemi olan reaktif bakım, aslında “bakım gerektirmeyen” bir yaklaşımdır [21].

Reaktif bakım, yüksek yedek parça ve işçilik maliyeti ile uzun süreli ekipman duruşlarına sebebiyet verir. Bu bakım türünde arızalı parçaları onarmak için gereken duruş süreleri oldukça uzun olup ekipmanın yeterince verimli kullanılamaması dolayısıyla maddi kayıplar da fazla olmaktadır. Beklenmeyen arızaların etkisini en aza indirmek için bakım ekibi arızaya en kısa sürede müdahale edebilecek donanımda ve tecrübede olmalıdır. Yapılan analizler, reaktif bakımların planlı olarak yapılan bakımlara göre üç kat daha maliyetli olduğunu göstermiştir [21].

2.1.2. Önleyici Bakım

Önleyici bakım, ekipman arızası meydana gelmeden önce gerekli tedbirler alınarak arızanın önüne geçilmesi olarak tanımlanabilir. Birçok alanda uygulanabilen önleyici bakım işletmelere özgüdür. Genellikle rutin denetimler esnasında yapılır ve doğal olarak denetim ve görev çizelgesi kullanılır. Bakımı yapılacak varlığın, ömrünün neresinde olduğuna ve şimdiye kadar ne tür sorunlarla karşılaştığına bağlı olarak önleyici bakım planlaması değişebilir. Ekipmanı kullanan çalışanların, yeterince bilgi sahibi olabileceği bir zaman zarfı boyunca kullanılan bir ekipman için “x sayıda döngüden sonra denetim ve bakım yapılır.” şeklinde bir planlamanın ortaya çıkması beklenen bir sonuçtur. Eğer planlanan süreden önce arıza gerçekleşirse reaktif bakım teknikleri kullanılarak onarım yapılmalıdır.

Önleyici bakımın birincil avantajı, sorunları henüz ortaya çıkmadan önlediği için ekipmanın atıl kalma süresini oldukça kısaltmasıdır. Buna bağlı olarak maddi kayıplar minimum seviyededir. Temel ekipman ve varlıkların ortalama ömürleri artar. Düzenli olarak ekipmanların denetlenmesi, güncellenmesi ve bakımlarının yapılması sayesinde yeni bir ekipmana yatırım yapma gereksinimi azalır. Önleyici bakımın dezavantajı ise, belli aralıklarla yapıldığı için bazen ekipmanın bakıma ihtiyacı yokken bile bakım yapılması dolayısıyla gereksiz maddi kayıplara sebep olmasıdır.


2.1.3. Kestirimci Bakım

Kestirimci bakım, bir arıza oluşmadan önce olası kusurları tespit etmek amacıyla ekipmanın çalışma durumunu takip eden bir bakım türüdür. Bu bakım türünde, ortaya çıkmakta olan arızaları tespit edebilmek için sistemlerin veya ekipmanların mekanik durumu, çalışma verimliliği ve çalışma şartlarının göstergeleri düzenli olarak takip edilir. Bu takiplerin amacı, onarımlar arasındaki en uzun aralığı sağlamak ve onarım sayısını en aza indirmek için gerekli verileri elde etmektir [21].

İlgili veriler analiz edilerek en doğru zamanda bakımlar yapılır ve bu sayede ekipmanın çalışma süresi en üst düzeye çıkar. Ekipman bakımlarının sadece gerektiği zaman yapılması,

gereğinden fazla yapılan bakımın ortaya çıkardığı vakit kaybını ortadan kaldırır. Uzun vadede bakım maliyetleri azalır ve ekipmanların kullanıldığı süre maksimum olduğu için üretimde kâr sağlanır. Personel için kapsamlı bir eğitim ve daha karmaşık yazılımlar gerektirmesi sebebiyle maliyetinin yüksek olması kestirimci bakımın dezavantajıdır.

Şekil 2.1.'de, ekipmanın operasyonu sırasında arızaların ortaya çıkış zamanına göre uygulanacak bakım yöntemleri gösterilmektedir. Erken tespit edilen ve henüz ekipmanın çalışmasını etkilemeyen hasar tespitinde kestirimci bakım devreye girmektedir. Hasarların dışarıdan farkedilir hale gelmesiyle birlikte önleyici bakım uygulanmakta olup, önleyici bakımın uygulanmasında geç kalındığı ve hasarın ekipmanın çalışmasına engel olduğu durumlarda reaktif bakım uygulanmaktadır.



Şekil 2.1. Öngörücü bakım stratejisi, ekipman arızalarını önlemek için erken uyarı yapmaya yarar [1].

Tablo 2.1.'de bakım yöntemlerinin uygulanma zamanı, avantaj ve dezavantaj bakımından özet karşılaştırması ve her bir yöntem için verilen örnek uygulama yer almaktadır.

Tablo 2.1. Bakım yöntemlerinin kısaca karşılaştırması

	Reaktif Bakım	Önleyici Bakım	Kestirimci Bakım
Bakım zamanı	Arızadan sonra	Önceden belirlenmiş aralıklarla	Gerektiği zaman
Avantaj	Sabit olmayan maliyet	Reaktif bakıma göre daha az arıza riski	Minimum arıza riski
Dezavantaj	Yüksek arıza riski	Gereksiz bakım yapılabilmesi	Yüksek maliyet
Örnek	Araba arızalandıktan sonra yağının değiştirilmesi	Her yıl belli aralıklarla arabanın yağının değiştirilmesi	Arabadan alınan verilerin analizi sonucunda yağının değiştirilmesi

2.2. Kalan Faydalı Ömür

Uçak motorları, mühendislik makineleri ve yüksek hızlı araçlar gibi karmaşık sistemlerdeki son gelişmeler, operasyonel güvenilirliği ve güvenliği arttırmak amacıyla çevrimiçi sağlık izlemenin önemini ortaya koymuştur [22][23][24]. Uçakların en temel parçalarından biri ve güç kaynağı olan uçak motorunun güvenilirlik çalışması, uçağın emniyetini sağlamak, bakım maliyetlerini azaltmak ve kullanılabilirliğini sürdürmek için büyük öneme sahiptir [25][26][27]. Bu anlamda, Prognostik Sağlık Yönetimi (PHM) etkili bir yaklaşımdır ve oldukça sık kullanılmaktadır [28][29]. Özellikle, Kalan Faydalı Ömür (RUL) tahmini, kestirimci bakım çerçevesinde önemli bir teknolojidir. Ana hatlarıyla, RUL, sistem veya bileşenin görevini artık icra edemez hale gelmeden önceki kalan ömrünü ifade etmektedir. RUL kestirimi sayesinde üretim kaybı azaltılır, bakım maliyetlerinden tasarruf edilir ve ekipman arızalanmadan önce ölümcül makine arızaları önlenmiş olur [30][31][32][33].

Günümüzde, makine öğrenmesi uygulamaları, karmaşık ve büyük verilerin varlığı sebebiyle Kalan Faydalı Ömrü (RUL) tahmin etmede önem kazanmıştır. Bu bilgi ışığında araştırmacılar,

çeşitli tahmin yaklaşımlarıyla geleneksel RUL tahmin örneklerini güçlendirmek için istek duymuşlardır.

Makine öğrenmesi yöntemleri sürekli olarak iyileştikçe PHM’de kullanımı artmış [34] ve daha doğru ömür tahmini ve arıza tespiti mümkün hale gelmiştir [35]. Makine öğrenmesi, verinin özellikleri ile ilgili bilgi sahibi olmadan bile, önemli özellikleri çıkararak sistemin davranışını modeller. Makine öğrenmesi teknikleri, insan müdahalesi ve hesaplama maliyetini daha düşük seviyelere indirerek modelleme karmaşıklığını azaltmayı hedefler.

Kalan faydalı ömür tahmini ile ilgili yaklaşımlar genel olarak üç kategoriye ayrılır: fizik tabanlı yaklaşımlar, veri tabanlı yaklaşımlar ve hibrit yaklaşımlar.

Fizik tabanlı bir model, kalan faydalı ömrü tahmin etmek için sistem dinamiklerinin fiziğine dayanan bir model kullanır [36][37][38][39][40]. Fiziksel modeller sınırlı sayıda geçmiş verilere sahip olsa da doğru ve makul RUL tahminleri yapabilir [41]. Ancak, fizik tabanlı modelleri karmaşık sistemlere uygulamak oldukça pahalıdır. Bu durum da bu yöntemin kullanılmasına sınırlama getirmektedir [42]. Rodrigues ve arkadaşları, mantık ağacı tabanlı yaklaşımdan destek alarak çok bileşenli sistemlerin kalan faydalı ömürlerini tahmin etmiştir [43]. Başka bir çalışmada, uçak hidrolik sistemlerinin Kalman filtre tabanlı ömür sonu tahmini çalışılmıştır [44]. Son zamanlarda, hidrolik aktüatör [45], rulman [46] ve diğer zaman serisi verileri [47] gibi çeşitli ekipmanlar için farklı tipte sensör verileri kullanılarak durum izleme çözümleri geliştirmeye yönelik çok sayıda çalışma yapılmıştır.

Veri tabanlı yaklaşımlar, sistem dinamiğinin karmaşık olduğu veya mevcut olmadığı durumlarda sistem sağlığına ilişkin geçmiş operasyonel verileri kullanarak RUL tahmini yapan modellerdir [48][49]. [24]’te yapılan çalışmaya göre, veri tabanlı yaklaşımın fizik tabanlı yaklaşıma göre daha hızlı ve ucuz olduğu ve daha doğru RUL tahminleri sağladığı görülmektedir. Veri kümesinin küçük gruplara ayrılarak eğitildiği (mini-batch traning) sinir ağları, akan veri dizileriyle etkileşime girebilir ve yeni değişiklikleri karşılamak için tahmin modelini güncelleyebilir. [50]’de, Ben Ali ve arkadaşları tarafından RUL’u tahmin etmek amacıyla zaman alanı dalgalanmasını önlemek için Weibull Dağılımı (WD) ile Basitleştirilmiş Bulanık Uyarlamalı Rezonans Teorisi Haritası sinir ağı eğitilerek yeni bir yaklaşım

sunulmuştur. Al-Dulaimi ve arkadaşları [51], RUL tahmini için Uzun Kısa Süreli Belleğe (LSTM) ve Evrişimsel Sinir Ağı'na (CNN) dayalı çok boyutlu özellik çıkarma ve bir füzyon algoritması aracılığıyla tahmin yolu olmak üzere iki farklı yaklaşım kullanan bir hibrit derin sinir ağı geliştirmişlerdir. Wen ve arkadaşları [52], CNN'ye dayalı özellik eşleme ve eğitim şemaları oluşturmuş ve RUL'u doğru bir şekilde tahmin etmek için birkaç öğrenciyi yapılandırdıktan sonra eğitim modellerini k-kat çapraz doğrulama (k-fold cross validation) yöntemiyle doğrulamıştır. Xiang ve arkadaşları [53], bir zaman penceresi özellik çıkarıcı ile birleştirilmiş yeni bir derin CNN kullanmışlardır. Böylece sinyal işlemede önceden bir uzmanlık gerekmesizin ham sensör ölçümleri doğrudan kullanılarak uçak motorlarının RUL tahmin süreci basitleştirilmiştir.

Hansen ve arkadaşları [54] tarafından önerilen hibrit yaklaşımlar, fizik tabanlı modeller ile prognostik sonuçlarının daha güvenilir ve doğru olduğu iddia edilen veri tabanlı modellerin kombinasyonudur. Hibrit modellerin kullanıldığı RUL tahmini ile ilgili yapılan geçmiş çalışmalara bakılacak olursa, Xiong ve arkadaşlarının [55] RUL tahmininde SVM'i eğitmek için Yarı Gizli Markov Modeli kullandığı görülür. Garcia ve arkadaşları [56] uçak motorlarının RUL'unu tahmin etmek için en iyi eğitim katsayılarını arayan hibrit bir SVM tabanlı sürü zekası tekniği geliştirmişlerdir. Saidi ve arkadaşları [57], rüzgar türbini yüksek hızlı shaft yataklarının sağlık öngörüsü amacıyla bir RUL tahmincisi oluşturabilmek için Spektral Kurtosis ile SVM'i birleştirmişlerdir. Ordoñez ve arkadaşları [58] erken RUL tahmini için birkaç tahmin algoritması oluşturmak amacıyla genetik algoritma kullanan gelişmiş bir SVM ile birleştirilmiş bir hibrit otoregresif model önermiştir. Chen ve arkadaşları [59], aynı RUL tahmini için SVM tabanlı bir benzerlik yaklaşımı kullanmıştır.

2.3. Makine Öğrenmesi

Makine öğrenmesi algoritma çeşitleri, mevcut veri kümesinin yapısına göre üç sınıfa ayrılır. NASA tarafından yayınlanan turbofan motoruna ait simülasyon veri kümesi, motorların ilk uçuşundan arıza gerçekleşene kadar tüm verileri barındırması sebebiyle aşağıda detayları verilen öğrenme yöntemlerinden denetimli öğrenme algoritmalarına uygundur.


2.3.1. Denetimli Öğrenme

Denetimli öğrenme (supervised learning), genel hipotezler üretmek için harici olarak sağlanan örneklerden akıl yürüten ve daha sonra gelecekteki örnekler hakkında tahminlerde bulunan algoritmaların aranmasıdır [60]. Belirli bir girdi-çıkı eğitim verilerine bağlı olarak bir sistemin girdi-çıkı bilgilerini elde etmeyi amaçlar. Çıkı, girdi verilerinin veya denetimin etiketi olarak kabul edildiğinden, girdi-çıkı eğitim örneğine etiketli eğitim verileri veya denetlenen veriler de denir [61]. Bu öğrenme yöntemiyle oluşturulan yapay sistem girdi ve çıkı arasındaki ilişkiyi öğrenebilir ve yeni girdiler verildikçe sistemin çıkısını tahmin eder. Girdi-çıkı ilişkisi genellikle öğrenme modeli parametreleriyle temsil edilir. Bu parametreleri elde etmek için ilgili parametreler tahmin sürecinden geçmelidir.

Denetimli algoritmalarda sınıflar önceden belirlenir. Bu sınıflar, insan tarafından tanımlanan bir sonlu küme şeklinde oluşturulur, bu da pratikte belirli bir veri segmentinin bu sınıflandırmalarla etiketleneceği anlamına gelir. Makine öğrenmesi algoritmasının görevi matematiksel modeller oluşturmaktır. Bu modeller daha sonra verilerin kendisindeki varyans ölçümleriyle ilgili tahmin kapasitesine dayalı olarak değerlendirilir.

Denetimli iki ana model bulunmaktadır: sınıflandırma modelleri ve regresyon modelleri. Regresyon modelleri, girdiyi gerçek değerli bir çıkıya eşler. Sınıflandırma modelleri, girdiyi önceden tanımlanmış sınıflara eşler [62].

Denetimli öğrenmenin en önemli avantajı, algoritma tarafından elde edilen tüm çıktıların insanlar için anlamlı olmasıdır. Dezavantaj olarak veri kümesi için etiket toplamanın zor ve maliyetli oluşu verilebilir.



Şekil 2.2. Denetimli öğrenme akış şeması [2]


Şekil 2.2.'de denetimli öğrenme yönteminin akış şeması verilmiştir. Bu şemadan anlaşıldığı üzere, eğitim setindeki etiketli verilerden birtakım öz nitelikler çıkarılarak makine öğrenmesi algoritması eğitilir. Eğitim verileri üzerinde tahminler yapan algoritma yeterince iyi bir tahmin performansına erişene kadar öğrenme devam eder. Öğrenen kestirimci model, yeni veriler üzerinde test edilir ve verilerin etiketleri tahmin edilir. Bu etiketler, gerçek bir değer veya kategorik olabilir.

En sık kullanılan denetimli öğrenme algoritmalarından bazıları k-en yakın komşu, doğrusal regresyon, lojistik regresyon, destek vektör makineleri, karar ağaçları, rastgele orman ve sinir ağlarıdır. Bu yöntemlerden doğrusal regresyon, destek vektör makineleri, karar ağaçları ve sinir ağları bu çalışmada kullanılan yöntemlerden bazılarıdır.

2.3.2. Denetimsiz Öğrenme

Denetimsiz öğrenme (unsupervised learning), veri kümesindeki çıktıların bilinmediği durumlarda verileri yorumlayarak anlamlı bir çıktı elde etmek için kullanılan öğrenme yöntemidir. Genellikle veride ne aranacağı bilinmeyen durumlarda bu yöntemin kullanılması faydalı olur. Veri kümesinde etiketleme yapmadan çıktıları tahmin eder.

Denetimsiz öğrenmenin ana görevi, sınıflandırma etiketlerini otomatik olarak geliştirmektir. Bu algoritmalar, kategorilere ayrılıp ayrılamayacaklarını belirlemek ve bir grup oluşturup oluşturamayacaklarını belirlemek için veri parçaları arasındaki benzerliği araştırır. Bu gruplara küme denir ve kümeleme (clustering) makine öğrenmesi tekniklerinin tüm ailesini temsil ederler. Bu denetimsiz sınıflandırmada (küme analizi) makine, kümelerin nasıl gruplandığını bilmez. Bu nedenle çıkan sonucun doğruluğundan emin olunamaz. Kategorize etme, ilişkilendirme ve anomali tespitinde denetimsiz öğrenme yönteminden faydalanılabilir.




Şekil 2.3. Denetimsiz öğrenme akış şeması [3]

Şekil 2.3.'te denetimsiz öğrenme yönteminin akış şeması verilmiştir. Bu yöntemde, etiketli olmayan girdi verilerini yorumlayarak veri kümesinin yapısını veya dağılımını modelleyen bir kestirim algoritması eğitilir. Bu algoritmanın çıktısı, veri kümesi içerisinde tespit edilen kümeler, birbiriyle ilişkili olduğu tespit edilen nitelikler veya veri kümesindeki diğer verilerden farklı bir davranış gösteren ve aykırı değer (outlier) olarak adlandırılan anomaliler olabilir.

2.3.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme (reinforcement learning), hangi eylemlerin yapılması gerektiğine ödül-ceza yöntemiyle karar verildiği bir öğrenme yaklaşımıdır. Bu yaklaşımın kullanıldığı durumlarda veri kümesi ve bilinen bir çıktı yoktur. Sadece girdilerden yola çıkan model deneme yanılma yoluyla öğrenir. Bu yöntemde, istenen davranışlara pozitif (ödül), istenmeyen davranışlara negatif (ceza) değerler atanır. En iyi çözüme ulaşmak için uzun vadeli ve en yüksek ödülü aramak için ajan programlanır. Uzun vadeli hedefler, ajanın kısa vadeli hedeflere odaklanmasını önler. Bu sayede ajan, zamanla olumsuzlardan kaçıp olumluları arama yoluna gider. Bu şekilde model öğrenmeye devam eder ve en iyi çözüm, en yüksek ödüle göre belirlenir.



Şekil 2.4. Pekiştirmeli öğrenme akış şeması [4]


Şekil 2.4.'te pekiştirmeli öğrenme yönteminin akış şeması verilmiştir. İlk olarak, ajan ortamın mevcut durumunu gözlemler. Gözlenen duruma göre, ajan hangi eylemi gerçekleştireceğine karar verir. Ortam daha sonra durumu değiştirir ve bu eylem için bir ödül üretir. Hem değişen durum hem de ödül, ajan tarafından alınır. Son olarak, alınan yeni bilgileri kullanarak, ajan bu eylemin iyi olduğu için tekrarlanması gerektiğini veya kötü olduğu için kaçınılması gerektiğini belirler. Bu deneme-yanılma süreci öğrenme tamamlanana kadar devam eder.

3. REGRESYON YÖNTEMLERİ

Giriş bölümünde, tez çalışması kapsamında, uçak motorlarının kalan faydalı ömürlerinin tahmin edilebilmesi için veriye dayalı makine öğrenmesi modelleri kullanıldığından bahsedilmiştir. Eğitim için kullanılan 6 temel makine öğrenmesi algoritması bu bölümde sunulmuştur.

3.1. Doğrusal Regresyon

Doğrusal Regresyon (Linear Regression), bir veya daha fazla bağımsız değişken ile bağımlı değişkenler arasındaki ilişkiyi bulmak için kullanılan bir yöntemdir. Bağımsız değişken sayısının bir olduğu durum basit doğrusal regresyon, bağımsız değişken sayısının birden fazla olduğu durum ise çoklu doğrusal regresyon olarak adlandırılır. Basit doğrusal regresyon, doğrusal bir denklem ile temsil edilirken; çoklu doğrusal regresyon, düzlem veya hiper-düzlem ile temsil edilebilir. Doğrusal regresyon için temsili gösterim Şekil 3.1. ile verilmiştir.



Şekil 3.1. Doğrusal Regresyon Grafiği [5]

Çoklu doğrusal regresyon için başvuru en yaygın yöntemlerden ilki Sıradan En Küçük Kareler yöntemidir. Bu yöntemde her bir noktanın regresyon çizgisine olan mesafesinin karelerinin toplamının minimum olmasına çalışılır. Çoklu doğrusal regresyonda kullanılan


bir diğ er y ntem ise gradyan iniřidir. Gradyan iniři, ger ek  ıktı deėeri ile tahmin edilen  ıktı deėeri arasındaki farkı g steren maliyet fonksiyonunu en aza indirerek hatayı minimize etmekte kullanılır. Minimizasyon iřlemi, toplam kare hatası en az olana kadar devam eder.

3.2. Regresyon Aėa ları

Karar aėa ları (decision trees), veri madenciliėinde sıklıkla kullanılan bir y ntemdir [63]. Bu y ntemdeki ama , bir model oluřturarak birtakım girdi deėiřkenlerine baėlı olarak hedef deėiřkenin deėerini tahmin etmektir. Girdi deėiřkeninin kategorik olduėu aėa  modelleri sınıflandırma aėa ları, girdi deėiřkeninin s rekli deėerler alabildiėi aėa  modelleri ise Regresyon Aėa ları (Regression Trees) olarak adlandırılır. Karar aėa ları, anlařılabilirlikleri ve basitlikleri g z  n ne alındıėında en pop ler makine  ėrenmesi algoritmaları arasındadır [64].

Karar aėa ları, hem sayısal hem kategorik deėiřkenleri iřlemede kullanılması,  ok az veri hazırlıėı gerektirmesi ve b y k veri k melerinde iyi performans sergilemeleri dolayısıyla avantajlıdırlar. Ayrıca insanların karar verme s recini diėer yaklařımlardan daha iyi bir řekilde yansıttıkları i in insan davranıřlarını ve kararlarını modellemede bařvurulan bir y ntemdir [65].

Bir karar aėacı temel olarak, d ė mler, dallar ve yapraklar olarak adlandırılan    temel b l mden oluřur. Her  znitelik bir d ė m ile temsil edilir. Karar aėacının son kısmına yaprak,  st kısmına ise k k adı verilir. K kler ve yapraklar arasındaki kısımlar dallar olarak ifade edilir [63]. Regresyon aėacı i in temsili g sterim řekil 3.2. ile verilmiřtir.



Şekil 3.2. Regresyon Ağacı Akış Şeması [6]


Regresyon ağacını oluştururken ilk önce eğitim setinin tamamı kök düğümde yer alır. Ardından veriler, belli kurallar çerçevesinde daha küçük dallara ayrılır. Bu kurala göre, ortalama sapmaların karelerinin toplamının en az olduğu dal seçilerek bir alt bölümlmeye geçilir. Yeni dalların hepsine bu kural uygulanır. En sonda gelinen düğümün ortalama sapmaların karelerinin toplamı sıfır olduğunda veya yaprak boyutu minimuma ulaştığında regresyon ağacı tamamlanmış olur. Kökten her yaprağa kadar tek bir yol veya tek bir karar kuralı vardır. Ağaç oluşumunun her aşamasında kullanılan değişken sayısına bağlı olarak tek değişkenli veya çok değişkenli karar ağacı yapıları vardır [66].

Yaprak boyutu, o yapraktaki gözlem sayısı ile ölçülür. Yaprak boyutunun küçük olması, ağacın çok dala ayrılması; yaprak boyutunun büyük olması ise ağacın daha az dala ayrılması olarak yorumlanabilir.

3.3. Birleştirilmiş Karar Ağaçları

Bölüm 3.2.'de karar ağaçlarının avantajlarından bahsedilmiştir. Bu avantajların yanı sıra, eğitim verilerindeki ufak bir değişikliğin tahmin sonuçlarını büyük ölçüde değiştirmesi ve

karmaşık ağaçların oluşturulması sonucu aşırı uyumun (overfit) meydana gelmesi gibi dezavantajları bulunmaktadır. Basit karar ağaçlarında sapmanın, karmaşık karar ağaçlarında ise varyansın büyük olması söz konusudur. Tek bir karar ağacı kullanmaktan daha iyisi, birkaç karar ağacını birleştiren Birleştirilmiş Karar Ağaçları (Ensemble of Trees) yöntemini kullanmaktır. Bu yöntemdeki amaç, tahmin doğruluğunu arttırmaktır. Birleştirilmiş karar ağacı için temsili gösterim Şekil 3.3. ile verilmiştir.




Şekil 3.3. Birleştirilmiş Karar Ağacı Akış Şeması [7]

3.4. Sinir Ağları

Sinir Ağları (Neural Networks) üzerine yapılan ilk çalışma, matematiğe dayalı bir hesaplama modeli oluşturan McCulloch ve Pitts'e aittir [67]. Yapay sinir ağları, bir girdi katmanını, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur [68]. Her katmanda birkaç düğüm veya nöron yer alır ve her katmandaki düğümler, önceki katmandaki tüm düğümlerin çıktılarını girdi olarak kullanır, böylece tüm nöronlar farklı katmanlar aracılığıyla birbirleriyle bağlantı kurar. Her nörona, öğrenme süreci sırasında sürekli güncellenen bir ağırlık atanır ve ağırlıktaki azalma veya artış, o nöronun sinyalinin gücünü değiştirir.

Mühendislik uygulamalarında sıkça kullanılan sinir ağı çeşitleri şu şekilde özetlenebilir:

- İleri beslemeli sinir ağı: Bir girdi katmanından, bir veya birkaç gizli katmandan ve bir çıktı katmanından (derin olmayan sinir ağı) oluşur.
- Evrişimli sinir ağı: Görüntü işlemede yaygın olarak kullanılan ve ağırlıkları paylaşan düğümlerle pencereleri giriş boyunca kaydıran ve özellik haritalarına girdiyi soyutlayan evrişimli katmanlarla karakterize edilen derin sinir ağlarıdır.
- Tekrarlayan sinir ağı: Zaman serisi, sensör ve metin verilerinde olduğu gibi girdideki sıralı bağımlılıkları modelleyen geri besleme döngülerine sahip sinir ağı mimarisidir. Tekrarlayan sinir ağının en popüler türü uzun kısa süreli bellek ağıdır (LSTM).



Şekil 3.4. Sinir Ağının Matematiksel Modeli [8]

Bu çalışmada kullanılan her model, regresyon için ileri beslemeli, tam bağlı bir sinir ağını temsil etmektedir. Tam bağlı katman, her girdinin tüm nöronlara bağlı olduğu yapılardır. Sinir ağının ilk tam bağlı katmanı, ağ girişine bağlıdır ve sonraki her katman bir önceki katmana bağlanır. Her tam bağlı katman, girdiyi bir ağırlık matrisi ile çarpıp ve ardından bir sapma vektörü ekler. Çıktının genliğini kontrol eden aktivasyon fonksiyonu, en sondaki hariç, tam bağlı her katmanı takip eder. Sondaki tam bağlı katman, ağın çıktısını, yani tahmin değerlerini sunar. Bir sinir ağının matematiksel modeli Şekil 3.4.'te verilmiştir.

Sinir ağlarının avantajları, görülmemiş değerler için sonuç üretebilmeleri, eksik örüntüleri tamamlayabilmeleri, eksik bilgi ile ve paralel çalışabilmeleri olarak sayılabilir. Bu yöntemin

dezavantajları ise belli bir problem için geliştirilen ağı farklı problemlere uyarlamanın zor olması, ağı davranışlarını açıklamanın ve sistem içerisindeki çalışma prensibini anlamının zor olması şeklinde sıralanabilir.

3.5. Gauss Süreç Regresyonu


Gauss Süreç Regresyonu (Gaussian Process Regression), parametrik olmayan ve Bayesci bir regresyon yaklaşımıdır. Birçok makine öğrenmesi algoritması bir fonksiyondaki parametreler için kesin değerleri öğrenirken, Bayes yaklaşımı olası değerler üzerinde bir olasılıksal dağılım çıkarır. Doğrusal bir fonksiyonun eğimini ifade eden parametre (w) üzerinde o parametreye ait önsel dağılımın belirlenmesi ve Bayes kuralına göre gözlenen verilere dayalı olasılıkların oluşturulmasıdır.

$$p(w | y, X) = \frac{p(y | X, w) p(w)}{p(y | X)} \quad (1)$$

$$\text{sonsal olasılık} = \frac{\text{olasılık} \times \text{önsel olasılık}}{\text{marjinal olasılık}} \quad (2)$$

Önsel dağılımın ve olasılığın Gauss olduğu varsayılır. Gauss süreç regresyonu, belirli bir işlevin parametrelerinin olasılıklarını hesaplamak yerine, verilere uyan tüm kabul edilebilir işlevler üzerindeki olasılıksal dağılımı hesaplar. Yani tahmin, olasılıksaldır ve tüm gözlemleri interpolate eder. Temsili Gauss Süreç Regresyon grafiği Şekil 3.5. ile verilmiştir.

Bu yöntemin avantajları arasında, küçük veri kümeleri üzerinde iyi çalışması ve tahminlerde belirsizlik ölçümleri sağlama becerisine sahip olması gösterilebilir. Öznitelik sayısının çok arttığı durumlarda hesaplama etkinliğini kaybetmesi ve performansının düşmesi, olumsuz özellikleri olarak sayılabilir.




Şekil 3.5. Gauss Süreç Regresyonu Grafiği [9]

3.6. Destek Vektör Regresyon Makinesi

Destek Vektör Makinesi (Support Vector Machine) analizi, ilk kez 1992 yılında Vladimir Vapnik tarafından çalışılan, sınıflandırma ve regresyon için kullanılan popüler bir makine öğrenme algoritmasıdır [69]. Destek Vektör Makinesi'nin regresyon versiyonu ise 1996 yılında önerilmiştir [70]. Parametrik olmayan Destek Vektör Regresyonu (DVR), çekirdek fonksiyonlarına dayanır.


Regresyon yöntemi olarak da kullanılabilen DVR, sınıflandırma için kullanılan DVM ile aynı prensibe dayanır. DVR'nin arkasındaki temel fikir, maksimum nokta sayısına sahip en uygun hiperdüzlemi bulmaktır. Hiper düzlemin her iki tarafında hiper düzleme en yakın olan veri noktalarına Destek Vektörleri denir. Bunlar, tahmin edilen çıktıyı gösteren gerekli satırı çizmek için kullanılır. Hiperdüzlemin iki tarafına ϵ (epsilon) mesafesinde çizilen çizgilere sınır çizgileri denir.



Şekil 3.6. Destek Vektör Makinesinin Regresyon ve Sınıflandırma Problemlerinde Çalışma Yöntemi [10]

DVR'nin amacı, hiperdüzleme en yakın veri noktaları veya destek vektörleri bu sınır çizgisi içinde olacak şekilde orijinal hiperdüzlemden ' ϵ ' uzaklıkta bir karar sınırına karar vermeye çalışmaktır. Regresyon analizinde, bant içindeki tüm noktalar için hata maliyeti sıfırdır. Yüksek miktarda tolere edilebilir bir hata ile ilgileniliyorsa ϵ yoğun bandı genişletilebilir.

Aykırı değerlere karşı dirençli olması, kolayca güncellenebilen bir model olması, tahmin doğruluğunun yüksek olması sebebiyle çok iyi genelleme yeteneğine sahip olması ve uygulamasının kolay olması gibi avantajlara sahiptir. Bu avantajların yanı sıra bu algoritmanın bazı olumsuz yönleri de bulunmaktadır. Bunlar, büyük veri kümelerine uygun olmaması, özellik sayısının örnek sayısını aştığı ve veri kümesinin çok gürültülü olduğu durumlarda performansının düşmesidir.



Şekil 3.7. Doğrusal ve Doğrusal Olmayan Destek Vektör Regresyonunun Çalışma Yöntemi [10]

Çekirdek fonksiyonu, girdi verilerini alan ve gerekli işleme biçimine dönüştüren matematiksel bir fonksiyondur. Genellikle yüksek boyutlu uzayda hiperdüzlemi bulmayı amaçlar. DVR algoritmaları, veriyi alıp istenen forma dönüştüren çekirdek fonksiyonlarını kullanır. Kullandıkları çekirdek fonksiyonlarına göre farklı DVR algoritmaları ortaya çıkar. Bu algoritmalarla örnek olarak doğrusal, doğrusal olmayan, polinom, radyal temel fonksiyon, gauss ve sigmoid gösterilebilir.

4. TURBOFAN MOTORUN KALAN FAYDALI ÖMRÜNÜN KESTİRİMİ

Tez çalışmasının bu bölümünde, veri kümesinin tanımı Bölüm 4.1.'de, veri üzerinde yapılan ön işlemler Bölüm 4.2.'de, makine öğrenmesi modelinin kullanılacağı veri setlerinin elde edilmesi Bölüm 4.3.'te, temel bileşen analizi Bölüm 4.4.'te, modelin eğitilmesi ve başka veri kümesi üzerinde doğrulanması Bölüm 4.5.'te detaylarıyla anlatılmıştır.

4.1. Veri Kümesi Tanımı


Bu çalışmada, 2008 yılında Uluslararası Prognostik Sağlık Yönetimi Konferansı'nda (PHM-08) düzenlenen yarışma verileri kullanılmıştır. Bu veri kümesi, Ticari Modüler Havacılık Tahrik Sistemi Simülasyonu (C-MAPSS) kullanılarak uçak gaz türbini motorlarının hasar yayılımını modelleyen verilerden sağlanmıştır [11]. İlgili veri kümesi, 218 adet çok değişkenli zaman serilerinden oluşan ve yapısı Şekil 4.1.'de verilen turbofan motoru verilerini içermektedir. Veri kümesinin tamamı aynı tipteki motorlardan oluşmaktadır. Veri kümesinde, her bir motorun arızalanana kadar yaptığı uçuş sayısı, motor performansı üzerinde önemli etkiye sahip olan operasyonel koşullar ve gürültü ile kirletilmiş sensör ölçümleri bulunmaktadır. Sensör ölçümleri, her bir uçuştan bir defa alınan tipik ölçümlerdir.

Veri kümesinde 218 motor için farklı uçuş koşullarında simülasyonla elde edilmiş 21 sensörden oluşan veriler bulunmaktadır. Veriler, boşluklarla ayrılmış 26 sütun içeren sıkıştırılmış bir metin dosyası olarak sağlanır. Her satır, tek bir operasyonel döngü sırasında alınan verilerin anlık görüntüsüdür; her sütun farklı bir değişkendir. Veri kümesi parametreleri Tablo 4.1.'de verilmiştir.

Tablo 4.1. Veri Kümesi Parametreleri

Parametre	Tanım	Birim
Ünite	-	-
Uçuş Sayısı	-	-
Operasyonel Ayar 1	İrtifa	ft
Operasyonel Ayar 2	Mach Sayısı	M
Operasyonel Ayar 3	Deniz Seviyesine Göre Sıcaklık	°F
Sensör 1	Fan Girişindeki Toplam Sıcaklık	°R
Sensör 2	LPC Çıkışındaki Toplam Sıcaklık	°R
Sensör 3	HPC Çıkışındaki Toplam Sıcaklık	°R
Sensör 4	LPT Çıkışındaki Toplam Sıcaklık	°R
Sensör 5	Fan Girişindeki Basınç	psia
Sensör 6	Baypas Kanalındaki Toplam Basınç	psia
Sensör 7	HPC Çıkışındaki Toplam Basınç	psia
Sensör 8	Fiziksel Fan Hızı	rpm
Sensör 9	Fiziksel Çekirdek Hızı	rpm
Sensör 10	Motor Basınç Oranı	-
Sensör 11	HPC Çıkışındaki Statik Basınç	psia
Sensör 12	Yakıt Akışının Ps30'a Oranı	pps/psi
Sensör 13	Düzeltilmiş Fan Hızı	rpm
Sensör 14	Düzeltilmiş Çekirdek Hızı	rpm
Sensör 15	Baypas Oranı	-
Sensör 16	Yakıcı Yakıt-Hava Oranı	-
Sensör 17	Akış Entalpisi	-
Sensör 18	İstenilen Fan Hızı	rpm
Sensör 19	İstenilen Düzeltilmiş Fan Hızı	rpm
Sensör 20	HPT Soğutma Sıvısı Akışı	lbm/s
Sensör 21	LPT Soğutma Sıvısı Akışı	lbm/s

Turbofan motoru, her bir serinin başlangıcında normal bir şekilde çalışmakta ve seri sırasında bir uçuşta arıza geliştirmektedir. Motorların, ilk uçuştan arızaya kadar tüm çalışmalarını içeren "Eğitim" veri kümesi, 218 adet motorun uçuş bilgilerini içermektedir. Bu veri kümesinin %75'lik kısmı tahmin edici modelleri eğitmek için, kalan %25'lik kısmı ise eğitilen modellerin tahmin performansını değerlendirmek için kullanılmıştır. Çalışmanın sonunda, tahmin edilen RUL ile gerçek RUL'lar karşılaştırılacak ve kestirim hata ölçümü yapılacaktır.



Şekil 4.1. Simüle Edilen Turbofan Motorun Basitleştirilmiş Diyagramı
[11]

4.2. Veri Ön İşleme

Veri ön işleme (data pre-processing), ham verilerin anlaşılabilir bir biçime dönüştürülebilmesi için başvurulacak önemli bir adımdır. Gerçek dünyada veriler genellikle eksik, hatalı, gürültülü veya tutarsız olabileceği için ön işleme adımı bu sorunları çözerek veriyi anlamlandırabilmeyi sağlar. Doğru ve yeterli şekilde işlenmeyen ham veriler ile sağlıklı bir eğitim yapılamaz ve dolayısıyla eğitilen model ile doğru tahminler yürütülemez. Tez çalışmasında "Eğitim" veri kümesine ön işleme aşamasında uygulanan adımlar aşağıdaki başlıklarda ele alınmıştır.

4.2.1. Veri Etiketleme

Eğitim veri kümesinde, başlangıçtan arızaya kadar tüm uçuş bilgilerinin bulunduğunu ve t ile gösterilen parametrenin her bir motora ait uçuş sayısını ifade ettiğini biliyoruz. Her motor için uçuş sayısı 1'den başlar ve her satırda "1" artarak arıza meydana gelene kadar veri kaydı tutulmaya devam eder. Herhangi bir anda motorun kalan faydalı ömrü, ilgili motorun toplam ömrü ile o andaki uçuş sayısının farkına eşittir. Bu bilgiden yola çıkılarak "Eğitim" veri kümesi için RUL'u gösteren yeni bir değişken oluşturulmuştur.


4.2.2. Çalışma Profillerinin Belirlenmesi

Motorların ömürlerine karşılık sensör ölçümleri çizdirildiği zaman grafikler herhangi bir eğilim göstermediği için bozulma sürecine dair bilgi elde edilememektedir. İşte bu noktada, operasyonel koşullardan yardım alınır. Operasyonel ayarların motor performansını önemli ölçüde etkilediği yukarıda belirtilmişti. Üç operasyonel koşul 3-boyutlu grafikte çizdirildiği zaman Şekil 4.2.'de görüldüğü gibi 6 farklı nokta etrafında kümelerin meydana geldiği yani 6 farklı çalışma koşulu olduğu görülmektedir. Tespit edilen bu kümelerin merkezlerinin belirlenmesi için k-ortalama (k-means) algoritmasına başvurulmuştur. Çalışma koşullarının sayısı, yönetilebilir bir boyuta indirilerek, bu koşulların sensör ölçümleri üzerindeki etkileri tamamen ortadan kaldırılabilir. Belirlenen kümeler, "Çalışma Koşulları" adlı yeni bir kategorik değişkene atanmış ve eğitim veri kümesine yeni bir sütun olarak eklenmiştir.

Sensör ölçümlerine daha yakından bakalım. Şekil 4.3.'te motorların üzerlerindeki sensörlerin motor ömrü boyunca okuduğu değerlerin grafikleri görülmektedir.

Şekil 4.4.'te ise, her bir çalışma kümesini farklı bir renkle vurgulayan, sensör değerlerinin farklı çalışma koşulları altında nasıl farklılaştığını gösteren grafikler paylaşılmıştır.

Ardından sensör verileri daha detaylı incelenmiş olup her bir sensörün, motorların ömrü boyunca kaç farklı değer aldığı hesaplanmış ve Tablo 4.2.'de sunulmuştur.




Şekil 4.2. Çalışma Koşulları


Tablo 4.2. Sensörlerin Aldığı Değerler

s1	s2	s3	s4	s5	s6	s7
6	1571	11839	14713	6	14	2004
s8	s9	s10	s11	s12	s13	s14
880	20945	8	671	1633	507	14250
s15	s16	s17	s18	s19	s20	s21
8210	2	49	6	2	500	16970

Çalışma koşullarından dolayı sensörlerin çoğu için farklılıkların ortaya çıktığı rahatlıkla görülebilir. İlerleyen aşamalarda, çalışma koşullarının etkisini ortadan kaldırmak için veriler üzerinde küme başına standardizasyon işlemi uygulanacaktır. Bu işlem, koşuldan koşula geçişin neden olduğu değişiklikleri ortadan kaldıracaktır.



Şekil 4.3. Sensör Değerleri



Şekil 4.4. Operasyonel Ayarların Sensörler Üzerindeki Etkisi


4.2.3. Veri Temizleme

Veri temizleme, veri kümesindeki yanlış, eksik ya da bozulmuş girdileri tespit etme, düzeltme, değiştirme ya da silme işlemleridir.

Bu çalışmada, kullanıcıya veri kümesi hakkında bilgi sağlamayan ve sonuçlar üzerinde hiç bir katkısı olmayan sensör ölçüm değişkenleri veri kümesinden çıkarılmıştır. "Çalışma Koşulları" isimli yeni değişkenin belirlenmesinde kullanılan operasyonel ayar (op1, op2, op3) değişkenleri kullanıcıya daha başka bilgi sağlamadığı için veri kümesinden çıkarılmıştır. Eğitim setinde kalan ömrü gösteren "RUL" isimli değişkenin oluşturulmasıyla birlikte artık işlevsiz olan "t" değişkeni de veri kümesinden çıkarılmıştır.

Aykırı Değerlerin Çıkarılması Aykırı değerler, veri kümesindeki diğer gözlemlerden saptamalar gösteren uç değerlerdir. Bir örneklem üzerinde genel modelden farklılaşırlar. Veri üretme, toplama, işleme ve analiz etme sürecinde aykırı değerler birçok kaynaktan gelebilir ve birçok boyutta saklanabilir. Makine öğrenmesinde ve herhangi bir niceliksel disiplinde verilerin kalitesi, bir tahmin veya sınıflandırma modelinin kalitesi kadar önemlidir. Dolayısıyla eğitilen modelin doğrulama seti üzerinde doğru tahminler yapabilmesi amacıyla PHM08 veri kümesinde aykırı değerler aranmıştır.

Veri kümesindeki 218 adet motorun çalışma sürelerine bakıldığı zaman 128 ila 357 arasında değerler aldığı ve 2 tane motorun diğer 216 motora göre nispeten daha uzun ömürlü olduğu Şekil 4.5.'te görülmektedir. İlerki aşamalarda tahminleri etkilememesi adına fazla uzun ömürlü olan bu birimler veri kümesinden çıkarılacaktır.



Şekil 4.5. Veri Kümesindeki Birimlerin Ömür İstatistiği

1

4.2.4. Veri Standardizasyonu


Farklı ölçeklerdeki değişkenler, analize farklı ağırlıklarda katkı sağlarlar. Bu da modelin doğru eğitilememesine sebebiyet verir. Çok değişkenli analizlerde, farklı birimlere sahip ölçümler arasında karşılaştırma yapabilmek ve verileri doğru analiz edebilmek için normalizasyon ya da standardizasyon uygulamak gereklidir. Bu çalışmada, standardizasyon yöntemi olarak sıkça kullanılan "Z-Puanı Standardizasyon" (Z-score standardization) yöntemi kullanılmıştır.

$$z = \frac{x - \mu}{\sigma} \quad (3)$$


Standardizasyon öncesi sensör ölçümleri ile standardizasyon sonrası sensör ölçümleri Şekil 4.6. ve Şekil 4.7.'de verilmiştir. Standardizasyon yöntemi uygulandıktan sonra algılayıcılardaki

¹Minimum, aykırı değerler hariç en düşük değeri gösterir. İlk çeyrek (%25), skorların yüzde yirmi beşlik dilimine gelen kısmını gösterir. Medyan, verilerin orta noktasını işaretler ve kutuyu iki bölüme bölen çizgiyle gösterilir. Üçüncü çeyrek (%75), skorların yüzde yetmiş beşlik dilimine gelen kısmını gösterir. Dolayısıyla, verilerin % 25'i bu değerin üzerindedir. Maksimum, aykırı değerler hariç en yüksek değeri gösterir.

bozulmaların daha net ortaya çıktığı görülmektedir. Sensör ölçümelerini gösteren grafiklerde, bütün motorlardaki ilgili sensöre ait ölçümler yer almaktadır.




Şekil 4.6. Standardizasyon öncesi ham verideki s2, s3, s20 ve s21 sensör ölçümleri



Şekil 4.7. Standardizasyon sonrası verideki s2, s3, s20 ve s21 sensör ölçümleri

Veri kümesindeki sensörlerdeki farklılıklar, çalışma koşullarına bağlı olarak gelişmektedir. 6 farklı çalışma koşulunun etkisinin ortadan kaldırılması için farklı çalışma koşullarına göre

gruplandırılmış ölçümler üzerinde standardizasyon işlemi yapılmıştır. Bu sayede çalışma koşulları arasındaki geçişin sebep olduğu değişiklikler ortadan kaldırılmıştır. Bu yöntem ile sensör ölçümlerini içeren değişkenlerin ortalaması 0'a, standart sapması ise 1'e eşitlenmiştir.



Şekil 4.8. Standardize Edilen Sensör Ölçümleri

Şekil 4.8.'in daha detaylı analiz edilmesinin ardından bazı ölçümlerde belirsizliklere rastlanmıştır. Bu belirsizliklerin oranı Tablo 4.3.'te sunulmuştur.

Tablo 4.3. Belirli Çalışma Koşulları Altında Sensör Verilerindeki Belirsizlik Oranı

s1	s5	s10	s16	s18	s19
%100	%100	%30,2	%85.3	%100	%100


Tablo 4.3.'teki veriler, Şekil 4.8.'i desteklemektedir. Boş grafikler, 6 farklı çalışma koşulu altında hiç bir değişim göstermeyen sensör ölçümlerine tekabül etmektedir. Bu, ilgili sensörden alınan ölçüm ile ilgili sensörün ortalama değerinin eşit olduğu anlamına gelir. Dolayısıyla böyle bir değişken, tahmin modeli oluşturma konusunda bize fayda sağlamayacaktır. Bu sebeple s1, s5, s18 ve s19 değişkenleri veri kümesinden çıkarılmıştır. S10 sensörünün 2 farklı çalışma koşulunda, s16 sensörünün ise 5 farklı çalışma koşulunda hiç bir değişim göstermediği tespit edilmiştir. Sağlıklı bir tahmin modeli oluşturabilmek için eksik veri içeren bu iki değişken de veri kümesinden çıkarılmıştır.

4.3. Veri Kümesini Bölme

Ön işleme (pre-processing) işlemlerinin bitmesinin ardından veri kümesi, "Eğitim Seti" ve "Doğrulama Seti" olmak üzere %75-25 oranında 2 parçaya ayrılmıştır. Veri kümesindeki 162 adet motor "Eğitim Seti" olarak, 54 adet motor ise "Doğrulama Seti" olarak kullanılmıştır. Doğrulama setinin eğitim setinden tek farkı, tahmin edilecek hedef değişkenin çıkarılmış olmasıdır. Bunu yapmaktaki amaç, eğitim verisi kullanılarak eğitilen modelin doğrulama seti üzerindeki tahmin performansını ölçmektir. Model tahminleri ile gerçek değerler karşılaştırılarak modelin tahmin performansı değerlendirilecek ve en uygun makine öğrenmesi modeli bulunacaktır.

4.4. Temel Bileşen Analizi

Temel bileşen analizi, çok boyutlu uzaydaki bir verinin, varyans maksimum olacak şekilde daha düşük boyuta indirgenmesi işlemidir. Boyut azalırken birtakım veriler kaybolur fakat burada amaçlanan, az bilgiyi içeren özelliklerin veri kümesinden çıkarılmasıdır. Temel bileşen analizi, verideki önemli bilgileri ortaya çıkarması dolayısıyla oldukça sık başvurulmuş bir yöntemdir. Bu yöntem, temel özellikleri belirleyerek çok boyutlu bir veriyi daha az miktarda değişkenle ifade etmeye yarar. Temel bileşen analizi, standardize edilmiş bileşenlerden oluşan veri kümesine uygulanabilir. İlgili grafikler Şekil 4.9. ve Şekil 4.10.'de sunulmuştur. Bu çalışmada yapılan temel bileşen analizinde Şekil 4.10.'de de görüldüğü üzere 4 temel bileşenin, varyansın %85'inden fazlasını koruduğu söylenebilir. Bu çalışmada kullanılan veri kümesi, eğitim süresini çok uzun sürelerle çıkaracak boyutta olmadığı için temel bileşen analizine başvurulmamıştır.



Şekil 4.9. Her Bir Temel Bileşenin Açıkladığı Varyans Oranı



Şekil 4.10. Temel Bileşenlerin Kümülatif Olarak Açıkladığı Varyans Oranı

4.5. Regresyon

Regresyon, iki veya daha çok değişken arasındaki ilişkiyi analiz etmede kullanılan bir yöntemdir. İlgili değişkenler niceldir ve bağımsız değişkenin (tahmin edilmesi istenen değişken) değeri, diğer bağımlı değişkenlere bağlıdır.

Bu çalışmada, regresyon analizi yapılarak turbofan motorlarının kalan faydalı ömürleri tahmin edilmiştir. Bu amaçla, Bölüm 4.3.'te bahsedilen "Doğrulama seti" kullanılarak tahmin algoritmalarının performansları değerlendirilmiştir.

Tez çalışmasında, 6 farklı algoritmaya ait toplam 24 adet makina öğrenmesi modeli eğitilmiştir. Kullanılan modeller Tablo 4.4.'te belirtilmiştir.

Tablo 4.4. Kullanılan Makina Öğrenmesi Modelleri

Kullanılan Modeller		
1. Doğrusal Regresyon	2. Birleştirilmiş Karar Ağaçları	3. Regresyon Ağacı
1.1. Doğrusal Regresyon	2.1. Torbalanmış Ağaçlar	3.1. Hassas Ağaç
1.2. Etkileşimli DR	2.2. Güçlendirilmiş Ağaçlar	3.2. Ortalama Ağaç
1.3. Gürbüz DR		3.3. Kaba Ağaç
1.4. Kademeli DR		
4. Destek Vektör Makinesi	5. Gauss Süreç Regresyonu	6. Siğir Ağları
4.1. Doğrusal DVM	5.1. Üstel GSR	6.1. İki Katmanlı SA
4.2. Kübik DVM	5.2. Matern 5/2 GSR	6.2. Üç Katmanlı SA
4.3. İkinci Dereceden DVM	5.3. Karesel Üstel GSR	6.3. Ortalama SA
4.4. Hassas Gauss DVM	5.4. Rasyonel İkinci	6.4. Dar SA
4.5. Ortalama Gauss DVM	Dereceden GSR	6.5. Geniş SA
4.6. Kaba Gauss DVM		

Bu modellerin 162 motordan oluşan eğitim veri kümesi üzerindeki tahmin performansı Tablo 4.6. ve Tablo 4.7.'de, mükemmel bir tahminin nasıl olması gerektiğine karşılık gerçek hayatta bizim modelimizin nasıl tahminler yürüttüğünü gösteren grafikler Tablo 4.8. ve Tablo 4.9.'da, modeller tarafından tahmin edilen kalan faydalı ömürlerin gerçek kalan faydalı ömürlerden ne kadar saptığı Tablo 4.10. ve Tablo 4.11.'de gösterilmiştir.

Tablo 4.6. ve Tablo 4.7.'de mavi renk ile gösterilen noktalar motorların gerçek kalan ömürlerini, sarı ile gösterilen noktalar kestirimci modellerimizin tahminlerini göstermektedir. Tablo 4.8. ve Tablo 4.9.'da x eksenini gerçek kalan ömürleri, y eksenini ise tahminleri göstermektedir. Algoritmalar mükemmel tahminler yapmış olsalardı grafiklerdeki tüm noktalar $x = y$ doğrusu üzerine yerleşmiş olurlardı. Fakat algoritmalarımız hatalar yapabildikleri için tahminler, ilgili doğru etrafına konuşlanmışlardır. Tablo 4.10. ve Tablo 4.11.'de gerçek değerler ile tahminler arasındaki sapmalar verilmiştir. Algoritmalar yine mükemmel tahminler yapmış


olsalardı grafiklerdeki tüm noktaların $y = 0$ doğrusu üzerinde olmaları gerekirdi. Bu grafiklerden çıkarılacak ortak sonuç, kalan ömür 0'a yaklaştıkça yapılan tahminlerin gerçek kalan faydalı ömre daha çok yaklaşması ve tahmin doğruluğunun artmasıdır. Çünkü uçuş sayısının artmasıyla birlikte makine öğrenmesi algoritmaları daha fazla veri ile eğitilir, ki bu da algoritmaların performansını artırır.

Eğitilen modellerin performansını ölçmek ve ne kadar hata ile çalıştığını belirlemek için maliyet fonksiyonu kullanılır. Çeşitli varyasyonları bulunan maliyet fonksiyonu, tahmin edilen değerler ile gerçek değerleri girdi olarak kullanır. Bu çalışma kapsamında, üç farklı maliyet fonksiyonu ile hata ölçümü yapılmış ve sonuçlar Tablo 4.5.'te sunulmuştur. Performansı iyi olan bir modelde, hesaplanan RMSE ve MAE değerlerinin küçük ve R-squared değerinin 1'e yakın olması beklenir. Performans düştükçe RMSE ve MAE değerleri büyür ve R-squared parametresinin değeri 0'a yaklaşır. Tablo 4.5. incelendiğinde tüm maliyet fonksiyonlarının sonuçlarının paralellik gösterdiği görülmektedir. Dolayısıyla modellerin performansını değerlendirmek için üç fonksiyondan herhangi birinden yararlanılabilir. Hassas Gauss DVM algoritmasının tüm kestirimci modeller arasında en kötü tahmin performansına sahip olduğu görülürken, Gauss Süreç Regresyonu ve Sinir Ağı algoritmalarının performanslarının genel olarak diğerlerinden yüksek olduğu görülmektedir. Kullanılan tüm kestirimci modeller içinde en yüksek tahmin performansına sahip olan model İki Katmanlı Sinir Ağı'dır.


Tablo 4.5. Eğitim İstatistikleri

Kullanılan Modeller		RMSE	R-Squared	MAE
Doğrusal Regresyon	Doğrusal Regresyon	43.88	0.59	34.07
	Etkileşimli DR	41.62	0.63	31.2
	Gülbüz DR	44.1	0.59	33.7
	Kademeli DR	41.6	0.63	31.2
Birleştirilmiş Karar Ağaçları	Torbalanmış Ağaçlar	40.8	0.65	29.8
	Güçlendirilmiş Ağaçlar	41.8	0.63	30.5
Regresyon Ağacı	Hassas Ağaç	53	0.4	38.6
	Ortalama Ağaç	47.3	0.52	34.4
	Kaba Ağaç	44.05	0.59	32.3
Destek Vektör Makinesi	Doğrusal DVM	44.4	0.58	33.6
	Kübik DVM	41.9	0.62	30.4
	İkinci Dereceden DVM	42.1	0.62	30.7
	Hassas Gauss DVM	56.2	0.33	44.9
	Ortalama Gauss DVM	40.9	0.64	29.4
	Kaba Gauss DVM	41.9	0.63	30.3
Gauss Süreç Regresyonu	Üstel GSR	40.3	0.65	29.3
	Rasyonel İkinci Dereceden GSR	40.3	0.65	29.4
	Karesel Üstel GSR	41	0.64	30.2
	Matern 5/2 GSR	40.5	0.65	29.6
Sinir Ağları	İki Katmanlı Sinir Ağı	40	0.66	29.1
	Üç Katmanlı Sinir Ağı	40.1	0.66	29.2
	Ortalama Sinir Ağı	40.3	0.65	29.5
	Dar Sinir Ağı	40.4	0.65	29.6
	Geniş Sinir Ağı	41.1	0.64	30.4


Tablo 4.6. Eğitim Setindeki Motorlar İçin Kalan Faydalı Ömür Tahminleri




Tablo 4.7. Eğitim Setindeki Motorlar İçin Kalan Faydalı Ömür Tahminleri



Tablo 4.8. Gerçek Kalan Faydalı Ömürler İle Tahmini Kalan Faydalı Ömürler Arasındaki İlişki




Tablo 4.9. Gerçek Kalan Faydalı Ömürler İle Tahmini Kalan Faydalı Ömürler Arasındaki İlişki



Tablo 4.10. Kestirim Hatası

Etkileşimli DR	Doğrusal Regresyon	Gürbüz DR
Kademeli DR	Torbalanmış Ağaçlar	Güçlendirilmiş Ağaçlar
Üstel GSR	matern 5/2 GSR	Rasyonel İkinci Dereceden GSR
Karesel Üstel GSR	İki Katmanlı Sinir Ağı	Üç Katmanlı Sinir Ağı


Tablo 4.11. Kestirim Hatası




Motor üzerine yerleştirilmiş sensörlerden her yeni veri geldiğinde, tahmin edilen RUL güncellenmektedir. Dolayısıyla her bir motor için motorun toplam uçuş sayısı kadar RUL tahmini yapılır. Yukarıda bahsedildiği gibi, 24 farklı algoritma ile 54 adet motorun kalan faydalı ömürleri tahmin edilmiştir. Bu da 1296 farklı sonucun elde edildiği anlamına gelmektedir. Elde edilen tüm sonuçlar, bu çalışmada sunulamayacak kadar fazla olduğu için rastgele bir motor seçilerek farklı algoritmalarla yapılan o motorlara ait tahmin sonuçları Tablo 4.12., Tablo 4.13. ve Tablo 4.14.'te görsel olarak sunulmuştur.

Grafiklerde "kırmızı" ile gösterilen noktaların birleşiminden oluşan doğru, 199 numaralı motorun gerçek kalan faydalı ömrüdür. Grafiklerden de anlaşılabileceği gibi her bir uçuştan sonra kalan faydalı ömür 1 eksilmektedir ve son uçuş gerçekleştiikten sonra kalan faydalı ömür "0" olmaktadır yani motor ömrünü tamamlamaktadır. "Mavi" ile gösterilen noktalar, ilgili makine öğrenmesi algoritmasının her bir uçuşta tahmin ettiği kalan faydalı ömür göstermektedir. Grafiklerde de görüldüğü üzere her bir uçuşta yeni bir RUL tahmini yapılmaktadır. Tahmin edilen değerler, doğrusal bir eğriye oturtularak mavi renkli doğru elde edilmiştir. Genel olarak bu doğrunun, gerçek Kalan Faydalı Ömür eğrisi ile benzerlik içinde olduğu fakat Doğrusal Regresyon ve Destek Vektör Makinesi algoritmalarının motorun ömrünün sonuna yaklaştıkça negatif RUL tahminleri yaptığı görülmektedir. Diğer algoritmaların, kalan faydalı ömür 0'a yaklaştıkça daha gerçekçi tahminler yaptığı ortadadır. Bunun sebebi, motorun ömrünün sonuna yaklaştıkça motordan toplanan verilerin sayısının artması olabilir. Makine öğrenmesi modelleri ne kadar çok veri ile eğitilirse performanları da o kadar artar.


Tablo 4.12. Doğrulama Setindeki 199 Numaralı Motor İçin Tahmin Edilen RUL İle Gerçek RUL Grafikleri



Tablo 4.13. Doğrulama Setindeki 199 Numaralı Motor İçin Tahmin Edilen RUL İle Gerçek RUL Grafikleri



Tablo 4.14. Doğrulama Setindeki 199 Numaralı Motor İçin Tahmin Edilen RUL İle Gerçek RUL Grafikleri



5. SONUÇLAR

Bölüm 4.5.'te eğitilen tüm makina öğrenmesi algoritmaları, 54 adet motora ait verilerden oluşan doğrulama setine uygulanmıştır. Bu veri kümesindeki motorların gerçek kalan faydalı ömürleri bilinmekte olduğu için yapılan tahminlerden yola çıkılarak her bir algoritma için maksimum pozitif hata, minimum negatif hata, MAE, RMSE ve standart sapma hesaplanmış ve sonuçlar Tablo 5.1.'de verilmiştir.

Tablo 5.2. her ne kadar görüntü olarak Tablo 5.1.'e benzese de daha farklı yorumlanır. Gerçek hayatta, uçuş sayısı "1" artınca motorun kalan faydalı ömrü "1" azalır. Yani x ekseninin Uçuş Sayısını ve y ekseninin Kalan Faydalı Ömrü gösterdiği bir koordinat sisteminde denklemi $y = -x+b$ olan bir eğri ortaya çıkar. Denklemdaki b , ilgili motorun toplam uçuş sayısıdır. Tablo 5.2.'deki hatalar hesaplanırken, her bir uçuşun sonunda tahmin edilen değerlerin üzerine eğimi "-1" olan bir eğri oturtulmuş ve bu eğrinin ekseni kestiği nokta ile b arasındaki fark hata olarak ölçülmüştür. Sırayla her bir uçuş için yeniden tahmin yapılmış ve yukarıda bahsedilen işlem tekrarlanmıştır. Her bir kestirimci model için elde edilen maksimum pozitif ve minimum negatif hatalar, MAE, RMSE ve standart sapması tabloda verilmiştir. Bu yöntemle, modelin performansından ziyade modelin kestirim tutarlılığı ölçülmek istenmiştir.

Hatanın pozitif olması, tahmin edilen RUL'un bilinen gerçek RUL'dan daha fazla olduğu anlamına gelmekte iken negatif hata ise yapılan tahminin gerçek RUL'dan daha küçük olduğu anlamına gelmektedir. Negatif hata durumunda, vaktinden daha erken bir bakım planlaması yapılmakta ve bu da hala kullanılabilir durumda olan motorun erkenden değiştirilmesi ya da onarılması sonucu maddi kayıplara sebep olmaktadır. Pozitif hata durumunda, ömrünün sonuna yaklaşmış olan motorun hala bir süre daha görev yapabilir durumda olduğu zannedilmekte ve bu sebeple daha ileri tarihler için bakım planlaması oluşturulmaktadır. Fakat uçuş anında oluşacak motor hasarlarının maddi kayıplardan da öte can kayıplarına ve itibar kaybına yol açması çok daha kritik bir problemdir. Bu sebeple, firmalar tarafından vaktinden geç yapılan tahminler yerine erken tahminler daha güvenilir bulunmaktadır.

Tablo 5.1. incelendiğinde, kalan faydalı ömrü tahmin etmede en yüksek performansların GSR ve Sinir Ağları algoritmalarına ait olduğu görülmektedir. Bu modeller, en az standart sapma ile gerçeğe en yakın ömür tahminini yaptığını göstermektedir. En düşük performansa sahip olan Hassas Gauss DVM algoritmasının diğer modellere göre standart sapmasının daha yüksek olmasının sebebi, motorun kalan faydalı ömrünün sonuna geldikçe modelin tahmin performansının kötüleşmesidir. Bu algoritma, küçük ölçekli çekirdek (kernel) fonksiyonu kullanır ve dolayısıyla esnek bir modeldir. Yani girdideki en küçük değişiklik, tahmin sonucunu etkiler. Bu durum, aşırı uyumlanmaya (overfit) yol açar. Bu sebeple Hassas Gauss DVM algoritmasının performansı kötüdür. Tabloda benzer şekilde, Hassas Ağaç algoritmasının da performansının düşük olduğu görülmektedir. Bu algoritmanın yaprak boyutu küçük ve dal sayısı fazladır. Bu karmaşık ağacın varyansı büyüktür. Bu da modelin esnek olmasına ve dolayısıyla aşırı uyumlanmaya sebebiyet verir. Ezberlemeye meyilli algoritmalar, tanımadığı veri kümesi üzerinde kötü performans gösterirler. Tablo 5.1., bu bilgileri desteklemektedir. Tablo 5.2.'deki sonuçların Tablo 5.1. ile benzer olduğu görülmektedir. GSR ve Sinir Ağları algoritmaları, diğer algoritmalara göre daha tutarlı tahminler yapmaktadır. Hassas Gauss DVM algoritması ise en büyük standart sapmaya sahip olan model olarak oldukça tutarsız tahminler yaptığını göstermektedir.

Çalışmanın bu kısmında şöyle bir iyileştirme yapılabilir: Motorun ömrünü olduğundan fazla tahmin etmek, iş gücü ve vakit kaybından da öte can kaybına sebebiyet verebileceği için geç tahminden ziyade erken tahminde bulunmanın tercih edilen bir davranış olduğundan bahsedilmiştir. Bu sebeple bir güvenlik önlemi olarak, kalan faydalı ömürleri hesaplamak istenen motorların tahmin edilen kalan faydalı ömürleri, belli bir güvenlik katsayısı ile çarpılarak tahmin edilen RUL'lar bir miktar küçültülebilir ve böylece geç tahminlerin önüne geçilebilir. Bu davranış, motorun kalan faydalı ömrünü biraz kısaltarak motora gereğinden erken bakım yapılması dolayısıyla hem gereksiz bakım maliyetine sebep olup hem de makinanın verimli şekilde kullanıldığı süreyi azaltsa da, geç tahminin sebep olduğu çok daha büyük kayıpları engellemeye yardımcı olur.

Tablo 5.1. Hata Tablosu

Kullanılan Modeller		Max.Pos.	Min.Neg.	MAE	RMSE	SD
Doğrusal Regresyon	Doğrusal Regresyon	117	-179	34.2	41.9	32.1
	Etkileşimli DR	143	-176	31.6	39.2	29.1
	Gülbüz DR	110	-184	33.8	41.9	32.2
	Kademeli DR	139	-177	31.6	39.2	28.9
Birleştirilmiş Karar Ağaçları	Torbalanmış Ağaçlar	141	-170	30	38.7	29.6
	Güçlendirilmiş Ağaçlar	115	-190	30.5	39.3	30.5
Regresyon Ağaçları	Hassas Ağaç	190	-221	38.8	51.9	44.7
	Ortalama Ağaç	178	-219	34.8	46.1	38.3
	Kaba Ağaç	149	-202	32.5	42.4	34.1
Destek Vektör Makinesi	Doğrusal DVM	107	-185	33.8	42.1	32.2
	Kübik DVM	149	-194	30.8	39.3	28.8
	İkinci Dereceden DVM	135	-185	31.2	39.5	28.9
	Hassas Gauss DVM	136	-193	42.9	52.1	46.7
	Ortalama Gauss DVM	142	-183	29.8	38.5	28.9
	Kaba Gauss DVM	133	-185	30.7	39.3	28.9
Gauss Süreç Regresyonu	Üstel GSR	134	-167	29.6	38	28.6
	Rasyonel İkinci Dereceden GSR	133	-170	29.7	37.9	28.5
	Karesel Üstel GSR	130	-174	30.5	38.5	28.6
	Matern 5/2 GSR	130	-170	29.8	38.1	28.4
Sinir Ağları	İki Katmanlı SA	149	-174	29.6	38.1	28.8
	Üç Katmanlı SA	144	-166	29.7	38.1	28.8
	Ortalama SA	143	-170	30	38.2	28.6
	Dar SA	140	-169	30.3	38.5	29.1
	Geniş SA	160	-181	30.7	39.2	29.8

Tablo 5.2. Deste Kestirim Tutarlılığı Tablosu

Kullanılan Modeller		Max.Pos.	Min.Neg.	MAE	RMSE	SD
Doğrusal Regresyon	Doğrusal Regresyon	62	-165	39.5	44.1	20.2
	Etkileşimli DR	72	-162	38.2	42.1	18.2
	Gülbüz DR	57	-169	41.1	45.7	20.4
	Kademeli DR	72	-162	38.1	42.1	18.2
Birleştirilmiş Karar Ağaçları	Torbalanmış Ağaçlar	64	-157	36.1	40.2	17.9
	Güçlendirilmiş Ağaçlar	54	-165	38.8	43.1	19.4
Regresyon Ağaçları	Hassas Ağaç	81	-221	36.5	40.7	18.1
	Ortalama Ağaç	61	-208	36.5	40.6	18.3
	Kaba Ağaç	64	-167	36.6	40.7	18.3
Destek Vektör Makinesi	Doğrusal DVM	54	-173	42.4	46.9	20.4
	Kübik DVM	69	-168	40	43.7	17.7
	İkinci Dereceden DVM	68	-169	41.1	44.9	18.1
	Hassas Gauss DVM	43	-186	44.9	50.5	24.5
	Ortalama Gauss DVM	65	-161	37.8	41.6	17.4
	Kaba Gauss DVM	66	-169	40.3	44.2	18.1
Gauss Süreç Regresyonu	Üstel GSR	66	-154	36.1	40.1	17.6
	Rasyonel İkinci Dereceden GSR	66	-156	36.2	40.2	17.6
	Karesel Üstel GSR	68	-160	37.1	41	18.1
	Matern 5/2 GSR	67	-157	36.4	40.4	17.7
Sinir Ağları	İki Katmanlı SA	67	-157	36.1	40	17.3
	Üç Katmanlı SA	68	-159	36	39.9	17.3
	Ortalama SA	70	-155	36.3	40.2	17.3
	Dar SA	69	-157	36.5	40.4	17.4
	Geniş SA	69	-158	36.4	40.2	17.2

Tez çalışması kapsamında, kestirimci bakım yaklaşımından faydalanılarak kalan faydalı ömrü tahmin etme ve buna bağlı olarak bakım planlaması yapılması üzerine detaylı bir çalışma sunulmuştur. Kalan faydalı ömrü tahmin etmek için regresyon yöntemine başvurulmuştur. Bu kapsamda, 6 farklı regresyon algoritması ve bu algoritmaların çeşitli versiyonları da dahil olmak üzere toplam 24 adet makina öğrenmesi algoritması kullanılmıştır. Bunu yaparken iki farklı programlama yazılımından yararlanılmıştır. Veri kümesi üzerindeki ön işlemler için RStudio; temel bileşen analizi, verilerin eğitilmesi ve modellerin başka veriler üzerinde doğrulanması için MATLAB'ın araç kutularından biri olan Predictive Maintenance Tool-box'a ait olan Regression Learner uygulaması kullanılmıştır.

Kullanılan veri kümesi, endüstride başka alanlarda da kullanılan motorlardan edinilebilecek bilgileri içermektedir. Yani bu veri kümesi ile yapılan RUL hesaplama ve bakım takvimi oluşturma çalışması, kestirimci bakımın benimsendiği benzer alanlara da adapte edilebilir ve yukarıda bahsedilen güvenlik katsayısı uygulaması, kritik öneme sahip sistemler için devreye alınabilir.

Motorların arızalanmasına kadar geçen tüm süre zarfında, motor üzerindeki bir çok sensörden veri toplanması, uygulamada zor bir işlem olduğu için bu çalışma kapsamında simülasyon verileri kullanılmıştır. Tez çalışmasının devamında, gerçek benzer sistemlerden veri toplanabilir ve bu sistemler üzerinde bu çalışmada elde edilen sonuçlardan da yararlanarak kestirimci bakım ışığında kalan faydalı ömür tahminleri gerçekleştirilebilir. Uçak motorları için gerçek verileri toplama ve kullanabilme evresine gelmek biraz zaman alabilecek bir işlem olduğu için ilk etapta veri toplamanın kolay olduğu alanlardan işe başlanabilir. Örneğin günlük hayatta sıkça kullanılan ve hayatı kolaylaştıran beyaz eşyalardan çeşitli sensör verileri toplanabilir ve arızaya kalan süre hesap edilerek beklenmedik arızaların önüne geçilebilir. Böylece günlük hayatın temposunda yapılan düzenli bakımlar ile makinelerin kullanımına sorunsuz devam edilir. Bu uygulama, hem evlerde hem de bu makinelerin kullanıldığı fabrikadaki olumsuzlukları ortadan kaldırmada oldukça faydalı olur. Uçak motorlarına veya beyaz eşyalara yerleştirilen sensörlerden toplanan verilerden meydana gelen veri kümesi, tezde kullanılan veri kümesine yapı olarak benzer. Bu çalışmada veri kümesine uygulanan tüm ön

işlemler, temel bileşen analizi ve verilerin eğitilmesi gibi işlemler, gerçek makinelere de rahatlıkla uyarlanabilir.



EK A : EĞİTİM PARAMETRELERİ

Bu bölümde, kestirimci algoritmaların eğitiminde kullanılan hiper parametreler ve eğitim süreleri verilmiştir.

Geniş Sinir Ağı: Katman Boyutu: 100, Aktivasyon Fonksiyonu: ReLU

Ortalama Sinir Ağı: Katman Boyutu: 25, Aktivasyon Fonksiyonu: ReLU

Dar Sinir Ağı: Katman Boyutu: 10, Aktivasyon Fonksiyonu: ReLU

İki Katmanlı Sinir Ağı: Katman Boyutu: [10, 10], Aktivasyon Fonksiyonu: ReLU

Üç Katmanlı Sinir Ağı: Katman Boyutu: [10, 10, 10], Aktivasyon Fonksiyonu: ReLU

Doğrusal DVM: Kernel Fonksiyonu: Doğrusal, Kernel Ölçeği: 3,9709

İkinci Dereceden DVM: Kernel Fonksiyonu: Polinom, Kernel Ölçeği: 3,9911, Derece: 2

Kübik DVM: Kernel Fonksiyonu: Polinom, Kernel Ölçeği: 3,9543, Derece: 3

Hassas Gauss DVM: Kernel fonksiyonu: Gauss, Kernel Ölçeği : 1

Ortalama Gauss DVM: Kernel Fonksiyonu: Gauss, Kernel Ölçeği: 4

Kaba Gauss DVM: Kernel Fonksiyonu: Gauss, Kernel Ölçeği: 16

Üstel GSR: Kernel Fonksiyonu: Üstel

Karesel Üstel GSR: Kernel Fonksiyonu: Karesel Üstel

Rasyonel İkinci Dereceden GSR: Kernel Fonksiyonu: Rasyonel İkinci Dereceden

Matern 5/2 GSR: Kernel Fonksiyonu: Matern52

Hassas Ağaç: Düğüm sayısı: 11077

Ortalama Ağaç: Düğüm sayısı: 4351

Kaba Ağaç: Düğüm sayısı: 1449

Doğrusal Regresyon Algoritması Eğitim Süresi: 1.98 sn

Etkileşimli DR Algoritması Eğitim Süresi: 6.7 sn

Gülbüz DR Algoritması Eğitim Süresi: 3.1 sn

Kademeli DR Algoritması Eğitim Süresi: 3314.7 sn

Torbalanmış Ağaçlar Algoritması Eğitim Süresi: 16.2 sn

Güçlendirilmiş Ağaçlar Algoritması Eğitim Süresi: 9.5 sn

Hassas Ağaç Algoritması Eğitim Süresi: 9.9 sn
Ortalama Ağaç Algoritması Eğitim Süresi: 2.4 sn
Kaba Ağaç Algoritması Eğitim Süresi: 1.3 sn
Doğrusal DVM Algoritması Eğitim Süresi: 130.6 sn
Kübik DVM Algoritması Eğitim Süresi: 920.5 sn
İkinci Dereceden DVM Algoritması Eğitim Süresi: 294.3 sn
Hassas Gauss DVM Algoritması Eğitim Süresi: 294.8 sn
Ortalama Gauss DVM Algoritması Eğitim Süresi: 163.8 sn
Üstel GSR Algoritması Eğitim Süresi: 1094.2 sn
Rasyonel İkinci Dereceden GSR Algoritması Eğitim Süresi: 1432.9 sn
Karesel Üstel GSR Algoritması Eğitim Süresi: 843.4 sn
Matern 5/2 GSR Algoritması Eğitim Süresi: 1111.6 sn
İki Katmanlı Sinir Ağı Algoritması Eğitim Süresi: 77 sn
Üç Katmanlı Sinir Ağı Algoritması Eğitim Süresi: 112.8 sn
Ortalama Sinir Ağı Algoritması Eğitim Süresi: 84.1 sn
Dar Sinir Ağı Algoritması Eğitim Süresi: 48.2 sn
Geniş Sinir Ağı Algoritması Eğitim Süresi: 279.5 sn

KAYNAKLAR

- [1] Bart van den Corput. Maximise profit with predictive maintenance of critical equipment. <https://www.ixon.cloud/knowledge-hub/predictive-maintenance-critical-equipment>. Erişim Tarihi: **31 Aralık 2021**.
- [2] Radim Rehurek. Practical data science in python. https://radimrehurek.com/data_science_python/. Erişim Tarihi: **31 Aralık 2021**.
- [3] Mihriban Tekeş. Makine Öğrenmesi: Denetimli (supervised) eğitim ve denetimsiz (unsupervised) eğitim. <https://mihribantekes.medium.com/makine-%C3%B6%C4%9Frenmesi-denetimli-supervised-e%C4%9Fitim-ve-denetimsiz-unsupervised-e%C4%9Fitim-5e3730354a5b>. Erişim Tarihi: **31 Aralık 2021**.
- [4] Chieh-Feng Cheng. Reinforcement learning - inwinstack: Technical blog. https://www.inwinstack.com/blog-en/blog_ai-en/6262/. Erişim Tarihi: **31 Aralık 2021**.
- [5] Akshay Singhal. Linear regression machine learning. <https://www.gatevidyalay.com/linear-regression-machine-learning-examples/>. Erişim Tarihi: **31 Aralık 2021**.
- [6] Eligijus Bujokas. Regression tree in python from scratch. <https://towardsdatascience.com/regression-tree-in-python-from-scratch-9b7b64c815e3>. Erişim Tarihi: **31 Aralık 2021**.
- [7] Rukshan Pramoditha. Random forests — an ensemble of decision trees. <https://towardsdatascience.com/random-forests-an-ensemble-of-decision-trees-37a003084c6c>. Erişim Tarihi: **31 Aralık 2021**.

- [8] Ju Yoon, Nguyen Minh Nhat, Hyun Lee, Jang Youn, Dang Kim, Dong Lee, and Kyoung Kwan Ahn. Optimization of design parameters of a eppr valve solenoid using artificial neural network. *Journal of Drive and Control*, 13:34–41, **2016**. doi:10.7839/ksfc.2016.13.2.034.
- [9] Subhasish Basak. Introduction to gaussian process regression (gpr). <https://subhasish-basak-c-94990.medium.com/introduction-to-gaussian-process-regression-gpr-b6c40f6ef6f9>. Eriřim Tarihi: **31 Aralık 2021**.
- [10] Beny Maulana Achsan. Support vector machine: Regression. <https://medium.com/it-paragon/support-vector-machine-regression-cf65348b6345>. Eriřim Tarihi: **31 Aralık 2021**.
- [11] Abhinav Saxena, Kai Goebel, Don Simon, and Neil Eklund. Damage propagation modeling for aircraft engine run-to-failure simulation. *International Conference on Prognostics and Health Management*, **2008**. doi:10.1109/PHM.2008.4711414.
- [12] Cynthia Barnhart, Peter Belobaba, and Amedeo R. Odoni. Applications of operations research in the air transport industry. *Transp. Sci.*, 37:368–391, **2003**.
- [13] Kim-Anh Nguyen, Phuc DO, and Antoine Grall. Multi-level predictive maintenance for multi-component systems. *Reliability Engineering [?] System Safety*, 144, **2015**. doi:10.1016/j.ress.2015.07.017.
- [14] Jinjiang Wang, Laibin Zhang, Lixiang Duan, and Robert Gao. A new paradigm of cloud-based predictive maintenance for intelligent manufacturing. *Journal of Intelligent Manufacturing*, 28:1125–1137, **2017**. doi:10.1007/s10845-015-1066-0.
- [15] Jay Lee, Fangji Wu, Wenyu Zhao, Mahsa Ghaffari, Linxia Liao, and David Siegel. Prognostics and health management design for rotary machinery systems—reviews, methodology and applications. *Mechanical Systems and Signal Processing*, 42:314–334, **2014**. doi:10.1016/j.ymssp.2013.06.004.

- [16] Klaus Schadow, Wolfgang Horn, and Hugo Pfoertner. Sensor and actuator needs for more intelligent gas turbine engines. **2010**. doi:10.1115/GT2010-22685.
- [17] Hongzhi Xu, Dongxiang Jiang, and Lei Liang. Application of fuzzy-rough set theory and improved smo algorithm in aircraft engine vibration fault diagnosis. In *Proceedings of the IEEE 2012 Prognostics and System Health Management Conference (PHM-2012 Beijing)*, pages 1–6. **2012**. doi:10.1109/PHM.2012.6228890.
- [18] Alireza Ahmadi, Torbjorn Fransson, Anneli Crona, Markus Klein, and Peter Soderholm. Integration of rcm and phm for the next generation of aircraft. In *2009 IEEE Aerospace conference*, pages 1–9. **2009**. doi:10.1109/AERO.2009.4839684.
- [19] Bo Sun, Shengkui Zeng, Rui Kang, and Michael Pecht. Benefits and challenges of system prognostics. *IEEE Transactions on Reliability - TR*, 61:323–335, **2012**. doi:10.1109/TR.2012.2194173.
- [20] A. Saxena and K. Goebel. Prognostics center of excellence - data repository. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>. Erişim Tarihi: **31 Aralık 2021**.
- [21] U. Simidu. *An introduction to predictive microbiology*, volume 42. **2001**. ISBN 0750675314.
- [22] Peter Tse and Kwok-Leung Tsui. An enhanced kurtogram method for fault diagnosis of rolling element bearings. *Mechanical Systems and Signal Processing*, 35:176–199, **2013**. doi:10.1016/j.ymssp.2012.10.003.
- [23] Shun-Peng Zhu, Hong-Zhong Huang, Yanfeng Li, Yu Liu, and Yuan-Jian Yang. Probabilistic modeling of damage accumulation for time-dependent fatigue reliability analysis of railway axle steels. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 229:23–33, **2013**. doi:10.1177/0954409713496772.

- [24] Kwok-Leung Tsui. Brownian motion with adaptive drift for remaining useful life prediction: Revisited. *Mechanical Systems and Signal Processing*, 99, **2018**. doi: 10.1016/j.ymssp.2017.07.015.
- [25] Shun-Peng Zhu, Hong-Zhong Huang, Peng Weiwen, Hai-Kun Wang, and Sankaran Mahadevan. Probabilistic physics of failure-based framework for fatigue life prediction of aircraft gas turbine discs under uncertainty. *Reliability Engineering System Safety*, 146:1–12, **2016**. doi:10.1016/j.ress.2015.10.002.
- [26] Shun-Peng Zhu, Yuan-Jian Yang, Hong-Zhong Huang, Zhiqiang Lv, and Hai-Kun Wang. A unified criterion for fatigue–creep life prediction of high temperature components. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 231(4):677–688, **2017**. doi: 10.1177/0954410016641448.
- [27] Zheng-Yong Yu, Shun-Peng Zhu, Qiang Liu, and Yunhan Liu. A new energy-critical plane damage parameter for multiaxial fatigue life prediction of turbine blades. *Materials*, 10, **2017**. doi:10.3390/ma10050513.
- [28] Shilong Sun and Peter Tse. A general sequential monte carlo method based optimal wavelet filter: A bayesian approach for extracting bearing fault features. *Mechanical Systems and Signal Processing*, 52-53, **2014**. doi:10.1016/j.ymssp.2014.07.005.
- [29] Dong Wang, Kwok-Leung Tsui, and Qiang Miao. Prognostics and health management: A review of vibration based bearing and gear health indicators. *IEEE Access*, 6:665–676, **2018**. doi:10.1109/ACCESS.2017.2774261.
- [30] Dong Wang, Peter W Tse, Wei Guo, and Qiang Miao. Support vector data description for fusion of multiple health indicators for enhancing gearbox fault diagnosis and prognosis. *Measurement Science and Technology*, 22(2):025102, **2010**. doi:10.1088/0957-0233/22/2/025102.

- [31] Weiwen Peng, Yan-Feng Li, Yuan-Jian Yang, Shun-Peng Zhu, and Hong-Zhong Huang. Bivariate analysis of incomplete degradation observations based on inverse gaussian processes and copulas. *IEEE Transactions on Reliability*, 65(2):624–639, **2016**. doi:10.1109/TR.2015.2513038.
- [32] Weiwen Peng, Yan-Feng Li, Yuan-Jian Yang, Jinhua Mi, and Hong-Zhong Huang. Bayesian degradation analysis with inverse gaussian process models under time-varying degradation rates. *IEEE Transactions on Reliability*, 66(1):84–96, **2017**. doi:10.1109/TR.2016.2635149.
- [33] Weiwen Peng, Lijuan Shen, Yan Shen, and Qiuzhuang Sun. Reliability analysis of repairable systems with recurrent misuse-induced failures and normal-operation failures. *Reliability Engineering System Safety*, 171:87–98, **2018**. ISSN 0951-8320. doi:https://doi.org/10.1016/j.ress.2017.11.016.
- [34] G. Sateesh Babu, Peilin Zhao, and Xiaoli Li. Deep convolutional neural network based regression approach for estimation of remaining useful life. In *DASFAA*. **2016**.
- [35] Gian Antonio Susto, Andrea Schirru, Simone Pampuri, Sean Mcloone, and Alessandro Beghi. Machine learning for predictive maintenance: A multiple classifier approach. *Industrial Informatics, IEEE Transactions on*, 11:812–820, **2015**. doi:10.1109/TII.2014.2349359.
- [36] G. Kacprzynski, A. Sarlashkar, M. Roemer, Andrew Hess, and B. Hardman. Predicting remaining life by fusing the physics of failure modeling with diagnostics. *JOM: the journal of the Minerals, Metals Materials Society*, 56:29–35, **2004**. doi:10.1007/s11837-004-0029-2.
- [37] James Li and Hyungdae Lee. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics. *Mechanical Systems and Signal Processing*, 19:836–846, **2005**. doi:10.1016/j.ymssp.2004.06.007.

- [38] Shun-Peng Zhu, Hong-Zhong Huang, Li-Ping He, Yu Liu, and Zhonglai Wang. A generalized energy-based fatigue–creep damage parameter for life prediction of turbine disk alloys. *Engineering Fracture Mechanics*, 90:89–100, **2012**. doi: 10.1016/j.engfracmech.2012.04.021.
- [39] Xian-Cheng Zhang, Shan-Tung Tu, Shun-Peng Zhu, and Cheng-cheng Zhang. A modified strain energy density exhaustion model for creep-fatigue life prediction. *International Journal of Fatigue*, 90, **2016**. doi:10.1016/j.ijfatigue.2016.03.005.
- [40] S.P. Zhu, S. Foletti, and S. Beretta. Probabilistic framework for multiaxial lcf assessment under material variability. *International Journal of Fatigue*, 103:371–385, **2017**. ISSN 0142-1123. doi:https://doi.org/10.1016/j.ijfatigue.2017.06.019.
- [41] Farzaneh Ahmadzadeh and Jan Lundberg. Remaining useful life estimation: review. *International Journal of System Assurance Engineering and Management*, 5, **2013**. doi:10.1007/s13198-013-0195-0.
- [42] Enrico Zio and Francesco Di Maio. A data-driven fuzzy approach for predicting the remaining useful life in dynamic failure scenarios of a nuclear power plant. *Reliability Engineering System Safety*, 95:49–57, **2010**. doi: 10.1016/j.ress.2009.08.001.
- [43] Leonardo Rodrigues, Joao Paulo Gomes, Felipe Ferri, Ivo de Medeiros, Roberto Galvao, and Cairo Nascimento Jr. Use of phm information and system architecture for optimized aircraft maintenance planning. *IEEE Systems Journal*, 9:1–11, **2014**. doi:10.1109/JSYST.2014.2343752.
- [44] Wlamir Vianna and Takashi Yoneyama. Predictive maintenance optimization for aircraft redundant systems subjected to multiple wear profiles. *IEEE Systems Journal*, PP:1–12, **2017**. doi:10.1109/JSYST.2017.2667232.
- [45] Stephen Adams, Ryan Meekins, Peter Beling, Kevin Farinholt, Nathan Brown, Sherwood Polter, and Qing Dong. A comparison of feature selection and feature extraction techniques for condition monitoring of a hydraulic actuator. **2018**.

- [46] Liu X. Zhang B. Zhang G. Niu G. Hu C. Zhao, G. Bearing health condition prediction using deep belief network. **2017**.
- [47] Sepideh Pourazarm and Daniel Nikovski. Fault detection and prognosis of time series data with random projection filter bank. **2017**.
- [48] N. Gebraeel, M. Lawley, R. Liu, and V. Parmeshwaran. Residual life predictions from vibration-based degradation signals: a neural network approach. *IEEE Transactions on Industrial Electronics*, 51(3):694–700, **2004**. doi:10.1109/TIE.2004.824875.
- [49] Runqing Huang, Lifeng Xi, Xinglin Li, C. Richard Liu, Hai Qiu, and Jay Lee. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods. *Mechanical Systems and Signal Processing*, 21(1):193–207, **2007**. ISSN 0888-3270. doi:https://doi.org/10.1016/j.ymssp.2005.11.008.
- [50] Jaouher Ben Ali, Brigitte Chebel-Morello, Lotfi Saidi, Simon Malinowski, and Farhat Fnaiech. Accurate bearing remaining useful life prediction based on weibull distribution and artificial neural network. *Mechanical Systems and Signal Processing*, 56, **2015**. doi:10.1016/j.ymssp.2014.10.014.
- [51] Ali Al-Dulaimi, Soheil Zabihi, A. Asif, and Arash Mohammadi. A multimodal and hybrid deep neural network model for remaining useful life estimation. *Comput. Ind.*, 108:186–196, **2019**.
- [52] Long Wen, Yan Dong, and Liang Gao. A new ensemble residual convolutional neural network for remaining useful life estimation. *Mathematical Biosciences and Engineering*, 16(2):862–880, **2019**. ISSN 15510018. doi:10.3934/mbe.2019040.
- [53] Xiang Li, Qian Ding, and J. Q. Sun. Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering System Safety*, 172, **2017**. doi:10.1016/j.ress.2017.11.021.

- [54] R. J. Hansen, D. L. Hall, and S. K. Kurtz. A New Approach to the Challenge of Machinery Prognostics. *Journal of Engineering for Gas Turbines and Power*, 117(2):320–325, **1995**. ISSN 0742-4795. doi:10.1115/1.2814097.
- [55] Xiong Xinxin, Li Qing, and Cheng Nong. Remaining useful life prognostics of aircraft engine based on fusion algorithm. In *2016 IEEE Chinese Guidance, Navigation and Control Conference (CGNCC)*, pages 628–633. **2016**. doi:10.1109/CGNCC.2016.7828859.
- [56] Paulino Jose Garcia Nieto, E. García-Gonzalo, Fernando Sánchez-Lasheras, and Francisco de Cos Juez. 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, **2015**. doi:10.1016/j.res.2015.02.001.
- [57] Lotfi Saidi, Jaouher Ben Ali, Eric Bechhoefer, and Mohamed Benbouzid. Wind turbine high-speed shaft bearings health prognosis through a spectral kurtosis-derived indices and svr. *Applied Acoustics*, 120:1–8, **2017**. doi:10.1016/j.apacoust.2017.01.005.
- [58] Celestino Ordóñez, Fernando Sánchez-Lasheras, Javier Roca, and Francisco de Cos Juez. A hybrid arima–svm model for the study of the remaining useful life of aircraft engines. *Journal of Computational and Applied Mathematics*, 346:184–191, **2019**. doi:10.1016/j.cam.2018.07.008.
- [59] Zhongzhe Chen, Shuchen Cao, and Zijian Mao. Remaining useful life estimation of aircraft engines using a modified similarity and supporting vector machine (svm) approach. *Energies*, 11:28, **2017**.
- [60] R. Konieczny and R. Idczak. Mössbauer study of Fe-Re alloys prepared by mechanical alloying. *Hyperfine Interactions*, 237(1):1–8, **2016**. ISSN 15729540. doi:10.1007/s10751-016-1232-6.
- [61] Qiong Liu and Ying Wu. Encyclopedia of the Sciences of Learning. *Encyclopedia of the Sciences of Learning*, (April), **2012**. doi:10.1007/978-1-4419-1428-6.

- [62] Vladimir Nasteski. An overview of the supervised machine learning methods. *Horizons.B*, 4(December 2017):51–62, **2017**. ISSN 18578578. doi:10.20544/horizons.b.04.1.17.p05.
- [63] Lior Rokach and Oded Maimon. *Data Mining with Decision Trees, Theory and Applications, 2nd Edition*. World Scientific Publishing Co. Pte. Ltd., **2015**.
- [64] Xindong Wu, Vipin Kumar, Quinlan J. Ross, Joydeep Ghosh, Qiang Yang, Hiroshi Motoda, Geoffrey J. McLachlan, Angus Ng, Bing Liu, Philip S. Yu, Zhi Hua Zhou, Michael Steinbach, David J. Hand, and Dan Steinberg. *Top 10 algorithms in data mining*, volume 14. **2008**. ISBN 1011500701. doi:10.1007/s10115-007-0114-2.
- [65] Trevor Hastie, Robert Tibshirani, Gareth James, and Daniela Witten. An Introduction to Statistical Learning (2nd Edition). *Springer Texts*, 102:618, **2021**. ISSN 01621459.
- [66] Wei-Yin Loh and Yu-shan Shih. Split selection methods for classification trees. *Stat Sinica*, 7, **1999**.
- [67] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, **1943**. ISSN 1522-9602. doi:10.1007/BF02478259.
- [68] J J Hopfield. Neural networks and physical systems with emergent collective computational abilities *Biophysics : Hopfield I T ., V .* 79(April):2554–2558, **1982**.
- [69] V. Vapnik. *The Nature of Statistical Learning Theory*. **1995**.
- [70] Christ. C.; Kaufman Linda; Smola Alexander J.; Drucker, Harris; Burges and Vladimir N. Vapnik. *Support Vector Regression Machines*. **1997**.