

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SİVİL HAVACILIK ANABİLİM DALI**

**İSTATİSTİKSEL TAHMİN YÖNTEMLERİ İLE UÇAK
MOTOR SAĞLIK DURUMUNUN İZLENMESİ**

**Hazırlayan
Alperen Mehmet SEVİNÇ**

**Danışman
Dr. Öğr. Üyesi Mustagime Tülin YILDIRIM**

Yüksek Lisans Tezi

**Ocak 2021
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SİVİL HAVACILIK ANABİLİM DALI**

**İSTATİSTİKSEL TAHMİN YÖNTEMLERİ İLE UÇAK
MOTOR SAĞLIK DURUMUNUN İZLENMESİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Alperen Mehmet SEVİNÇ**

**Danışman
Dr. Öğr. Üyesi Mustagime Tülin YILDIRIM**

**Ocak 2021
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Alperen Mehmet SEVİNÇ



İstatistiksel tahmin yöntemleri ile uçak motor sağlık durumunun izlenmesi adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan

Alperen Mehmet SEVİNÇ

Danışman

Dr. Öğretim Üyesi Mustagime Tülin YILDIRIM

Sivil Havacılık ABD Başkanı

Prof. Dr. İlke TÜRKMEN

Dr. Öğretim Üyesi Mustagime Tülin YILDIRIM danışmanlığında **Alperen Mehmet SEVİNÇ** tarafından hazırlanan “**İstatistiksel Tahmin Yöntemleri İle Uçak Motor Sağlık Durumunun İzlenmesi**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Sivil Havacılık Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

..... / /

JÜRİ:

Danışman : Dr. Öğretim Üyesi Mustagime Tülin YILDIRIM.....

Üye :

Üye :

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun tarih ve sayılı kararı ile onaylanmıştır.

..... / /

Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

TEŞEKKÜR

Çalışmalarım boyunca farklı bakış açıları ve bilimsel katkılarıyla beni aydınlatan, yakın ilgi ve yardımlarını esirgemeyen ve bu günlere gelmemde en büyük katkı sahibi sayın hocam Dr. Öğretim Üyesi Mustagime Tülin YILDIRIM'a teşekkürü bir borç bilirim.

Ayrıca; çalışmalarım süresince sabır göstererek beni daima destekleyen aileme en içten teşekkürlerimi sunarım.

Alperen Mehmet SEVİNÇ

Kayseri, Ocak 2021

İSTATİSTİKSEL TAHMİN YÖNTEMLERİ İLE UÇAK MOTOR SAĞLIK DURUMUNUN İZLENMESİ

Alperen Mehmet SEVİNÇ

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Ocak 2021

Danışman: Dr. Öğretim Üyesi Mustagime Tülin YILDIRIM

ÖZET

Havacılıkta hava aracı motor bakımında pratikte uygulanan ve literatürde hala geliştirilmeye devam edilen çok sayıda hava aracı motoru performans analizi yöntemi bulunmaktadır. Hava aracı motor performans analizi sonucuna bağlı olarak hava araçlarının motorlarının sağlığına karar verilebilmektedir. Bakım uygulamalarında uçuş sonrası bakım esnasında motor performans analizi yapılabildiği gibi günümüzde uçuş esnasında hava aracından yere iletilen verilerle de performans analizleri yapılabilmekte, arıza uyarısı üretilmektedir. Bu tez çalışmasında hava aracı motoru sağlığı izleme yöntemleri araştırılmış; kalan faydalı ömür tahmini ve tahmine dayalı bakım yöntemleri ile ilgili çalışmalar incelenmiş; uçak performans parametreleri ile motora ait bir parametre olan N1 parametresi arasındaki ilişkiler ele alınarak N1 parametresinin motor sağlığı izleme üzerindeki etkisi incelenmiştir. Uçuş performans parametreleri ile N1 parametresi arasındaki ilişki incelenirken korelasyon analizi ve çoklu regresyon analizi yöntemlerinden yararlanılmıştır. N1 parametresi ile ilgili olan veriler kullanılarak uçak motoru sağlık durumunu incelemek üzere eğitim yapılmış, ardından eğitim algoritmalarının başarımları değerlendirilmiştir. Literatürden görülebildiği kadarı ile N1 parametresi kullanılarak uçak motor sağlığı izleme üzerine daha önce yapılan çalışma bulunmadığından bu tez çalışması ile bu alanda bulunan bir boşluk daha doldurulmuş bulunmaktadır. Tez çalışmasından elde edilen sonuçlar bu çalışmanın emniyetli uçuşun sağlanmasına ve bakım maliyetlerinin azaltılmasına katkı sağlamak amacıyla kullanılabileceğini göstermektedir.

AIRCRAFT ENGINE HEALTH MONITORING VIA STATISTICAL ESTIMATION METHODS

Alperen Mehmet SEVİNÇ

Erciyes University, Graduate School of Natural and Applied Sciences

Master Thesis, January 2021

Supervisor: Asst. Prof. Mustagime Tülin YILDIRIM

ABSTRACT

There are many aircraft engine performance analysis methods that are practically applied in aircraft engine maintenance in aviation and are still being developed in the literature. Depending on the aircraft engine performance analysis result, mechanics decide the aircraft engine health conditions. In maintenance applications, engine performance analysis can be performed during post-flight maintenance, as well as performance analysis can be made with the data transmitted from the aircraft to the ground during the flight, and malfunction alerts are generated. In this thesis, aircraft engine health monitoring methods have been investigated; Studies on remaining useful life estimation and predictive maintenance methods were examined; The relationship between aircraft performance parameters and the N1 parameter, which is an engine parameter, was examined and the effect of the N1 parameter on engine health monitoring was examined. Correlation analysis and multiple regression analysis methods were used to examine the relationship between flight performance parameters and the N1 parameter. Using the data related to the N1 parameter, training was conducted to examine the aircraft engine health status, and then the performance of the training algorithms was evaluated. As far as it can be seen from the literature, since there is no previous study on aircraft engine health monitoring using the N1 parameter and this thesis has filled a gap in this field. The results obtained from the thesis show that this study can be used to maintain flight safety and reduced maintenance costs.

İÇİNDEKİLER

İSTATİSTİKSEL TAHMİN YÖNTEMLERİ İLE UÇAK MOTOR SAĞLIK DURUMUNUN İZLENMESİ

BİLİMSEL ETİĞE UYGUNLUK	ii
YÖNERGEYE UYGUNLUK.....	iii
ONAY	iv
TEŞEKKÜR.....	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	xii
TABLolar LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ	xiv
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER

1.1. Genel Bilgiler	3
1.2. Bakımda Kullanılan Tahmin Yöntemleri	4
1.2.1. Kalan Yararlı Ömür (Remaining Useful Life - RUL) Tahmini.....	4
1.2.2. Tahmine Dayalı Bakım veya Kestirimci Bakım	5
1.3. Uçak Veri Kaynakları.....	6
1.3.1. Jiroskop (Gyroscope)	6
1.3.2. Suni Ufuk Göstergesi (Standby Horizon Indicator)	7
1.3.3. Dönüş ve Kayış Göstergesi (Turn and Slim Indicator).....	8
1.3.4. Konum Yön Göstergesi (Attitude Director Indicator-ADI).....	8
1.3.5. Yatay Durum Göstergesi (Horizontal Situation Indicator-HSI)	9
1.3.6. Hücum Açısı Göstergesi (Angle Of Attack Indicator)	9
1.3.7. Otopilot	10
1.3.8. Küresel Konumlama Sistemi (Global Positioning System-GPS).....	10
1.3.9. Saha Seyrüseferi (Area Navigation-RNAV)	10

1.3.10. Arazi Farkındalık ve Uyarı Sistemi (Terrain Awareness Warning System-TAWS).....	10
1.3.11. VHF Omni-directional Radio Range-VOR	10
1.3.12. Aletli İniş Sistemleri (Instrument Landing System-ILS)	11
1.3.13. Distance-measuring equipment-DME	11
1.3.14. Motor Veri Kaynakları.....	11
1.3.14.1. EGT Göstergesi	11
1.3.14.2. Engine Pressure Ratio-EPR Göstergesi	12
1.3.14.3. Devir Göstergesi (Tachometer).....	13
1.3.14.4. Yağ Basınç Göstergesi	13
1.3.15. Yağ Sıcaklık Göstergesi	14
1.3.16. Yakıt Akış Göstergesi	14
1.3.17. Yakıt Basınç Göstergesi.....	15
1.3.18. Yakıt Miktar Göstergesi.....	16
1.4. Literatür	16

2. BÖLÜM

ARAŞTIRMA YÖNTEMLERİ

2.1. Yapay Sinir Ağları	21
2.2. Biyolojik Nöron (Sinir Ağı)	21
2.2.1. Yapay Nöron.....	22
2.3. YSA'nın Avantajları.....	23
2.4. Yapay Sinir Ağlarının Sınıflandırılması	24
2.4.1. İleri Beslemeli Ağlar (Feedforward Networks):.....	24
2.4.2. Geri Beslemeli Ağlar (Recurrent Networks):	24
2.5. Öğrenme Algoritmaları	25
2.6. Regresyon Analizi	26
2.6.1. İstatiksel Regresyon Analizi.....	26
2.6.2. Tek Değişkenli Regresyon Analizi	26
2.6.3. Çok Değişkenli Regresyon Analizi.....	27
2.7. Korelasyon Analizi.....	29
2.8. Tahmin Modellerinin Doğruluklarının Ölçülmesi.....	29
2.8.1. Ortalama Hata (Mean Error-ME)	30
2.8.2. Ortalama Hata Yüzdesi (Mean Percentage Error-MPE).....	30

2.8.3. Ortalama Karesel Hata (Mean Squared Error-MSE).....	30
2.8.4. Ortalama Karesel Hatanın Karekökü (Root Mean Square Error-RMSE).....	30
2.8.5. Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE).....	31

3. BÖLÜM

BULGULAR, SONUÇ, ÖNERİLER

3.1. Bulgular.....	32
3.1.1. N1 bağımlı değişkenini etkileyen bağımsız değişkenlerin anlaşılması için korelasyon analizi ve çoklu regresyon analizi.....	32
3.1.2. Yapay Sinir Ağları ile 11 Farklı Eğitim Algoritması Kullanarak Tahmin Edilmesi.....	40
3.1.2.1. Levenberg-Marquardt Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar.....	40
3.1.2.2. BFGS Quasi-Newton Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar.....	42
3.1.2.3. Bayesian-Regularization Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar	44
3.1.2.4. Conjugate Gradient with Beale-Powell Restarts Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar	46
3.1.2.5. Conjugate Gradient Backpropagation with Fletcher-Reeves Updates Eğitim Algoritması ile Elde Edilen Sonuçlar	48
3.1.2.6. Conjugate Gradient Backpropagation with Polak-Ribiere Restart Eğitim Algoritması ile Elde Edilen Sonuçlar	50
3.1.2.7. Gradient Descent with Adaptive Learning Rate Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar	52
3.1.2.8. Gradient Descent with Momentum&Adaptive LR Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar	54
3.1.2.9. One-step Secant Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar.....	56
3.1.2.10. Rpron Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar.....	58

3.1.2.11. Scaled Conjugate Gradient Backpropagation Eğitim Algoritması	
ile Elde Edilen Sonuçlar	60
3.2. Sonuçlar ve Tartışma	62
KAYNAKLAR	65
ÖZGEÇMİŞ.....	71



KISALTMALAR

AOA	: Angle Of Attack (Hücum Açısı)
BP	: Backpropagation (Geri yayılım)
CBM	: Condition-Based Maintenance (Durum Tabanlı Bakım)
EGT	: Exhaust Gas Temperature (Egzoz Gaz Sıcaklığı)
EHM	: Engine Health Monitoring (Motor Sağlık İzleme)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MSE	: Mean Squared Error (Ortalama Karesel Hata)
N1	: Low Pressure Shaft (Düşük Basıncılı Şaft)
N2	: High Pressure Shaft (Yüksek Basıncılı Şaft)
RMSE	: Root Mean Squared Error (Kök Ortalama Karesel Hata)
RUL	: Remaining Useful Life (Kalan Yararlı Ömür)
TAT	: Total Air Temperature (Toplam Hava Sıcaklığı)
TTF	: Time To Failure (Başarısızlık Süresi)
YSA	: Yapay Sinir Ağları

TABLÖLER LİSTESİ

Tablo 2.1.	YSA ve biyolojik sinir sistemi benzerlikleri.....	22
Tablo 2.2.	YSA ile istatistiksel prensipler arasındaki terminolojik benzerlikler	23
Tablo 2.3.	Sig değerinin yorumu.....	29
Tablo 3.1.	Pearson korelasyon katsayısının yorumu.....	32
Tablo 3.2.	Korelasyon analizi sonucu	34
Tablo 3.3.	11 farklı eğitim algoritmasının MSE değerlerine göre karşılaştırılması....	63
Tablo 3.4.	YSA performans değerleri (trainlm için).....	64



ŞEKİLLER LİSTESİ

Şekil 1.1.	Jiroskop.....	7
Şekil 1.2.	Suni ufuk göstergesi.....	7
Şekil 1.3.	Dönüş ve kayış göstergesi.....	8
Şekil 1.4.	Konum yön göstergesi	8
Şekil 1.5.	Yatay durum göstergesi	9
Şekil 1.6.	Angle of attack göstergesi.....	9
Şekil 1.7.	EGT göstergesi	12
Şekil 1.8.	EPR göstergesi	12
Şekil 1.9.	Devir Göstergesi	13
Şekil 1.10.	Yağ basınç göstergesi	13
Şekil 1.11.	Yağ sıcaklık göstergesi	14
Şekil 1.12.	Yakıt akış göstergesi	15
Şekil 1.13.	Yakıt basınç göstergesi	15
Şekil 1.14.	Yakıt miktar göstergesi ve çalışma prensibi	16
Şekil 2.1.	Biyolojik sinir sistemi blok gösterimi.....	21
Şekil 2.2.	Biyolojik nöron	22
Şekil 2.3.	p girişli bir nöronun temel gösterim grafiği.....	23
Şekil 2.4.	İleri beslemeli ağ.....	25
Şekil 2.5.	Geri beslemeli ağ	25
Şekil 3.1.	N1 eğitim verileri için model özeti sonuçları	35
Şekil 3.2.	N1 eğitim verileri için ANOVA sonuçları.....	36
Şekil 3.3.	N1 parametresi için çoklu regresyon analiz sonuçları	36
Şekil 3.4.	Bağımsız ve bağımlı değişken olarak kullanılan veriler.....	38
Şekil 3.5.	N1 eğitim verileri için model özeti sonuçları	38
Şekil 3.6.	N1 eğitim verileri için ANOVA sonuçları.....	38
Şekil 3.7.	N1 eğitim verileri için katsayılar sonucu	39
Şekil 3.8.	N1 tahmini için geliştirilen YSA	40
Şekil 3.9.	“trainlm” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları.....	41
Şekil 3.10.	“trainlm” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	41
Şekil 3.11.	“trainlm” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	42

Şekil 3.12.	“trainlm” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	42
Şekil 3.13.	“trainbfg” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları.....	43
Şekil 3.14.	“trainbfg” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	43
Şekil 3.15.	“trainbfg” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	44
Şekil 3.16.	“trainbfg” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	44
Şekil 3.17.	“trainbr” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları.....	45
Şekil 3.18.	“trainbr” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	45
Şekil 3.19.	“trainbr” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	46
Şekil 3.20.	“trainbr” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	46
Şekil 3.21.	“traincgb” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları	47
Şekil 3.22.	“traincgb” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları.....	47
Şekil 3.23.	“traincgb” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	48
Şekil 3.24.	“traincgb” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	48
Şekil 3.25.	“traincgf” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları.....	49
Şekil 3.26.	“traincgf” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	49
Şekil 3.27.	“traincgf” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	50
Şekil 3.28.	“traincgf” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	50
Şekil 3.29.	“traincgp” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları	51
Şekil 3.30.	“traincgp” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları.....	51
Şekil 3.31.	“traincgp” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	52
Şekil 3.32.	“traincgp” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	52
Şekil 3.33.	“traingda” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları	53
Şekil 3.34.	“traingda” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları.....	53
Şekil 3.35.	“traingda” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	54
Şekil 3.36.	“traingda” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	54
Şekil 3.37.	“traingdx” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları	55

Şekil 3.38.	“traingdx” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları.....	55
Şekil 3.39.	“traingdx” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	56
Şekil 3.40.	“traingdx” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	56
Şekil 3.41.	“trainoss” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları	57
Şekil 3.42.	“trainoss” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	57
Şekil 3.43.	“trainoss” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	58
Şekil 3.44.	“trainoss” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	58
Şekil 3.45.	“trainrp” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları.....	59
Şekil 3.46.	“trainrp” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	59
Şekil 3.47.	“trainrp” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	60
Şekil 3.48.	“trainrp” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	60
Şekil 3.49.	“trainscg” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları.....	61
Şekil 3.50.	“trainscg” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları	61
Şekil 3.51.	“trainscg” eğitim fonksiyonu ile oluşturulan ağın test sonuçları	62
Şekil 3.52.	“trainscg” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları.....	62

GİRİŞ

Havacılık sanayii, havayolu ulaşımı, hava kargoculuğu, hava savunma ve askeri havacılık alanında hızla ilerlemekte ve büyümektedir. Havacılıkta meydana gelen bu gelişmelere paralel olarak hava aracı bakımında da pek çok gelişme meydana gelmektedir. Havayolu şirketleri ve uçak üreticileri bakım alanındaki gelişmelerde hem arıza meydana gelmeden tahmin edebilmeyi, arıza olmadan önlemeyi hem de bakım hattında zamanın nasıl iyi şekilde kullanılabileceğinin cevaplarını bulmayı hedeflemişlerdir. Bu tez çalışmasına konu olan uçak motorları için uçağın kalbidir denebilir. Uçak bakımının tamamı içerisinde uçak motoru bakımı büyük öneme sahiptir. Uçak motoru bakımı vakit isteyen, karmaşık ve oldukça maliyetli bir bakımdır. Uçağın en pahalı parçasının motorları olduğu düşünüldüğünde bakım maliyetlerinin bu kadar yüksek olması beklenen bir durumdur. Uçak motor bakım maliyetleri bir uçağın toplam bakım maliyetinin neredeyse %30'unu oluşturmaktadır [1]. Uçaklarda parçaların tamamı büyük öneme sahiptir ancak uçuş sırasında bazı parçaları kaybetmek hayati risk oluşturmaktadır. Hayati risk taşıyan parçaların başında yine uçak motorları gelmektedir. Hayati risklerin önüne geçilmesi, emniyetli uçuşun sağlanması, bakım maliyet kaleminin düşürülmesi, sağlıklı motorla yapılacak uçuşlarla çevresel korumanın sağlanması uçak bakım yöntemlerinin geliştirilmesinin ne denli büyük öneme sahip olduğunu göstermektedir. Geçmişten günümüze havacılık sektörünün gelişmesiyle hava aracı bakım kuruluşları gelişerek bugünkü halini almıştır. İlk başlarda sabit zaman aralıklarıyla periyodik bakımlar gerçekleştirilmekteydi. "Havacılık tarihi ve havacılık kuralları kanla yazılmıştır!" sözü reaktif, yani kazalar ve olaylardan sonra kuralların geldiğini göstermektedir. Reaktif bakımdan proaktif bakıma geçiş zamanla gerçekleşmeye başlamıştır. Yani eskiden havacılıkta kazalar olduktan sonra önlemler alınırken günümüzde kazalar gerçekleşmeden öngörülmek istenmektedir. Buna da tahmine dayalı bakım, kestirimci bakım denilmektedir. Kestirimci bakım yöntemleri ile herhangi bir sorunu meydana gelmeden tespit edip gerekli önlemleri alarak uçakların

emniyetli uçuş yapması, yüksek bakım maliyetin önüne geçilmesi ve çevresel koruma yapılması mümkün olmaktadır. Uçak bakımında kullanılan istatistiksel yöntemler ile hem hataların önceden tahmin edilmesi hem de uçak parçalarına ait kalan yararlı ömür (Remaining Useful Life-RUL) tahmini yapılmaktadır. Tahmine dayalı bakım ve kestirimci bakımdan birkaç cümle ile bahsetmek gerekirse; endüstride kullanılan makinelerin bakım ve onarımları ile olası duruş maliyetlerinin çok yüksek meblağlara karşılık gelmesi ve beklenmedik bir arıza nedeniyle makinelerin uzun süre çalışamaz hale gelmesi durumunda seri üretim yapan tesislerde üretimin azalması, ürünlerin maliyetinin artması gibi durumların olumsuz etkilerinden korunmak için yapılan çalışmalar neticesinde geliştirilen çeşitli test ve analiz yöntemleri ile arızalar meydana gelmeden tespit edebilmektir diyebiliriz [2]. Kalan yararlı ömür tahmini (Remaining Useful Life-RUL) ise bir öğenin, bileşenin veya sistemin amaçlanan amaca uygun olarak ne kadar süre çalışabileceğinin tahmin edilmesi yöntemidir [2]. Kestirimci bakım yöntemlerinde bahsedildiği aynı şekilde aniden meydana gelebilecek arızaların, onarım ve üretim kesintisi açısından çok maliyetli olması ve itibar açısından kötü olduğunu bilen sanayiciler için endüstriyel sistemlerin kalan faydalı ömürlerinin tahmin edilmesi büyük önem arz etmektedir [3]. Sonraki bölümlerde bu yöntemler hakkında literatürde yapılmış çalışmalardan örnekler verilecektir. Bu tez çalışmasında hava aracı motoru sağlığı izleme yöntemleri araştırılmış; kalan parçalı ömür tahmini ve tahmine dayalı bakım yöntemleri ile ilgili çalışmalar incelenmiş; ve bir uygulama örneği olarak uçak sensörlerinden alınan veriler üzerinde istatistiksel tahmin yöntemleri kullanılarak uçak motorlarında arıza tespiti yapılmıştır. Arıza tespitinde uçak performans parametreleri ile motora ait bir parametre olan N1 parametresi arasındaki ilişkiler ele alınmış, N1 parametresinin motor sağlığı izleme üzerindeki etkisi incelenmiştir.

1. BÖLÜM

GENEL BİLGİLER

1.1. Genel Bilgiler

Havacılık sanayii, havayolu ulaşımı, hava kargoculuğu, hava savunma ve askeri havacılık hızla ilerlemekte ve büyümektedir. Yakın gelecekte havacılık tüm bu alanlarda daha etkili hale gelecektir. Uçak bakımı, uçuşta emniyetin şartlarının yerine getirilmesi, uçağın uçuşa hazır halde bulunmasının sağlanması ve emniyet faktöründen taviz vermeden giderlerin düşürülmesi şeklinde özetlenebilir. Uçağın üretiminden son uçuşuna kadar kullanıldığı süre içinde iyi çalışır, sağlıklı ve uçuşa elverişli şekilde tutulabilmesi maksadıyla yapılan işlemlerin tümü bakım faaliyetleri kapsamındadır.

Havacılık sektörünün gelişmesiyle hava aracı bakım kuruluşları da zaman içinde gelişerek bugünkü halini almıştır. İlk başlarda sabit zaman aralıklarıyla periyodik bakımlar gerçekleştirilmekteydi. “Havacılık tarihi ve havacılık kuralları kanla yazılmıştır!” sözü reaktif, yani kazalar ve olaylardan sonra kuralların geldiğini göstermektedir. Reaktif bakımdan proaktif bakıma geçiş zamanla gerçekleşmeye başlamıştır. Yani eskiden havacılıkta kazalar olduktan sonra önlemler alınırken günümüzde kazalar gerçekleşmeden öngörülme istenmektedir. Sistemlere gerekli bakımlar arıza oluşmasını beklemeden önceden yapılmaktadır. Böylece arızalar önlenabilmektedir. Programlı bakımlar önleyici bakım kapsamında yer almaktadır. Üretici firma tarafından bakım el kitaplarında belirlenen zaman aralıklarıyla yapılan uçak yapısındaki sistemler ve ekipmanlar arızalansın veya arızalanmasın kontrol edilip, yapımca firma tarafından belirlenen sınırlayıcı koşullara uygunluğunun tespit edildiği uymuyorsa değiştirildiği günlük, aylık veya yıllık olarak programlanabilen bakımlardır. Programlı bakımlar belirli zaman aralıklarında uygulanır ve çeşitli kodlara sahiptir. Zaman aralıkları ve kodlar uçağın cinsine, bakımı uygulayan kuruluşun bakım planına ve şirketlere göre değişiklik gösterebilir. Genellikle programlı bakım periyotları A, B,

C, D, E ve benzeri harflerle temsil edilir. Her bir bakım periyodu bir öncekinden daha geniş ve daha uzun süre alan bakımlardır. Bu bakımlara programlı bakım denilmektedir.

Programsız bakım bir malzemenin bilinen veya tahmin edilen arızasının düzeltilerek belirlenen hale geri getirmek için yapılan bakım faaliyetleri olarak tanımlanır. Başka bir deyişle programsız bakım, ortaya çıkan arızaların ya da hasarların giderilmesi için yapılan bakım faaliyetleridir. Uçuş esnasında veya kontroller esnasında uçuş emniyetini tehlikeye arz eden herhangi bir arızanın oluşması durumunda derhal uygulanan, bu yapılmadan uçağın uçuşa verilmesi mümkün olmayan bakımlardır. Kuş çarpması, yıldırım çarpması, sert iniş programsız bakımı doğuran sebeplere örnek olarak verilebilir [4]. Düzeltici ve önleyici bakıma ek olarak eldeki veriler kullanılarak durum analizi yapan, tahmine dayalı bakım yöntemleri de kullanılmaktadır. Tahmine dayalı bakım veya kestirimci bakım olarak isimlendirilen bu bakım yöntemi ile arıza meydana gelmeden önlenmekte, muhtemel kazaların önüne geçilmekte, can kaybı ihtimali önlenmekte, emniyetli uçuş sağlanmakta, motorun uzun süre sağlıklı kalması sağlanmaktadır.

1.2. Bakımda Kullanılan Tahmin Yöntemleri

1.2.1. Kalan Yararlı Ömür (Remaining Useful Life - RUL) Tahmini

Kalan yararlı ömür tahmini (Remaining Useful Life-RUL) bir öğenin, bileşenin veya sistemin amaçlanan amaca uygun olarak ne kadar süre çalışabileceğinin tahmin edilmesi yöntemidir [2]. Aniden meydana gelebilecek arızaların, onarım ve üretim kesintisi açısından çok maliyetli olması ve itibar açısından kötü olduğunu bilen sanayiciler için endüstriyel sistemlerin kalan faydalı ömürlerinin tahmin edilmesi büyük önem arz etmektedir [3]. İyi bir RUL tahmin yönteminin tahmin hatasının mümkün olduğunca sifıra yakın olması gerekmektedir [5]. Bunu hesaba kattıktan sonra, bakım ekipleri, planlanmamış arıza süresini ve gereksiz önleyici bakımı azaltmak amacıyla bakım programını optimize edebilir. Prognostikler ve sağlık yönetiminin kritik bir sorunu, mevcut zamandan arızanın oluşmasına kadar kalan çalışma döngüsü olarak tanımlanan kalan faydalı ömrü (RUL) tahmin etmektir [5]. Yani bir makinenin gelecekteki durumunu sunmanın en iyi yollarından biri, kalan faydalı ömrünü (RUL) tahmin etmektir. RUL bir makinenin ne kadar süre daha düzgün çalışabileceğiyle ilgili bilgi verdiğinden, esnek ve etkili bir bakım programı oluşturmak için kullanılabilecek güçlü

bir araçtır [6]. Kalan yararlı ömür modeli için girdiler büyük ölçüde mevcut verilere bağlı olacaktır. Bunların tümü, makine parçalarının durumunun göstergeleri olarak düşünülebilir. Çoğu yapay zeka uygulamasında olduğu gibi, ne kadar fazla veri girişi olursa o oranda sağlıklı sonuç almak mümkün olacaktır [3].

RUL ile yapılan pek çok tahmin çalışması bulunmaktadır. Bir RUL çalışmasında motorun geçmiş verileri kullanılarak motor bozulma süreci incelenmiş ve motorların geriye kalan ömrü tahmin edilmiştir. Tahmin işleminde uyarlanır nöro-bulanık çıkarım sistemi kullanılmıştır [6]. Bir başka RUL çalışmasında durum izleme (condition monitoring - CM) bilgisayar verileri kullanılarak motora ait ömür bozulması incelenmiştir [7]. Model tabanlı prognostik yaklaşımlar, doğru matematiksel modellerin kurulabildiği durumlarda uygulanabilir. Bu tür çalışmalarda bir sistemin sensörleri ile algılanan ölçümleri ile matematiksel bir modelin çıktıları arasındaki tutarlılık kontrolü, kıyaslama yapılarak gerçekleştirilmektedir [8]. Bir başka RUL tahmini çalışmasında harici girişli doğrusal olmayan otoregresif sinir ağı yöntemi ile Levenberg-Marquardt Algoritması (LMA) kullanılmıştır [3].

1.2.2. Tahmine Dayalı Bakım veya Kestirimci Bakım

Endüstriyel üretim süreçlerinde makinelerin ve sistemlerin belirli periyotlarda bakıma girmesi, üretim süreçlerinin planlananın dışında sekteye uğramaması için büyük önem arz etmektedir. Bu bakım süreçleri gerek bakım maliyetleri gerekse üretim hattının çalışmıyor, katma değer oluşturmuyor olması sebebiyle işletmelere belli bir miktarda maliyet getirmektedir. Bakım planlarının dışında herhangi bir arıza sebebiyle üretimin durması ise beklenenin de üzerinde kayba sebep olabilmektedir. Bu tür beklenmeyen kayıpları önlemek için çeşitli analiz yöntemleri kullanılarak hataların meydana gelmeden tespit edilebildiği tahmine dayalı bakım veya kestirimci bakım yöntemleri geliştirilmiştir. Tahmine dayalı bakım veya kestirimci bakım, olağan dışı hataların sayısını azaltmayı ve çalışma verimliliğini en üst düzeye çıkarmayı, bakım süreçlerinin daha programlı olmasını sağlayarak operasyonel mükemmellik sağlamayı, bakım programlarının sadece gerekli durumlarda yapılmasını sağlayarak fazladan bakım ihtiyacının ortadan kaldırılmasını ve üretim sürecini en uzun tutarak daha az bakım maliyeti ile kâr artışı sağlamayı amaçlamaktadır. Makina ve sistem arızalarında erken müdahale, olası büyük sonuçları elimine ederek, uygun maliyet ve zaman tasarrufu

imkânı sağlamaktadır. Kullanılan cihazların arızalanması durumunda çalışamaz hale gelen sistemin zararlarını en aza indirmektedir. Önerilen tedbirler zamanında doğru şekilde uygulanırsa üretim daha verimli hale gelmektedir. Tahmine dayalı bakım veya kestirimci bakım için oluşturulan ağ planlaması ve sistemlerden gelen bilgiler kullanılarak cihaz arızaları kolaylıkla tespit edebilmektedir. Bu şekilde tüm arıza uyarıları tek panelde birleştirilebilmektedir. Makine ve sistem durumu analiz yazılımları aracılığıyla yapılmakta elde edilen sonuçlar doğrultusunda düzeltici işlemler yapılmaktadır.[2] Havacılık sektöründe hizmet veren şirketler, uçuş gecikmelerinin ve iptallerinin maliyetli etkilerini düşürmek için tahmine dayalı veya kestirimci bakım uygulamalarını kullanmaktadırlar. Hava yollarının uçak sağlığını iyileştirmesine ve yıkıcı kazaları önlemesine yardımcı olmak için yine tahmine dayalı veya kestirimci bakımdan faydalanılmaktadır. Bu tez çalışmasında yukarıda verilen bilgilere ek olarak uçuş parametreleri kullanılarak uçak motor sağlığı tahmini yapılmıştır. Literatürden görülebildiği kadarı ile henüz bu çalışmanın benzeri bulunmamaktadır.

1.3. Uçak Veri Kaynakları

Uçakta bulunan sensörler ve sistemler yardımıyla elde edilen pek çok veri bulunmaktadır. Uçak verileri işlenerek pilotlara bilgilendirme mesajı, ikaz ve uyarılar üretildiği gibi verinin cinsine bağlı olarak yerde bulunan görevlilere de uyarı mesajları iletilebilmektedir. Veri kaynaklarına ait örnekler aşağıdaki başlıklarla sunulmaktadır.

1.3.1. Jiroskop (Gyroscope)

Jiroskop, halka çerçeve içerisinde eksen üzerine yerleştirilmiş, rahatlıkla dönebilen ve sürtünmesi azaltılmış olan bir diskten oluşmaktadır. Açısal momentumun korunumu prensibine dayalı olarak çalışan bir araçtır. Modern uçaklarda jirokobik prensiple çalışan göstergeler kullanılmaktadır. Pilotlar kendi hisleriyle uçağın pozisyonunu kavrayamazlar ancak jiroskop yardımıyla bilebilirler. Jiroskop rotorun montaj şekline göre iki jirokopik esastan birine bağlı olarak çalışmaktadır. Bunlar; rigidity ve precession olarak isimlendirilmektedir.



Şekil 1.1. Jiroskop

1.3.2. Suni Ufuk Göstergesi (Standby Horizon Indicator)

Bu göstergede cayro rotoru dönmeye başladığı andan itibaren ufuk çizgisi, yeryüzünü temsil eden çizgi ve şekiller uçağın havadaki pozisyonu ne olursa olsun gerçek ufuk çizgisine paralel kalmaktadır [9].



Şekil 1.2. Suni ufuk göstergesi

1.3.3. Dönüş ve Kayış Göstergesi (Turn and Slim Indicator)


Bu gösterge pilota savrulmadan, kaymadan, dengeli ve koordineli bir dönüş yaptıracak bilgileri göstermektedir. İçinde bulunan jiroskop uçağın burnunun yön değiştirme hızını ve miktarını vermektedir [9].



Şekil 1.3. Dönüş ve kayış göstergesi

1.3.4. Konum Yön Göstergesi (Attitude Director Indicator-ADI)

ADI, uçağın pitch ve roll hareketlerini dikey cayrodan (yön göstergesi) aldığı bilgilerle derece olarak, flight director, roll ve pitch kumandalarını, süzülüş açısını (Glide Slope) pisti karşılama (Rising Runway), dönüş ve yatışı (Rate Of Turn) gösteren göstergedir.



Şekil 1.4. Konum yön göstergesi

1.3.5. Yatay Durum Göstergesi (Horizontal Situation Indicator-HSI)

HSI, uçağın manyetik heading (yön), course (radyo yolu), course deviation (radyo yolundan sapmalar) ve glide slope'u (süzülüş açısını) göstermektedir. Pilot bu gösterge ile gelen ve gidilen rota noktalarına göre uçağın pozisyonunu tespit etmektedir. Bu rota noktalarına way point denmektedir [10].



Şekil 1.5. Yatay durum göstergesi

1.3.6. Hücum Açısı Göstergesi (Angle Of Attack Indicator)

Hücum açısı (Angle Of Attack), kanat kesitinde cord hattının hava akış doğrultusuyla yaptığı açıdır. Kanatın ürettiği lift hücum açısı dışında kanat aerodinamiği, yoğunluk, irtifa, uçağın brüt ağırlığı ve problemlerden aldığı hız bilgisi gibi faktörlere de bağlıdır [11].



Şekil 1.6. Angle of attack göstergesi

1.3.7. Otopilot

Bir otopilot, pilotların uçağın ve uçuşun genel durumuna odaklanmasına yardımcı olan görevler yapabilmektedir. Bir otopilotun doğru kullanılması, uçağın yönlendirilmesi ve kontrol edilmesine yönelik süreci otomatikleştirmeye yardımcı olmaktadır. Otomatik pilotlar, rakımın sürdürülmesi, tırmanma veya belirli bir rakıma inme ve tayin edilmiş bir rotaya dönme, uçağın belirlenmiş bir rotaya müdahale etmesi gibi görevleri otomatikleştirebilmektedirler.

1.3.8. Küresel Konumlama Sistemi (Global Positioning System-GPS)

Yeryüzünde herhangi engelsiz bir görüş hattında, dört veya daha fazla uydusu ile kötü hava koşullarında bile yer ve zaman bilgileri sağlayan uzay tabanlı uydu navigasyon sistemidir. Sürekli şekilde kodlanmış veri yollayan bir uydu ağıdır. Uydularla arasındaki mesafeyi ölçerek yeryüzündeki doğru yeri belirlemeyi hedeflemektedir [12].

1.3.9. Saha Seyrüseferi (Area Navigation-RNAV)

RNAV cihazları, dünya merkezli herhangi bir seyrüsefer yardımcısı üzerinden geçmeden saha seyrüseferi yapmaya yarayan cihazlara verilen genel addır.

1.3.10. Arazi Farkındalık ve Uyarı Sistemi (Terrain Awareness Warning System-TAWS)

Arazi farkındalık ve uyarı sistemi (TAWS), uçaklarda bulunduğu pilotlara otomatik olarak ayırt edici bir uyarı sağlayan, telsiz altimetre okumalarına ve yeryüzünden tehlike arz eden mesafelerde uyarı veren bir güvenlik ağıdır [13].

1.3.11. VHF Omni-directional Radio Range-VOR

VOR taşıyıcısı, aralarında faz farkı bulunan iki adet ses sinyalinin modüle edilmesi ile elde edilmektedir. Bu ses sinyalleri 30 Hz sinüzoidal işaretlerdir. Bunlardan bir tanesi referans, diğeri de değişken sinyal olarak isimlendirilmektedir [14]. Seyrüsefer yardımcı sistemlerdendir.

1.3.12. Aletli İniş Sistemleri (Instrument Landing System-ILS)

Aletli iniş sistemi olarak tanımlanan ILS sistemi, yatay ve düşey olarak uçağa kılavuzluk görevi yaparak, uçağın piste sağlıklı iniş yapmasını sağlar. Özellikle bulutlu, görüşün kısıtlı olduğu, sisli, yağmurlu ve karlı havalarda güvenli, görüş mesafesinin yüksek olduğu durumlarda ise güvenliğin yanı sıra konforlu bir yaklaşma ve iniş yapılmasına olanak sağlar. ILS Sistemi lokalizer, glide slope ve marker beacondan oluşan yaklaşma ve iniş için, uluslararası olarak kullanılan bir seyrüsefer sistemidir [15].

1.3.13. Distance-measuring equipment-DME

Bir istasyona doğru uçan hava aracının o noktaya kadar olan uzaklık bilgisi bu cihazlar tarafından sağlanır. Bu sistem VOR, NDB ve ILS cihazlarına göre biraz daha farklıdır. Diğer seyrüsefer sistemlerinde cihazın sadece verici özelliği olmasına rağmen, bu cihazda hem alıcı hem verici özelliği vardır [14].

1.3.14. Motor Veri Kaynakları

1.3.14.1. EGT Göstergesi

Gaz türbinli motorlarda, thrust parametresinden sonra en önemli performans parametresi EGT değeridir. Uçak kokpitinde motor göstergelerine baktığınızda her zaman ikinci sırada yer alır. İsminden kolaylıkla anlaşılacağı üzere motordaki egzoz gaz sıcaklığını gösterir. ITT (Inter Turbine Temperature), Turbine Gas Temperature (TGT), Jet Pipe Temperature (JPT), Turbine Entry Temperature (TET) veya TIT (Turbine Inlet Temperature) şeklinde farklı isimler ile ifade edilir ancak en yaygın kullanımı EGT (Exhaust Gas Temperature)'dir. Bir motorun üretebileceği maksimum thrustı belirleyen en önemli faktördür [16].

Motordaki sıcaklık, limitin üzerine çıktığında motorda kalıcı hasarlanmalar kaçınılmaz hale gelir. Limit aşımı söz konusu olduğunda motorun kaç dereceye ne kadar süre maruz kaldığı bilgisi oldukça önemlidir. Çünkü oluşan hasarlar motor değişimine kadar gidebilir. Motor revizyonu, hem motor fiyatı olarak hem de bakım firmasının teknisyen ücreti olarak oldukça maliyetli bir işlemdir. Motor tasarımında belirlenmiş bir thrustı

 retirken oluřan EGT aynı zamanda motorumuzun ne kadar verimli olduėunun da g stergesidir. Y ksek EGT motordaki ařınma ve yıpranmanın bir g stergesidir.



řekil 1.7. EGT g stergesi

1.3.14.2. Engine Pressure Ratio-EPR G stergesi

Motor basın  oranı olarak  evrilen EPR bazı motor ve u ak kombinasyonlarında kullanılan bir g stergesidir. Deėer olarak motor thrustına karřılık gelmektedir. S z konusu oran, t rbin  ıkıřı toplam basıncının, fan giriřindeki toplam basıncına oranıdır. Motor takati N1'e g re set edilen motorlarda EPR g stergesinin kullanılmasına gerek yoktur [17].



řekil 1.8. EPR g stergesi

1.3.14.3. Devir Göstergesi (Tachometer)

Devir göstergesi, motor devrini tur/dakika (Revolutions Per Minute “RPM”) değeri türünden göstermektedir. Devir ayarı RPM göstergesinden yararlanılarak yapılmaktadır [18].



Şekil 1.9. Devir Göstergesi

1.3.14.4. Yağ Basınç Göstergesi

Yağ basınç indikatörü, yağ basınç manifoldundaki yağın basıncını PSI olarak göstermektedir. Sistem AUTOSYN olarak çalışmaktadır. Sistemde bir transmitter içinde mekanik olarak çalışan bir diyafram ve elektriksels olarak çalışan bir synkrodan ibarettir. Yağ direkt olarak transmitter içindeki diyaframa girer. Basıncın değerine göre diyafram açılıp kapanır. Bu mekanik hareket synkro ile elektrik sinyaline dönüştürülerek indikatöre gönderilmektedir.



Şekil 1.10. Yağ basınç göstergesi

1.3.15. Yağ Sıcaklık Göstergesi

Bu göstergeler motor soğutma ve yağlama sistemindeki yağın motora giriş anındaki ısını C° cinsinden göstermektedir [19]. 28 VDC ile çalışır.

Sistem gösterge ve hararet ampulünden meydana gelmektedir. Yağ sıcaklığının ölçümü transistor yardımıyla yapılır. Bir termistör, sıcaklığı ölçmek için kullanılan bir direnç tipidir. Çalışma prensibi direnç ve sıcaklık arasındaki ilişkiye dayalıdır. Uçakta kullanılan termistör ürünü, dirençli termometre detektörü veya sıcaklık ampulü olarak da bilinen direnç sıcaklık cihazıdır. Bir bobin formunda direnç sargıları üzerine çok küçük çaplı bir tel uzunluğu sarılır. Bobin, sarımları kirletici maddelere karşı korumak için paslanmaz çelik bir gövde içinde bulunmaktadır. Sargıların her bir ucu, elektriksel bir bağlayıcı şeklinde oluşturulan pimlerin üzerine lehimlidir. Bu, flanşa kaynaklanır ve hava geçirmez bir şekilde kapatılır. Bu sıcaklık ölçüm cihazının prensipleri metal bir elementin direnç değişimini ölçmeye ve bunu sıcaklık olarak yorumlamaya dayanmaktadır. Metal elementler pozitif bir sıcaklık katsayısına sahiptir. Nikel ve platin gibi metallerde direnç ve sıcaklık arasında çok kararlı ve doğrusal bir ilişki bulunmaktadır.



Şekil 1.11. Yağ sıcaklık göstergesi

1.3.16. Yakıt Akış Göstergesi

Akış metre veya debi metre, gaz, sıvı ve buhar gibi akışkanlığı olan ve bir tesisat üzerinden geçen maddeleri, “birim miktar/birim zaman” cinsinden, mekanik ya da elektronik olarak ölçen cihazdır. Bu gösterge bir motorun bir saatte yakmış olduğu yakıtın akış miktarını KGPH (Kilogram Per Hour) veya PPH (Pound Per Hour) olarak ve kullanılan yakıtın miktarını da kg veya lb cinsinden göstermektedir [20].



Şekil 1.12. Yakıt akış göstergesi

Sistem; güç kaynağı, transmitter, indicator ve reset switchden oluşmaktadır. Power supply 115V AC 400 Hz 1Ø (bazı uçaklarda 28 V DC) ile beslenip, çıkış olarak 15V AC 4 Hz 3Ø gerilim oluşturur.

1.3.17. Yakıt Basınç Göstergesi

Bu gösterge manifold hattındaki yakıtın pompa basıncını PSI cinsinden göstermektedir. Çalışma gerilimi 26 V AC 400 Hz 1Ø'dır. İndikatör AUTOSYN prensibi ile çalışır. Sistem 1 adet transmitter ve göstergeden ibarettir. Yakıt pompasının çıkış basıncı direkt olarak transmitter içindeki diyaframa girer. Basıncın değerine göre diyafram açılır veya kapanır. Bu mekaniki hareket synkro vasıtasıyla elektriki sinyale dönüştürülerek göstergeye iletilmektedir.




Şekil 1.13. Yakıt basınç göstergesi

1.3.18. Yakıt Miktar Göstergesi

Sistem her bir tank için yeterli tank prob, konpansatör problemler ile birlikte ikmal panelinde, pilot kabininde her tanka ait birer indikatör ve bazı uçaklarda toplam yakıt miktarını gösteren indikatörden ibarettir. Tank içerisindeki yakıt miktarı yakıtın ve havanın elektrik akımına karşı gösterdikleri yalıtkanlık seviyesine göre indikatöre elektrikli bir kapasitans değeri gönderirler. Tank içerisindeki probun bulunduğu bölgede yakıt yoksa indikatör “0” değerini göstermektedir.

Yakıt seviyesi yükseldikçe yakıtın havaya nazaran daha iletken olması geçen elektrik akımını artıracak, bu voltaj indikatör içerisindeki amplifier tarafından yükseltilecek ve indikatör motoru çalışarak yakıt miktarı indikatörde görülecektir [21].



Şekil 1.14. Yakıt miktar göstergesi ve çalışma prensibi

1.4. Literatür

Andreas Mair ve Thomas Thurner pistonlu uçak motorlarının sağlık durumunu izlemek için “motor bloğuna bağlı tek bir hızlanma sensöründen gelen bilgilere dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde hiyerarşik bir tahmin şemasında model analizi yapılmış ve bulanık mantık kullanılarak modele dayalı sinyal işleme yapılmıştır [22].

Feng LU ve arkadaşları sensör arızasını önlemek ve gaz türbini sağlığının izlenmesi için “yeni bir hibrid Kalman Filtre-KF yaklaşımı geliştiren” bir yöntem üzerinde çalışmışlardır. Bu yöntemde doğrusallaştırılmış KF ve uzatılmış KF kullanılarak

termodinamik parametrelerin doğrusal ilişkisine bağlı olarak yerel filtreler kullanılmıştır [23].

Erotokritos Skordilis ve Ramin Moghaddass karmaşık sistemlerin güvenilirlik analizi için daha güvenilir sonuçlar üretmek için “sistemin çalışma koşullarının gelişimini ve zaman içindeki bozulmasına dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde hibrid bir durum-uzay modeli kullanarak arıza teşhisi için bir dizi gerçek zamanlı sensör ölçümü kullanmışlardır [24].

Shih-Huai Chen ve Chao-Chung Peng turbofan motor kompresörlerinin potansiyel uçuş riskini önleyebilmek için “motor modellemesi için algoritmalar geliştirmeye ve optimal parametrelerin tanımlanmasını baz alan” bir yöntem üzerine çalışmışlardır. Bu yöntemde fiziksel izentropik sıkıştırma denklemini ve veriye dayalı regresyon tekniğini kullanmışlardır [25].

Gaurav Saraswat ve arkadaşları dizel motorun sağlık durumunu tahmin etmek için “özellik seçimi ve özellik çıkararak verilerin boyutunu azaltmaya dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde deneysel çalışmaya dayanarak en iyi boyut küçültme ve tahmin yöntemi önerilmiştir [26].

Seyed Ali Razavi ve Ali Mahmoodian motor bozulma sürecini inceleyerek uçak motorlarının yararlı ömrünü tahmini için “uyarlanabilir nöro-bulanık çıkarım sistemi (Adaptive Neuro-Fuzzy Inference System-ANFIS) algoritması kullanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde otomatik olarak optimum kümeleme, bulanık kurallar ve yapısal parametreler sağlayan nöro-bulanık bir yapı kullanılmıştır [6].

JIALIN LI ve arkadaşları makinanın yararlı ömrünü tahmin için “uzun kısa süreli belleği (LSTM) ve evrişimli bir sinir ağını (CNN) birleştiren bir yönlendirilmiş çevrimsiz grafik (DAG) ağına dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde özellik çıkarma için sadece CNN kullanmak yerine CNN ve LSTM'yi organik olarak birleştirme yapılmıştır [27].

Shakthi Weerasinghe ve Supunmali Ahangama veri analitiği kullanarak uçaklarda öngörülmesi bakım ve performans optimizasyonunu sağlamak için “genel havacılıkta hem toplu işleme hem de gerçek zamanlı akış verilerine dayanan” bir yöntem üzerine

çalışmışlardır. Bu yöntemde sağlık izleme ve tahmini analiz için bakım ve uçakların performansını optimize etme işlemi gerçekleştirilmiştir [12].

Cunsong Wang ve arkadaşları veri odaklı aero-motor bozulma stratejisi tahmini geliştirmek için “NASA'nın aeroengine verilerine dayanan” bir yöntem üzerinde çalışmışlardır [7].

Kunyuan Deng ve arkadaşları uçak motorları için otomatik özellik çıkarma ile kalan faydalı ömür tahmini için “yığılmış seyrek otoenkoderi geçitli tekrarlayan ünite ile birleştiren” bir yöntem üzerinde çalışmışlardır [5].

Link C. Jaw etkili teşhis ve sağlık yönetimi (Prognostic Health Management-PHM) hedefine ulaşmak için “yapay siniri ağlarının modelleme alanında olgunlaştığı görüşüne dayanan” bir yöntem üzerine çalışmışlardır. Bu yöntemde yapay sinir ağlarının önemli avantajlarını sunan geleneksel modelleme ile yapay sinir ağı tabanlı algoritmaların PHM sistemlerinde uygulanmasını harmanlayarak kullanmışlardır [28].

Ramgopal Mushini ve Dan Simon uçak gaz türbini motoru sağlık tahmini problemi için “optimal veya alternatif ölçüm parametre setlerini incelemeye dayanan” bir yöntem üzerine çalışmışlardır [29].

İrem Tumer ve Anupa Bajwa ticari uçakların mevcut motor sistemlerinin eksiklerini belirlemek için “NASA Ames Araştırma Merkezi'nde motor sağlığı ve izleme araştırmalarına öncü olarak hizmet etmeyi amaçlayan” bir yöntem üzerine çalışmışlardır. Bu yöntemde ilk olarak uygulama durumu araştırılmış ardından alternatif yöntemleri araştırmak için yapılmıştır [30].

Daniel E. Viassolo ve arkadaşları motor kontrolleri, motor arıza tespiti ve izolasyonu ve motor sağlığı yönetimi için “General Electric Global Research ve General Electric Aviation'daki son programlara dayanan” bir yöntem üzerine çalışmışlardır. Bu yöntemde yüksek kaliteli motor modelleri kullanan uygulamalar kullanılarak ayrıntılı olarak çeşitli vaka çalışmaları yapılmıştır [31].

Dan Simon biyocoğrafyanın matematiğini yeni bir alanın gelişimi için “BBO (Biogeography Based Optimization)’nun Genetik Algoritmalar ve parçacık sürü optimizasyonuna dayanan” bir yöntem üzerine çalışmışlardır. Bu yöntemde

BBO(Biogeography Based Optimization)'yu, genetik algoritmalar ve parçacık sürü optimizasyonunun birden çok yerel optimaldeki yüksek boyutlu problem çözümü için kullanarak aynı problem türlerinin çoğuna uygulanabilir hale getirmiştir [32].

Peng Zhang ve Jinqun Huang bileşenlerin sağlık durumunu izlemek ve ciddi hasarları önlemek için “geçici gaz yolu ölçümlerine dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde motor izleme ve diyagnostik, bileşenlerin parametrelerinin sağlık tahmini ile gerçekleştirilmiştir [33].

Ashish Babbar ve arkadaşları motor sağlığını ve performansını tahmin etmek için “Egzoz Gazı Sıcaklığı (EGT), Yakıt Akışı (FF), Motor Fan Hızları (N1 ve N2), Yağ Basıncı (OIP) ve Yağ Sıcaklığı (OIT) gibi çeşitli uçuş parametrelerine dayanan” bir yöntem üzerine çalışmışlardır. Bu yöntemde belirli bir uçuş sırasında motor davranışını belirlemeye ve gelecekteki uçuşların uçuş parametresi koşullarını tahmin ederek motor performansını tahmin etmeye yardımcı olan teşhis ve prognostik şemalar geliştirilmiştir [34].

Soumik Sarkar ve arkadaşları motor sisteminin çoklu kritik parametrelerindeki anormallikleri tahmin etmek için “Sembolik Dinamik Filtreleme (SDF) adı verilen istatistiksel bir model tanıma aracına dayanan” bir yöntem üzerinde çalışmışlardır [35].

Xiaodong Zhang ve arkadaşları uçak motorlarının arıza tespit ve izolasyon (FDI) yöntemi için “önceki belgelerde geliştirilen ve arıza tespiti için bir arıza tespit tahmin edicisinin kullanıldığı genel bir mimariyi takip eden” bir yöntem üzerinde çalışmışlardır [36].

Martha A Zaidan ve arkadaşları motor nüfusunun geçmiş hizmet içi verileri ve iletilen performans ölçümlerini birleştirmek için “kalan yararlı ömrün tahminine dayanan” bir yöntem üzerinde çalışmışlardır [37].

Md Monzurul Alam ve arkadaşları uçak türbin motoru için bir prognostik sistem tasarlamak için “yapay sinir ağı (YSA) tabanlı bir yaklaşıma dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde parametrelerin sağlık eğilimini modellemek için bir tahmin yöntemi kullanılarak model otoregresif teknik ile geliştirilmiş ve tüm veri işleme çevrimiçi olarak yapılmıştır [38].

Zigmund Bluvband ve Sergey Porotsky askıya alınan zaman serileri için prognostik ve sağlık yönetimi “SVR ve SVC yöntemlerinin (Destek Vektör Regresyonu ve Destek Vektör Sınıflandırması) modifikasyonuna dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde en uygun RUL (Remaining Useful Life)'u tahmin etmek için askıya alınmış zaman serilerini kullanarak önerilen modelin saf denetimli öğrenme tabanlı modelden çok daha iyi tahmin gerçekleştirdiği gözlenmiştir [39].

Chunsheng Yang ve arkadaşları TTF (Time To Failure) tahmini için tahmine dayalı modellerin geliştirilmesi “makine öğrenimi tabanlı modellerin geliştirilmesine dayanan” bir yöntem üzerinde çalışmışlardır. Bu yöntemde makine öğrenimi ve veri madenciliği tekniklerini kullanarak TTF (Time To Failure)'yi tahmin etmek için öngörücü modeller geliştirmenin etkili ve uygulanabilir bir yolu olduğunu göstermişlerdir [40].

Zohra Bouzidi ve arkadaşları veriye dayalı bir prognostik sistemin performans ölçümü için “ampirik verilere dayalı modelleri öğrenen” bir yöntem üzerinde çalışmışlardır. Bu yöntemde tarihsel verileri kullanarak prognostik sistemin performansını doğruluk, kesinlik, MSE (Ortalama Karesel Hata) ve eğitim süresine göre ölçmüşlerdir [3].

Guoxing Lan ve arkadaşları LSTM (Long Short-Term Memory) sinir ağları kullanarak, “turbofan motorunun kalan yararlı ömür tahminini yapmak amacıyla öklid uzaklık tabanlı” bir yöntem üzerinde çalışmışlardır. Bu yöntemde LSTM (Long Short-Term Memory) modeli kullanılarak RUL tahmininde veriye dayalı yaklaşımlar geliştirilmiştir [41].

2. BÖLÜM

ARAŞTIRMA YÖNTEMLERİ

2.1. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin işleyişi örnek alınarak geliştirilmiş bir sistemdir. Karmaşık hesaplama sistemi vardır. Nöronlar farklı şekillerde birbirlerine bağlanarak ağlar meydana getirirler. YSA'lar, normal şartlarda bir insanın düşünme ve gözlem yapmaya yönelik içgüdüsel yeteneklerini gerektiren sorunlara çözüm üretmektedir. İnsan beyninin çalışma prensibi YSA modellerinin geliştirilmesinde, ilerletilmesinde ve çeşitlenmesinde kullanılmıştır [42]. YSA günümüzde askeriye, havacılık, mühendislik, tıp, tarım, hayvancılık, uzay ve birçok tahmin yönteminde kullanılmaktadır.

2.2. Biyolojik Nöron (Sinir Ağı)

Biyolojik sinir ağları, veriyi alıp, yorumlayıp uygun bir yorumla birlikte cevap üreten bir merkezin kontrolünde bulunan alıcı ve tepki nöronlardan meydana gelir. Sistemin merkezinde beyin bulunur. Şekil 2.1'de gösterilmiştir.




Şekil 2.1. Biyolojik sinir sistemi blok gösterimi

Alıcı nöronların görevi ortamdan aldıkları uyarıları elektriksel sinyale çevirerek beyne göndermektir. Tepki nöronlarının görevi ise beyin ürettiği elektrik sinyalini gerekli tepkilere çevirmektir. Nöronlar aynı zamanda sinir hücreleri olarak adlandırılır. 3

katmandan oluşur. Birincisi gövdedir (cell body). İkincisi gövde girdisi olan sinyal alıcılar (dendrit). Ve sonuncusu gövde çıktısı olan sinyal ileticilerdir (akson). Şekil 2.2’de gösterilmiştir [42].

2.2.1. Yapay Nöron

Yapay nöronun bir diğer adı işlemci elemandır. YSA’lar birbirine bağlı birçok elemandan meydana gelirler. Yapay sinir sistemi ve biyolojik sinir sistemi arasındaki benzeşimler Tablo 2.1’de verilmiştir [42]. YSA ile istatistiksel prensipler arasındaki benzerlik ve ilişkiler Tablo 2.2’de gösterilmiştir [42]. İşlemci eleman 5 kısımdan oluşmaktadır. Bunlar giriş, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkıştır. p girişli nöronun gösterimi Şekil 2.3’te verilmiştir. Burada x girişi, y çıkışı, F fonksiyonu, p nöron girdi sayısını, n çıkış sayısını, w ise ağırlığı ifade etmektedir [43].




Şekil 2.2. Biyolojik nöron

Tablo 2.1. YSA ve biyolojik sinir sistemi benzerlikleri

Biyolojik Sinir Sistemi	YSA
Nöron	İşlemci Eleman
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Tablo 2.2. YSA ile istatistiksel prensipler arasındaki terminolojik benzerlikler

İstatistiksel	YSA
Model	Ağ
Tahmin	Öğrenme
Regresyon	Danışmalı Öğrenme
İnterpolasyon	Genelleştirme
Gözlem	Öğrenme Algoritması
Parametre	Ağ Parametreleri (ağırlıklar, katsayılar)
Bağımsız Değişken	Giriş Verileri
Bağımlı Değişken	Çıkış Verileri
Sınır Regresyonu	Ağırlık Budama İşlemi



Şekil 2.3. p girişli bir nöronun temel gösterim grafiği

2.3. YSA'nın Avantajları

Yapay sinir ağlarının diğer sistemlere göre üstün yönleri doğrusal olmaması, örneklerden öğrenebilmesi, genelleme yapabilmesi, adaptasyonu, gürültüye karşı duyarlı olması, donanımı ve kolay erişimidir. İşlemci eleman doğrusal olmadığı için YSA'nın neredeyse tabiattaki tüm sorunlara uygulanabilirliği artmaktadır. Uygulanabilirliğini doğrusal olmayan transfer fonksiyonları sağlamaktadır. Yapay sinir ağlarının bir problemi öğrenebilmesi için o problemin giriş verilerini veya giriş verilerine denk gelen çıkış verilerini bilmesi yeterli gelir ve bu özelliği yapay sinir ağlarını diğer yaklaşımlardan ayırır. Ancak YSA yapısının uygun ve veri sayılarının yeterli olması gerekmektedir. Eğitim aşaması bittikten sonra eğitim kümesi dışındaki kümeler içinde yapay sinir ağı çıkış verileri kazandırabilme özelliğine sahiptir. Bu çıkış verilerinin geçerliliği, bilinen test verilerinin çıkışı ile yapay sinir ağlarının çıkışı

karşılaştırılarak elde edilir. Yapılan hatalar belli sınırlar dahilindeyse kabul edilir. Bu işleme genelleme testi adı verilir ve deneysel verilerin hesaplanmasında büyük kolaylık sağlar. Zamandan tasarruf ettirmektedir. Bir diğer avantajı sürekli eğitilebilme özelliğidir. Şekil 2.3'te x ve w olarak tanımladığımız giriş ve ağırlıklar yeterli miktarda sağlanamaz, bozuk veri girişi veya ağırlıkla ilgili sorun olursa bunu tolere ederek genelleme yapar ve belli doğruluk sınırları dahilinde çıkış verisi verir. YSA bu işlemi verileri ağırlıklar üzerine paralel olarak dağıtmakla sağlamaktadır. Geleneksel yöntemlere göre veriyi daha iyi korur, saklar ve işler. Yine ağırlıkları paralel dağıtma özelliği sayesinde gürültüyü dengelemektedir. Yapay sinir ağlarının farklı algoritmalarda çalışmasının temel sebebi çok geniş ölçekli işlemci sahibi olmasıdır. Bu özelliği uygulamalarda çok önemlidir. Yapay sinir ağlarının kullanımını arttıran ve yaygınlaştıran diğer önemli özelliği ise yazılımın ucuz olması ve internette rahatlıkla erişilebilir olmasıdır [44].

2.4. Yapay Sinir Ağlarının Sınıflandırılması

Sınıflandırma işlemi öğrenme algoritmaları ve yapılarına göre gerçekleştirilmektedir. Yapay sinir ağlarındaki işaretin akış yönüne ve yapısına bağlı olarak, ileri beslemeli (feedforward) ve geri beslemeli (feedback veya recurrent) ağlar beslemeli olmak üzere iki çeşittir [44].


2.4.1. İleri Beslemeli Ağlar (Feedforward Networks):

İleri beslemeli ağlar yapay sinir ağlarının en temel ve en ilkel yapısıdır. Yapay nöronlar ileri beslemeli ağlarda katmanlardan oluşurlar. Bu ağda bilgiler yalnızca ileri doğru, çıkış katmanına doğru hareket ederler. Şekil 2.4'te bir ileri beslemeli ağın blok diyagramı gösterilmiştir.


2.4.2. Geri Beslemeli Ağlar (Recurrent Networks):

Bir geri beslemeli sinir ağı çıkış ve ara katmanlardaki çıkışlardan giriş birimlerine veya önceki ara katmanlara geri beslenmenin yapıldığı bir ağ yapısıdır. Geri beslemeli ağın dinamik hafızası mevcuttur. Bu nöron yapısındaki ağın çıkışı bir andaki çıkış hem o anki hem de önceki girişleri yansıtır. Bu ağlar özellikle bazı çeşitli zaman serilerinin

tahmininde oldukça başarı sağlamıştır. Şekil 2.5'te geri beslemeli ağı blok diyagramı gösterilmiştir [44].



Şekil 2.4. İleri beslemeli ağ



Şekil 2.5. Geri beslemeli ağ

2.5. Öğrenme Algoritmaları

Çalışma alanına göre birçok öğrenme algoritması bulunmaktadır. Öğrenme algoritmalarının büyük çoğunluğu Hebb kuralından esinlenilmiştir. Hebb'den sonra yaygın olarak Delta, Kohen, Hopfield öğrenme algoritmalarından türetilmişlerdir. Danışmanlı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve takviyeli öğrenme (reinforcement learning) olmak üzere 3 farklı öğrenme algoritması vardır. YSA'nın yapısı ve öğrenme kuralı, uygulanan öğrenme metoduna göre belirlenmektedir [14]. Geri yayılım Algoritması (Backpropagation-BP), Esnek Yayılım (Resilient Propagation-RP) Algoritması, Delta-Bar-Delta (DBD), Genetik

Algoritma, Levenberg-Marquardt Yöntemi (LMM) gibi yaygın olarak kullanılan öğrenme algoritmaları bulunmaktadır.

2.6. Regresyon Analizi

Regresyon analizi, aralarında sebep-sonuç ilişkisi olan iki veya ikiden fazla değişken arasındaki ilişkiyi tespit etmek ve bu ilişkiyi kullanarak o konu ile ilgili tahminler ya da kestirimler yapabilmek için yapılır. Gerçek hayatta birçok olayda sebep sonuç ilişkisine rastlanır. Bu analiz yönteminde iki veya ikiden fazla değişken arasındaki ilişkiyi açıklamak için matematiksel bir yöntem kullanılır. Bu yöntem de regresyon analizi olarak isimlendirilir. Eşitlik 2.1’de basit regresyon analizi anlatılmıştır [45].

$$Y = \alpha + \beta X + \varepsilon \quad (2.1)$$

Bir bağımlı, bir de bağımsız değişken içeren bir modeldir. Hali hazırda Y, bağımlı (sonuç) değişken olup belli bir hataya sahip olduğu kabul edilir. X, bağımsız (sebep) değişkeni olup hatasız ölçüldüğü kabul edilir. α , sabit olup $X=0$ olduğunda Y’nin aldığı değerdir. β ise regresyon katsayısı olup, X’in kendi birimi cinsinden 1 birim değişmesine karşılık Y’de kendi birimi cinsinden meydana gelecek değişme miktarını ifade eder. ε ; tesadüfi hata terimi olup ortalaması sıfır, varyansı σ^2 olan normal dağılıma sahip olduğu varsayılır [45].

2.6.1. İstatiksel Regresyon Analizi

Regresyon, değişkenler arasındaki ilişki ve bağlantıların tetkik edilmesi demektir. Bu analizde değişkenlerden biri ya da birden fazlasını, diğer bir ya da birden fazla değişkeni ne kadar etkilediği araştırılır. Regresyon analizi ile bağımsız ve bağımlı değişkenlerin aralarındaki ilişkinin seviyesi fonksiyonel biçimde açıklanır. Yani, bilinmeyen parametrelerin tahmin edilmesi için oluşturulan bu modelde, bağımsız değişkenlerin belirli bazı değerleri için bağımlı değişkenin katsayı değerleri belirlenir [46].

2.6.2. Tek Değişkenli Regresyon Analizi

Tek değişkenli regresyon analizi bir bağımlı değişken ve bir bağımsız değişken arasındaki ilişkiyi tetkik eden analiz yöntemidir. Bu analizle bağımlı ve bağımsız

değişkenler arasındaki doğrusal (lineer) ilişkiyi temsil eden bir doğru denklemi formüle edilmektedir. Korelasyon analizinde olduğu gibi regresyon analizinde üzerinde durulan ilişki, değişkenler arasındaki doğrusal ilişkidir. Bu doğrunun hesaplanması ise en küçük kareler yöntemi yardımıyla yapılmaktadır.

2.6.3. Çok Değişkenli Regresyon Analizi

Çoklu regresyonda iki ve tek değişkenli regresyona ek olarak bağımlı değişken üzerinde birden fazla bağımsız değişkenin hepsinin etkisi araştırılır. x_1 'den başlayarak x_n 'e kadar olan bağımsız değişkenlerle y bağımlı değişkeni arasındaki ilişkiyi araştırır. Çok değişkenli doğrusal regresyon analizinde, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi regresyon denkleminin formülü aşağıdaki eşitlik ile ifade edilmektedir

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n + \varepsilon \quad (2.2)$$

k tane örnek için y bağımlı ve x bağımsız değişkenlerine ait çoklu regresyon denklemi:

$$y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \cdots + \beta_p x_{1k} + \varepsilon_1 \quad (2.3)$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \cdots + \beta_p x_{2k} + \varepsilon_2 \quad (2.4)$$

$$y_k = \beta_0 + \beta_1 x_{k1} + \beta_2 x_{k2} + \cdots + \beta_p x_{kk} + \varepsilon_k \quad (2.5)$$

şeklindedir [47].

Burada y, örneklem için bağımlı değişken değerini temsil ederken, $x_1, x_2, \dots, x_k$ k bağımsız değişken sayısını, $\beta_0, \beta_1, \dots, \beta_k$ regresyon parametrelerini, ε ise rassal sapma değerini temsil etmektedir [47].

y: $k \times 1$ boyutlu bağımlı değişken vektörünü, x: $k \times (k + 1)$ boyutlu bağımsız değişken matrisini, β : $(k + 1) \times 1$ boyutlu regresyon katsayıları vektörünü, ε : $k \times 1$ boyutlu hata vektörünü temsil etmektedir. Regresyon modeli eşitlik (2.6) ile veya eşitlik 2.7'deki matris ile gösterilmektedir.

$$Y = X\beta + \varepsilon \quad (2.6)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_K \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ & \vdots & & \ddots & \vdots \\ 1 & x_{K1} & x_{K2} & \cdots & x_{Kk} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_K \end{bmatrix} \quad (2.7)$$

Hatalar ile ilgili bazı gösterimler aşağıda verilmiştir:

$$E(\varepsilon_j) = 0 \quad (2.8)$$

$$Var(\varepsilon_j) = \sigma(sabit) \quad (2.9)$$

$$Cov(\varepsilon_j, \varepsilon_l) = 0, j \neq l \quad (2.10)$$

k tane bağımsız değişken (x) ile M tane bağımlı değişken (y)'ye ait çok değişkenli çoklu regresyon modeli aşağıda eşitliklerde verildiği gibidir:

$$y_1 = \beta_{01} + \beta_{11}x_1 + \beta_{21}x_2 + \cdots + \beta_{k1}x_k + \varepsilon_1 \quad (2.11)$$

$$y_2 = \beta_{02} + \beta_{12}x_1 + \beta_{22}x_2 + \cdots + \beta_{k2}x_k + \varepsilon_2 \quad (2.12)$$

$$y_m = \beta_{0m} + \beta_{1m}x_1 + \beta_{2m}x_2 + \cdots + \beta_{km}x_k + \varepsilon_m \quad (2.13)$$

Burada y: k×M boyutlu bağımlı değişken matrisini, x: k×(k+1) boyutlu bağımsız değişken matrisini, β: (k+1)×M boyutlu regresyon katsayıları matrisini, ε: k×M boyutlu hata matrisini ifade etmektedir. Bu çalışmada, $x_1, x_2, \dots, x_k$ gözlemlenebilen değerler, y sonuç ve $\beta_j, j=0,1, \dots, k$ regresyon sayıları olarak ifade edilmektedir. β_j parametreleri x_i 'lerdeki değişim için y'de olması tahmin edilen değişimi ve ε ise hatayı temsil etmektedir. Bu tez çalışmasında regresyon analizi için kullanılan formül eşitlik (2.14)'te gösterilmiştir.

$$N1 = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \beta_6 X_6 + \beta_7 X_7 + \beta_8 X_8 \quad (2.14)$$

Buradaki x_i değerleri sırasıyla airspeed, angle of attack, roll, heading, latitude acceleriton, speed break, total air temperature, exhaust gas temperature, $\beta_0, \beta_1, \beta_2, \dots, \beta_8$ ise bilinmeyen etkenlerdir. Regresyon modelinden elde edilen katsayıların anlamlı ya da anlamsız olduğu T testi uygulanarak bulunur. T testine ait anlamlılık değeri (Sig.) 0,05'ten küçük ise varsayım olarak kabul edilir ve modelde

bulunan katsayıların anlamlı olduğu sonucuna ulaşılır [48]. Buradaki Sig. değeri istatistiksel anlamlılık derecesinin belirlenmesi için kullanılan bir değerdir. Anlamlılık derecesi genellikle literatürde 0,05 ve 0,01 aralığında alınır. Anlamlılık derecesi 0,05 ise %95 güven aralığını, anlamlılık derecesi 0,01 ise %99 güven aralığını ifade eder. “Sig.” değerinin literatürdeki değerlendirmesinin genel yaklaşımı eşitlik (2.14)’te gösterilmiştir [49]. Tez çalışmamızda geliştirdiğimiz modelin “Sig.” değerinin yorumlaması Tablo 2.3’e göre yapılmıştır.

Tablo 2.3. Sig değerinin yorumu [50]

Sig. Değeri	Yorumu
$0,01 < \text{Sig.} \leq 0,05$	Sonuçlar anlamlı
$0,001 \leq \text{Sig.} < 0,01$	Sonuçlar yüksek derecede anlamlı
$\text{Sig.} < 0,001$	Sonuçlar oldukça yüksek derecede anlamlı
$0,05 \leq \text{Sig.} < 0,10$	Sonuçlar istatistiksel olarak anlamlı sayılmamaktadır
$\text{Sig.} > 0,10$	İstatistiksel önemi olan bir eğilim bazen kayıtlı edilmiştir.

2.7. Korelasyon Analizi

Korelasyon analizi iki veya ikiden daha fazla değişken arasında bir ilişkinin olup olmadığı, şayet ilişki varsa bu ilişkinin şiddetini ortaya koyan bir istatistiki analizdir. Korelasyon katsayısı -1 ile +1 ($-1 \leq r \leq +1$) arasında değişen değerler almakla birlikte, korelasyon kat sayılarında 0,00 ile 0,25 arası değerin ‘çok zayıf’, 0,26 ile 0,49 arası değerin ‘zayıf’, 0,50 ile 0,69 arası değerin ‘orta’, 0,70 ile 0,89 arası değerin ‘yüksek’, 0,90 ile 1,00 arası değerin ise ‘çok yüksek’ olduğu ifade edilir. Korelasyon katsayısının pozitif olması değişkenler arasında doğrusal bir ilişkinin olduğunu, negatif olması ise ters yönlü bir ilişkinin olduğunu göstermektedir [51].

2.8. Tahmin Modellerinin Doğruluklarının Ölçülmesi

Tahmin modellerinin performansının değerlendirilmesinde kullanılan pek çok yöntem vardır. Aşağıda bunlardan bazıları hakkında bilgi verilmiştir.

2.8.1. Ortalama Hata (Mean Error-ME)

Ortalama hata bir makine öğrenmesi modelinin öngördüğü tahmin değerleri ile gerçek değerlerin arasındaki hata ortalamasıdır [52]. Ortalama hata formülü aşağıda eşitlik (2.15)'te verilmiştir:

$$ME = \frac{1}{n} \sum_{j=1}^n e_j \quad (2.15)$$

2.8.2. Ortalama Hata Yüzdesi (Mean Percentage Error-MPE)

Bir makine öğrenmesi modelinin tahmin ettiği değerler ile gerçek değerleri arasındaki farkın ortalama yüzdesidir [52]. Ortalama Hata Yüzdesi formülü aşağıda eşitlik (2.16)'da verilmiştir:

$$MPE = \frac{100}{n} \sum_{j=1}^n \frac{e_j}{A_j} \quad (2.16)$$

2.8.3. Ortalama Karesel Hata (Mean Squared Error-MSE)

Ortalama karesel hata, bir makine öğrenmesi modelinin, tahminleyicinin performansını ölçer, her zaman pozitif değerlidir. MSE değeri sıfıra yakın olan tahminleyiciler daha iyi bir performans göstermektedir [53]. Ortalama karesel hata formülü aşağıda eşitlik (2.17)'de verilmiştir:

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (2.17)$$

2.8.4. Ortalama Karesel Hatanın Karekökü (Root Mean Square Error-RMSE)

Bir makine öğrenmesi modelinin, tahminleyicinin tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen kuadratik bir metriktir [54]. Ortalama karesel hatanın karekökü formülü aşağıda eşitlik (2.18)'de verilmiştir:

$$RMSE = \sqrt{\frac{\sum_{j=1}^n e_j^2}{n}}$$

$$RMSE = \sqrt{MSE} \quad (2.18)$$

2.8.5. Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)

Yapılan tahminlerin doğruluğunu ölçmek için kullanılır [52]. Ortalama mutlak hata yüzdesi formülü aşağıda eşitlik (2.19)'da verilmiştir:

$$MAPE = \frac{100}{n} \sum_j^n \frac{|e_j|}{|A_j|} \quad (2.19)$$

3. BÖLÜM

BULGULAR, SONUÇ, ÖNERİLER

3.1. Bulgular

3.1.1. N1 bağımlı değişkenini etkileyen bağımsız değişkenlerin anlaşılması için korelasyon analizi ve çoklu regresyon analizi

Korelasyon Analizi:

Değişkenlerin arasında bir ilişki olup olmadığı, eğer bir ilişki var ise bunun derecesi ve yönü korelasyon analizi ile belirlenir. Korelasyon analizinde korelasyon katsayısı dikkate alınarak gerekli yorumlar yapılabilir. Korelasyon katsayısı -1 ile +1 arasında değişebilir. Korelasyon katsayısının + olmasının anlamı ilişki pozitif yönlü, - olması ise zıt yönlü ilişkinin olduğu anlamına gelmektedir. Bunun anlamı değişkenler birlikte artıyor veya azalıyorsa pozitif yönde, değişkenlerden biri artarken diğeri azalıyorsa ise negatif yönde bir ilişki vardır. Ancak korelasyon katsayısı değişkenler arasındaki nedensel ilişkiyi göstermez [51].

Tablo 3.1. Pearson korelasyon katsayısının yorumu [55]

Korelasyon değer aralığı	Yorumu
0.00-0.19	Çok zayıf
0.20-0.39	Zayıf
0.40-0.59	Orta
0.60-0.79	Güçlü
0.80-1.0	Çok güçlü

Regresyon analizi:

Regresyon Analizi, değişkenlerin arasındaki matematiksel ilişkiyi kurmak ve bu ilişkiyi incelemek maksatlı kullanılan bir istatistiksel yöntemdir. Regresyon analizindeki değişkenler bağımlı değişken ve bağımsız değişken olarak nitelendirilirler. **Bağımlı**

değişken, bağımsız değişken tarafından etkilenen ya da bağımsız değişkene bağlı olarak değiştiği ifade edilen değişkendir. **Bağımsız değişken** ise, bağımlı değişken üzerinde anlamlı bir etkisi olduğu düşünülen değişkendir. Kurulan regresyon modelinde bir bağımsız değişken ile model kurulmuş ise bu tip regresyon modellerine **basit doğrusal regresyon** adı verilir. Bağımlı değişkenimizin tek bir bağımsız değişken açıklamakta yetersiz kaldığı durumlarda birden fazla bağımsız değişken ile modelleme yapılabilir. Böyle birden fazla sayıda bağımsız değişken ile modelleme yapıldığı durumlara **çok değişkenli doğrusal regresyon** denilmektedir.

Veri kümemizdeki N1 bağımsız değişkenimiz ve N2, Altitude, Airspeed, Ground Speed, Pitch, Angle Of Attack, Roll, Heading, Vertical Acceleration, Latitude Acceleration, Longitude Acceleration, Speed Break, Total Air Temperature, Exhaust Gas Temperature bağımsız değişkenlerimizi dikkate alarak elde ettiğimiz korelasyon analizinin sonucu aşağıda Tablo 3.2 de verilmiştir.

Tablo 3.2’de değişkenler arası korelasyon değerleri ele alındığında Altitude, Airspeed, Ground Speed, Pitch, Longitude Acceleration ve Exhaust Gas Temperature bağımsız değişkenleri ile N1 bağımlı değişkeni arasında **pozitif yönlü güçlü düzeyde** istatistiksel olarak anlamlı bir ilişki olduğu saptanmıştır. Airspeed bağımsız değişkeni ile N1 bağımlı değişkeni arasında **pozitif yönlü orta düzeyde** ilişki olduğu anlaşılmaktadır. Latitude Acceleration, Heading bağımsız değişkenleri ile N1 bağımlı değişkeni arasında **pozitif yönlü zayıf düzeyde** istatistik olarak anlamlı bir ilişki olduğu tespit edilmiştir. Yukarıda bahsi geçen değişkenlerden geriye kalan bağımsız değişkenler ile N1 bağımlı değişkenimiz arasındaki korelasyon ilişkisinin negatif yönlü olduğu analiz sonucunda elde edilmiştir. Bu değişkenlerden N1 bağımlı değişkeni ile Total Air Temperature bağımsız değişkeni arasında **negatif yönlü güçlü düzeyde**, Angle Of Attack bağımsız değişkeni ile **negatif yönlü orta düzeyde**, Roll bağımsız değişkeni ile **negatif yönlü zayıf düzeyde** ve Vertical Acceleration, Speed Break bağımsız değişkenleri ile de **negatif yönlü zayıf düzeyde** istatistiksel ilişki olduğu gözlemlenmiştir.

Tablo 3.2. Korelasyon analizi sonucu

Değişkenler	N1	N2	Altitude	Airspeed	Ground Speed	Pitch	AOA	Roll	Heading	Vertical Acceleration	Latitude Acceleration	Longitude Acceleration	Speed Break	TAT	EGT
N1	1														
N2	,960**	1													
Altitude	,647**	,565**	1												
Airspeed	,565**	,623**	,780**	1											
Ground Speed	,658**	,655**	,930**	,953**	1										
Pitch	,685**	,688**	0,012	,132**	,104**	1									
AOA	-,505**	-,468**	-,763**	-,745**	-,795**	0,013	1								
Roll	-,250**	-,244**	-,198**	-,182**	-,200**	-,186**	,223**	1							
Heading	,263**	,426**	0,026	,256**	,181**	,197**	-,166**	-,0011	1						
Vertical Acceleration	-,120**	-,103**	-,088**	-,058*	-,076**	-,109**	,209**	,220**	,063*	1					
Latitude Acceleration	,289**	,307**	,244**	,340**	,317**	,206**	-,318**	-,215**	,331**	-,079**	1				
Longitude Acceleration	,682**	,670**	-0,001	,082**	,066*	,892**	0,037	-,153**	,134**	-,088**	,180**	1			
Speed Break	-,121**	-,059*	-,261**	-,304**	-,287**	-,098**	,079**	,094**	,259**	,076**	-,154**	-,274**	1		
TAT	-,639**	-,571**	-,974**	-,739**	-,898**	0	,735**	,185**	-,088**	,080**	-,227**	0,036	,165**	1	
EGT	,718**	,652**	0,046	0,01	0,048	,878**	-0,005	-,122**	,067*	-,113**	,151**	,885**	-,073**	-,0011	1

*n=1435, * p<0,05, ** p<0,01; İlişkinin şiddeti $0,70 \leq r_{xy} \leq 1$ Güçlü, $0,40 \leq r_{xy} < 0,70$ Orta, $0 < r_{xy} < 0,40$ Düşük

Regresyon analizi öncesinde bağımsız değişkenler arası korelasyona bakıldığında bağımsız değişkenler arası korelasyonun ya anlamsız ya da düşük düzeyde olması modelin daha sağlıklı olması için istenen bir durumdur. N1 bağımlı değişken ve N2 bağımsız değişkenin oldukça yüksek bir korelasyon değerine sahiptir. Bunun anlamı N1 bağımlı değişkeni ile N2 bağımsız değişkeni birlikte hareket ediyor demektir ve modellememizin sağlıklı olması açısından N2 bağımsız değişkeni modelimizden çıkarılması gerekmektedir. Bu birlikte hareket etme durumunu ortadan kaldırmak adına N2 bağımsız değişkenimiz modelden çıkartılmıştır. Modeldeki bağımsız değişkenlerin arasındaki yüksek korelasyon modelde çoklu doğrusallık problemi olarak karşımıza çıkar. Bu nedenle Airspeed, Ground Speed, Angle Of Attack ve Total Air Temperature değişkenlerinin modele bozabileceği öngörülmüştür. Bu durumu incelemek adına yeni veri kümemiz ile çoklu doğrusal regresyon modeline bakılmıştır. EGT, Angle Of Attack, Speed Break, Vertical Acceleration, Roll, Heading, Latitude Acceleration, Total Air Temperature, Airspeed, Pitch, Longitude Acceleration, Altitude, Ground Speed bağımsız değişkenlerimizin, bağımlı değişkenimiz olan N1değişkenin üzerindeki etkisini gösteren regresyon analizinin sonuçları aşağıda Şekil 3.1, Şekil 3.2, Şekil 3.3 ve Şekil 3.4'te verilmiştir.

Model Summary ^b										
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	.987 ^a	.975	.975	4,0283	.975	4289,341	13	1421	.000	.323
a. Predictors: (Constant), Exhaust Gas Temperature EGT, Angle Of Attack AOA, Speed Break, Vertical Accelariton, Roll, Heading, Latitude Acceleration, Total Air Temperature TAT, Airspeed, Pitch, Longitude Acceleration, Altitude, Ground Speed										
b. Dependent Variable: N1										

Şekil 3.1. N1 eğitim verileri için model özeti sonuçları

Şekil 3.1'de yapılan modellemenin sonucunda adjusted R^2 ve sig. Değerine bakılarak kurulan modelin anlamlı olduğu ve bağımsız 13 değişkenin bağımlı değişkeni % 97.5 ini açıkladığını geriye kalan %2.5'luk kısım ise başka değişkenlerce açıklanmaktadır.

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	904835,994	13	69602,769	4289,341	,000 ^b
	Residual	23058,445	1421	16,227		
	Total	927894,439	1434			
a. Dependent Variable: N1						
b. Predictors: (Constant), Exhaust Gas Temperature EGT, Angle Of Attack AOA, Speed Break, Vertical Acceleration, Roll, Heading, Latitude Acceleration, Total Air Temperature TAT, Airspeed, Pitch, Longitude Acceleration, Altitude, Ground Speed						

Şekil 3.2. N1 eğitim verileri için ANOVA sonuçları

Coefficients ^a								
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	2,830	3,058		,925	,355		
	Altitude	,000	,000	,049	1,101	,271	,009	113,788
	Airspeed	-,058	,017	-,181	-3,426	,001	,006	159,918
	Ground Speed	,083	,015	,504	5,644	,000	,002	455,681
	Pitch	-,172	,079	-,026	-2,171	,030	,119	8,419
	Angle Of Attack AOA	,249	,111	,018	2,235	,026	,277	3,616
	Roll	-,213	,028	-,034	-7,550	,000	,845	1,184
	Heading	,045	,003	,089	15,878	,000	,560	1,785
	Vertical Acceleration	-2,054	2,555	-,004	-,804	,422	,862	1,160
	Latitude Acceleration	-38,438	8,187	-,023	-4,695	,000	,734	1,362
	Longitude Acceleration	113,195	3,511	,413	32,239	,000	,107	9,383
	Speed Break	,774	,034	,145	22,975	,000	,440	2,273
	Total Air Temperature TAT	-,448	,034	-,311	-13,378	,000	,032	30,956
	Exhaust Gas Temperature EGT	,078	,003	,351	27,442	,000	,107	9,369
a. Dependent Variable: N1								

Şekil 3.3. N1 parametresi için çoklu regresyon analiz sonuçları

EGT, Angle Of Attack, Speed Break, Vertical Acceleration, Roll, Heading, Latitude Acceleration, Total Air Temperature, Airspeed, Pitch, Longitude Acceleration, Altitude, Ground Speed bağımsız değişkenleri kullanılarak bağımlı değişkenimiz olan N1 yorumlamak amacıyla çok değişkenli regresyon analizi yapılmıştır. Analiz sonucunda anlamlı bir regresyon modeli, $F(13,1421)=4289.341$, $p<.005$ değeri ve bağımlı değişkendeki varyansın %97.5'inin (Adjusted $R^2=.975$) bağımsız değişkenler tarafından açıklandığı bulunmuştur. Geriye kalan %2.5'lük kısım ise başka değişkenlerce açıklanmaktadır. Buna göre bağımsız Airspeed değişkenimiz, $\beta=-0.181$, $t(1421)=-3.426$, Ground speed değişkenimiz, $\beta=0.504$, $t(1421)=5.644$, Roll değişkenimiz, $\beta=-0.034$, $t(1421)=-7.55$, Heading değişkenimiz, $\beta=0.089$, $t(1421)=15.878$, Heading değişkenimiz, $\beta=0.089$, $t(1421)=15.878$, Latitude Acceleration değişkenimiz, $\beta=-0.023$, $t(1421)=-4.695$, Longitude Acceleration değişkenimiz, $\beta=0.413$, $t(1421)=32.239$, Speed Break değişkenimiz, $\beta=0.145$, $t(1421)=22.975$, Total Air Temperature değişkenimiz, $\beta=-0.311$, $t(1421)=-13.378$, Exhaust Gas Temperature değişkenimiz, $\beta=0.351$, $t(1421)=27.442$ değerleri ve sig. anlamlılık değerine göre ($p<.005$) model için anlamlı değişkenlerdir. Altitude, Pitch, Angle of Attach ve Vertical Acceleration değişkenleri ise kurulan modelde $p>.005$ olduğu için anlamsızdır. Kurulan modelde VIF değerleri incelenildiğinde ise $VIF>10$ olan değerler gözükmemektedir. Ground Speed $VIF=455.681$, Airspeed $VIF=159.918$, Altitude $VIF=113.788$ ve Total Air Temperature $VIF=30.956$ dır. VIF değerinin yüksek olması çoklu doğrusallık problemine işaret eder ve istenmeyen bir durumdur. Bu istenmeyen durumu engellemek adına VIF değeri en yüksek olandan başlamak kaydı ile VIF değeri yüksek bağımsız değişkenler teker teker elenerek model yeniden kurulmuş ve model anlamlı olana kadar devam edilmiştir. en son elde edilen modele ait sonuçların tabloları aşağıda Şekil 3.4, Şekil 3.5, Şekil 3.6 ve Şekil 3.7'de verilmiştir.

Variables Entered/Removed ^a			
Model	Variables Entered	Variables Removed	Method
1	Exhaust Gas Temperature EGT, Angle Of Attack AOA, Speed Break, Roll, Heading, Latitude Acceleration, Total Air Temperature TAT, Airspeed ^b		Enter
a. Dependent Variable: N1			
b. All requested variables entered.			

Şekil 3.4. Bağımsız ve bağımlı değişken olarak kullanılan veriler

Model Summary ^b										
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	,976 ^a	,953	,953	5,5264	,953	3619,420	8	1426	,000	,170
a. Predictors: (Constant), Exhaust Gas Temperature EGT, Angle Of Attack AOA, Speed Break, Roll, Heading, Latitude Acceleration, Total Air Temperature TAT, Airspeed										
b. Dependent Variable: N1										

Şekil 3.5. N1 eğitim verileri için model özeti sonuçları

ANOVA ^a					
Model		Sum of Squares	df	Mean Square	Sig.
1	Regression	884342,157	8	110542,770	,000 ^b
	Residual	43552,282	1426	30,542	
	Total	927894,439	1434		
a. Dependent Variable: N1					
b. Predictors: (Constant), Exhaust Gas Temperature EGT, Angle Of Attack AOA, Speed Break, Roll, Heading, Latitude Acceleration, Total Air Temperature TAT, Airspeed					

Şekil 3.6. N1 eğitim verileri için ANOVA sonuçları

Coefficients ^a								
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-43,382	1,205		-35,987	,000		
	Airspeed	,058	,003	,181	16,655	,000	,278	3,603
	Angle Of Attack AOA	,379	,138	,027	2,742	,006	,338	2,958
	Roll	-,323	,037	-,052	-8,647	,000	,910	1,099
	Heading	,066	,003	,131	18,949	,000	,687	1,456
	Latitude Acceleration	-59,662	11,171	-,036	-5,341	,000	,742	1,347
	Speed Break	,179	,037	,034	4,861	,000	,691	1,447
	Total Air Temperature TAT	-,734	,014	-,509	-53,682	,000	,366	2,735
	Exhaust Gas Temperature EGT	,156	,001	,704	119,975	,000	,957	1,045
a. Dependent Variable: N1								

Şekil 3.7. N1 eğitim verileri için katsayılar sonucu

Exhaust Gas Temperature, Angle Of Attack, Speed Break, Roll, Heading, Latitude Acceleration, Total Air Temperature, Airspeed, değişkenleri kullanılarak bağımlı değişkenimiz olan N1 yorumlamak amacıyla çok değişkenli regresyon analizi yapılmıştır. Analiz sonucunda anlamlı bir regresyon modeli, $F(8,1426)=3619.42$, $p<.005$ değeri ve bağımlı değişkendeki varyansın %95'inin (Adjusted $R^2=.95$) bağımsız değişkenler tarafından açıklandığı bulunmuştur. Geriye kalan % 5'lik kısım ise başka değişkenlerce açıklanmaktadır. Buna göre bağımsız Airspeed değişkenimiz, $\beta=0.181$, $t(1426)=16.655$, Angle of Attach değişkenimiz, $\beta=0.027$, $t(1426)=2.742$, Roll değişkenimiz, $\beta=-0.052$, $t(1426)=-8.647$, Heading değişkenimiz, $\beta=0.131$, $t(1426)=18.949$, Latitude Acceleration değişkenimiz, $\beta=-0.036$, $t(1426)=-5.341$, Speed Break değişkenimiz, $\beta=0.034$, $t(1426)=4.861$, Total Air Temperature değişkenimiz, $\beta=-0.509$, $t(1426)=-53.682$, Exhaust Gas Temperature değişkenimiz, $\beta=0.704$, $t(1426)=119.975$ değerleri ve sig. anlamlılık değerine göre ($p<.005$) model için anlamlı değişkenlerdir.


N1 parametresi tahminine alakalı çoklu regresyon eşitliği bağıntısı aşağıda verilmiştir:

$$N1 = -43,382 + 0,058.Airspeed + 0,379.AOA - 0,323.Roll + 0,066.Heading - 59,662.Latitude\ acceleration + 0,179.Speed\ break - 0,734.TAT + 0,156. EGT \quad (4.1)$$

3.1.2. Yapay Sinir Ağları ile 11 Farklı Eğitim Algoritması Kullanarak Tahmin Edilmesi

İnsan beyninin çalışma prensibinden etkilenecek oluşturulmuş olan yapay sinir ağları (Artificial Neural Networks- ANN), birbiriyle paralel çalışmakta olan, birbirine bilgiyi ileten ve bilgi alan bir yapıdan meydana gelmektedir. Bir ağ şeklinde birbirine bağlanan yapay sinir ağı hücreleri problem çözmek amacıyla kullanılır.

Kurduğumuz ağ yapısında input verileri olarak, regresyon analizi sonucu elde ettiğimiz; Exhaust Gas Temperature, Angle Of Attack, Speed Break, Roll, Heading, Latitude Acceleration, Total Air Temperature Ve Airspeed verileri, output verisi olarak N1 verisi girilmiştir. Kurulan bu sinir ağı yapısında 11 farklı algoritmalar çalıştırılarak en iyi sonuç elde edilmeye çalışılmıştır. Verilerimiz %70'i eğitim verisi, %15'i test verisi ve geriye kalan %15'i de validation verisi olarak ayrılmıştır.




Şekil 3.8. N1 tahmini için geliştirilen YSA


Tahminin iyileştirilmesi için “Number of Hidden Neurons” değerleri ile tahmini iyileştirmek için 15 ile 20 arasında sayı değerleri verilmiştir.

3.1.2.1. Levenberg-Marquardt Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Kurulan YSA yapısını eğitmek için “trainlm” eğitim algoritması kullanılmıştır. En iyi tahmin işlemi gerçekleşen yapay sinir ağı yapısında gizli katmanda 15 nöron kullanıldığı gözlemlenmiştir. Bu YSA yapısı ile elde edilen sonuçlara ait grafikler Şekil 4.9, Şekil 3.10, Şekil 3.11 ve Şekil 3.12’de verilmiştir.




Şekil 3.9. “trainlm” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.10. “trainlm” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.11. “trainlm” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.12. “trainlm” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.2. BFGS Quasi-Newton Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Quasi-Newton Backpropagation eğitim algoritması ile kurulan YSA yapısında Farklı gizli nöron sayıları denenerek en iyi tahmin işlemi elde edilmeye çalışılmıştır. En yüksek doğruluk oranda tahmin işlemi gizli nöron sayısı 20 olan ağ yapısı ile elde edilmiştir. bu ağ yapısından elde edilen sonuçlar aşağıda Şekil 3.13, Şekil 3.14, Şekil 3.15 ve Şekil 3.16’da verilmiştir.




Şekil 3.13. “trainbfg” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.14. “trainbfg” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları



Şekil 3.15. “trainbfg” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.16. “trainbfg” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları


3.1.2.3. Bayesian-Regularization Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar

Bu ağı eğitmek için Matlab’de “trainbr” komutu ile ifade edilen Bayesian-Regularization Backpropagation eğitim algoritması kullanılmıştır. Kurulan ağ yapısı ile en yüksek doğrulukta tahmin işlemi yapmak için gizli katmandaki nöron sayıları değiştirilerek analizler yapılmış ve en iyi sonucu gizli katmanın 20 nöronundan oluştuğu ağ yapısının verdiği gözlemlenmiştir. Tüm ihtimaller denenmiş olsa da Validation R= sonucu trainbr eğitim algoritmasından alınamamıştır. Bu ağ yapısı ile elde edilen


sonuçlara ait grafikler aşağıda Şekil 3.17, Şekil 3.18, Şekil 3.19 ve Şekil 3.20’de gösterilmiştir.




Şekil 3.17. “trainbr” eğitim fonksiyonu ile oluşturulan ağı regresyon sonuçları



Şekil 3.18. “trainbr” eğitim fonksiyonu ile oluşturulan ağı eğitim sonuçları




Şekil 3.19. “trainbr” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.20. “trainbr” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.4. Conjugate Gradient with Beale-Powell Restarts Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Conjugate Gradient with Beale-Powell Restarts Backpropagation Eğitim Algoritması kullanılarak kurulan ağ yapısında gizli katmanda farklı nöron sayıları denenmiştir. En iyi tahmin sonucu 19 nöronlu gizli katman ile kurulan ağ yapısı ile elde edilmiştir. Elde edilen bu sonuçlar aşağıdaki verilen Şekil 3.21, Şekil 3.22, Şekil 3.23 ve Şekil 3.24’te verilmiştir.




Şekil 3.21. “traincgb” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.22. “traincgb” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.23. “traincgb” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.24. “traincgb” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.5. Conjugate Gradient Backpropagation with Fletcher-Reeves Updates Eğitim Algoritması ile Elde Edilen Sonuçlar


Kurulan YSA yapısını eğitmek için Conjugate Gradient Backpropagation with Fletcher-Reeves Updates eğitim algoritması kullanılmıştır. En iyi tahmin işlemi gerçekleşen yapay sinir ağı yapısında gizli katmanda 19 nöron kullanıldığı gözlemlenmiştir. Bu YSA yapısı ile elde edilen sonuçlara ait grafikler Şekil 3.25, Şekil 3.26, Şekil 3.27 ve Şekil 3.28’de verilmiştir.




Şekil 3.25. “traincgf” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.26. “traincgf” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.27. “traincgf” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.28. “traincgf” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.6. Conjugate Gradient Backpropagation with Polak-Ribiere Restart Eğitim Algoritması ile Elde Edilen Sonuçlar


Conjugate Gradient Backpropagation with Polak-Ribiere Restart eğitim algoritması ile kurulan YSA yapısında Farklı gizli nöron sayıları denenerek en iyi tahmin işlemi elde edilmeye çalışılmıştır. En yüksek doğruluk oranda tahmin işlemi gizli nöron sayısı 20 olan ağ yapısı ile elde edilmiştir. Bu ağ yapısından elde edilen sonuçlar aşağıda Şekil 3.29, Şekil 3.30, Şekil 3.31 ve Şekil 3.32’de verilmiştir.




Şekil 3.29. “traincgp” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.30. “traincgp” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.31. “traincgp” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.32. “traincgp” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.7. Gradient Descent with Adaptive Learning Rate Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Bu ağı eğitmek için Matlab’de “traingda” komutu ile ifade edilen Gradient Descent with Adaptive Learning Rate Backpropagation eğitim algoritması kullanılmıştır. Kurulan ağ yapısı ile en yüksek doğrulukta tahmin işlemi yapmak için gizli katmandaki nöron sayıları değiştirilerek analizler yapılmış ve en iyi sonucu gizli katmanın 19 nörondan oluştuğu ağ yapısının verdiği gözlemlenmiştir. Bu ağ yapısı ile elde edilen sonuçlara ait grafikler aşağıda Şekil 3.33, Şekil 3.34, Şekil 3.35 ve Şekil 3.36’da gösterilmiştir.




Şekil 3.33. “traingda” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.34. “traingda” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.35. “traingda” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.36. “traingda” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.8. Gradient Descent with Momentum&Adaptive LR Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Gradient Descent with Momentum&Adaptive LR Backpropagation eğitim algoritması ile kurulan YSA yapısında farklı gizli nöron sayıları denenerek en iyi tahmin işlemi elde edilmeye çalışılmıştır. En yüksek doğruluk oranda tahmin işlemi gizli nöron sayısı 20 olan ağ yapısı ile elde edilmiştir. Bu ağ yapısından elde edilen sonuçlar aşağıda Şekil 3.37, Şekil 3.38, Şekil 3.39 ve Şekil 3.40'ta verilmiştir.




Şekil 3.37. “traingdx” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.38. “traingdx” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.39. “traingdx” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.40. “traingdx” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.9. One-step Secant Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


One-step Secant Backpropagation eğitim algoritması ile kurulan YSA yapısında farklı gizli nöron sayıları denenerek gerçek değere en yakın tahmin işlemi elde edilmeye çalışılmıştır. En yüksek doğruluk oranda tahmin işlemi gizli nöron sayısı 19 olan ağ yapısı ile elde edilmiştir. Bu ağ yapısından elde edilen sonuçlar aşağıda Şekil 3.41, Şekil 3.42, Şekil 3.43 ve Şekil 3.44’te verilmiştir.




Şekil 3.41. “trainoss” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.42. “trainoss” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.43. “trainoss” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.44. “trainoss” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.10. Rpron Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Bu ağı eğitmek için Matlab’de “trainrp” komutu ile ifade edilen Rpron Backpropagation eğitim algoritması kullanılmıştır. Kurulan ağ yapısı ile en yüksek doğrulukta tahmin işlemi yapmak için gizli katmandaki nöron sayıları değiştirilerek analizler yapılmış ve en iyi sonucu gizli katmanın 20 nörondan oluştuğu ağ yapısının verdiği gözlemlenmiştir. Bu ağ yapısı ile elde edilen sonuçlara ait grafikler aşağıda Şekil 3.45, Şekil 3.46, Şekil 3.47 ve Şekil 3.48’de gösterilmiştir.




Şekil 3.45. “trainrp” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.46. “trainrp” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları




Şekil 3.47. “trainrp” eğitim fonksiyonu ile oluşturulan ağın test sonuçları




Şekil 3.48. “trainrp” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.1.2.11. Scaled Conjugate Gradient Backpropagation Eğitim Algoritması ile Elde Edilen Sonuçlar


Scaled Conjugate Gradient Backpropagation eğitim algoritması ile kurulan YSA yapısında farklı gizli nöron sayıları denenerek en iyi tahmin işlemi elde edilmeye çalışılmıştır. En yüksek doğruluk oranda tahmin işlemi gizli nöron sayısı 18 olan ağ yapısı ile elde edilmiştir. Bu ağ yapısından elde edilen sonuçlar aşağıda Şekil 3.49, Şekil 3.50, Şekil 3.51 ve Şekil 3.52’de verilmiştir.




Şekil 3.49. “trainscg” eğitim fonksiyonu ile oluşturulan ağın regresyon sonuçları



Şekil 3.50. “trainscg” eğitim fonksiyonu ile oluşturulan ağın eğitim sonuçları



Şekil 3.51. “trainscg” eğitim fonksiyonu ile oluşturulan ağın test sonuçları



Şekil 3.52. “trainscg” eğitim fonksiyonu ile oluşturulan ağın performans ve durum sonuçları

3.2. Sonuçlar ve Tartışma

Tahmin gücünü değerlendirmek için tahmin sonucu ile gerçek değer temel alındığı değerlendirme yöntemleri vardır. Bu yöntemlerde R^2 değeri, MAPE değeri, MSE değerine bakılır ve aldıkları değerlere göre değerlendirme yapılır. Korelasyon katsayısı iki veya daha fazla değişken arasındaki ilişkiyi açıklar. $-1 < R^2 < 1$ arasında değer alır. $R^2=1$, değerlerin birebir aynı olduğunu $R^2=-1$ ise tam tersi olduğunu gösterir. R^2 değeri 1'e ne kadar yakın olursa ağın performansı o kadar iyi olur. MAPE değeri regresyon ve zaman serisi modellerinde tahminlerin doğruluğu hakkında fikir vermek için kullanılır.

MAPE, ortalama mutlak hata yüzdesi olarak bilinir ve başlıca hata ölçme yöntemlerinden birisidir. Mümkün olduğunca sifıra yakın olması istenir. Lewis'e göre, MAPE değeri %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi", %20 ile %50 arasında olan modelleri "kabul edilebilir" ve %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır [49].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.2)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) * 100 \quad (3.3)$$

Geliştirilen 11 ağın sonuçlarının R^2 ve Test MSE değerine göre kıyaslandığında, tüm ağların N1 bağımsız verimizi yüksek doğrulukta tahmin ettiği görülmüştür. Elde edilen sonuçlar aşağıda Tablo 3.3.'te verilmiştir.

Tablo 3.3. 11 farklı eğitim algoritmasının MSE değerlerine göre karşılaştırılması

Eğitim algoritması	Eğitim R^2	Validasyon R^2	Test R^2	Eğitim MSE	Test MSE
trainlm	0.9928	0.9894	0.9850	56.744	59.073
trainbgf	0.9807	0.9752	0.9787	133.177	132.589
trainbr	0.9688	-	0.9714	44.970	45.441
traincgb	0.9632	0.9636	0.9707	177.369	184.204
traincgf	0.9764	0.9753	0.9855	145.342	148.217
traincgp	0.9765	0.9851	0.9724	146.802	146.252
traingda	0.9643	0.9557	0.9373	179.108	190.645
traingdx	0.9713	0.9698	0.9704	193.342	194.093
trainoss	0.9823	0.9755	0.9702	133.778	132.153
trainrp	0.9836	0.9842	0.9620	125.121	129.976
trainscg	0.9786	0.9692	0.9752	153.184	170.163

Tablo incelendiğinde tüm algoritmaların başarılı olarak N1 verisini tahmin ettiği ancak en yüksek doğrulukta elde edilen sonuç Levenberg-Marquardt backpropagation algoritması (trainlm) ile elde edildiği görülmüştür. Uçağın sensöründen elde edilen N1 değeri ile Levenberg-Marquardt backpropagation (trainlm) algoritmasının tahmin edilen

değerlerin Train, Test ve Validation aşamasındaki R^2 değeri ($R^2 > 0,98$) yüksektir. Levenberg-Marquardt backpropagation (trainlm) algoritması ile eğitilen ağın performansını değerlendirmek için Train, Test ve Validation aşamaları, tahmin edilen değerler ile ölçülen değerler arasındaki hata performans sonuçları aşağıdaki tabloda sunulmuştur.

Tablo 3.4. YSA performans değerleri (trainlm için)

YSA	R^2	MAPE	%MAPE	RMSE
Train	0,9928	0,0292	2,92	23.821
Test	0,9894	0,0314	3,14	24.305
Validation	0,9850	0,0126	1,26	24.617

Değerlendirdiğimiz sonuçlara göre korelasyon katsayısı anlamına gelen R^2 değerleri 0,985'in üzerindedir. Bu aralarında pozitif yönde yüksek ilişki olduğunu gösterir. Eğittiğimiz ağın Train, Test ve Validation MAPE değerleri %10'un altında kaldığı için "çok iyi" olduğunu yani yüksek doğrulukta tahminde bulunduğunu söyleyebiliriz. RMSE, ortalama hata kareleri toplamı kökü olarak bilinir. Ne kadar küçük olursa o kadar iyidir. N1 parametresinin tahmini için regresyon analizi yöntemi ile seçilen; Airspeed, Angle of Attack, Roll, Heading, Latitude Acceleration, Speed Break, Total Air Temperature, Exhaust Gas Temperature bağımsız değişkenleri ile başarılı bir şekilde tahmin edildiği açıktır. Bu sonuçlar bize yapılan hem regresyon analizi işleminin hem de kurulan yapay sinir ağ modelinin başarılı olduğunu göstermektedir.

KAYNAKLAR

1. Fornlöf, V., 2016. Improved Remaining Useful Life Estimations for On-Condition Parts in Aircraft Engines, University of Skövde, Sweden, Runit AB, Skövde, 978-91-981474-9-0.
2. Bilginer, S., 2020. Endüstri 4.0 ile Kestirimci Bakım. (Web page: <https://www.endustri40.com/endustri-4-0-ile-kestirimci-bakim/>) (Accessed: 20th December 2020)
3. Bouzidi, Z., Terrissa, L., Lahmadi, A., Zerhouni, N. Ve Ayad, S., 2017. The performance measure of a data driven prognostic system : Application to an Aircraft Engine. **IEEE International Conference on Prognostics and Health Management, PHM**, 978-1-5090-6465-6/17.
4. Uçak Bakım Onarımı. (Web page: <https://slonder.tripod.com/bakim.html>) (Accessed: 20th December 2020)
5. Deng, K., Zhang, X., Cheng, Y., Zheng, Z., Jiang, F., Liu, W. ve Peng, J., 2019. A Remaining Useful Life Prediction Method with Automatic Feature Extraction for Aircraft Engines. **IEEE**, 978-1-7281-2778-1.
6. Razavi, S. A., Najafabadi, A. ve Mahmoodian, A., 2018. Remaining Useful Life Estimation Using ANFIS Algorithm: A Data-Driven Approach for Prognostics. **IEEE**, 2166-5656/18.
7. Wang, C., Lu, N., Cheng, Y. ve Jiang, B., 2019. A Data-Driven Aero-Engine Degradation Prognostic Strategy. **IEEE Transactions on Cybernetics**, 1-11.
8. Tu, F., Ghostal, S., Luo, J., Biswas, G., Mahadevan, S., Jaw, L. ve Navarra, K., 2006. PHM Integration with Maintenance and Inventory Management Systems. **IEEE Aerospace Conference**, 1 1-4244-0525-4.
9. Dijital Teknikler ve Elektronik Alet Sistemleri. (Web page: chrome-extension://ohfgljdgelakfkefopgklcohadegdpjf/https://gavsispanel.gelisim.edu.tr/Document/nigul/20190617170931429_c1258b97-5ae4-4fbc-aaa7-ad43416d9920.pdf)(Accessed: 16th December 2020)

10. Horizontal situation indicator. Wikimedia. (Web page: https://en.wikipedia.org/wiki/Horizontal_situation_indicator) (Accessed: 20th December 2020)
11. Vitale, A., Corrado, F., Genito, N., Garbarino, L. ve Verde, L. 2019. Innovative Real Time Estimator for Redundancy of Angle of Attack Sensors in Commercial Aircraft. **IEEE Conference on Control and Fault-Tolerant Systems (SysTol)**, 978-1-7281-0380-8.
12. Global Positioning System (GPS) (Web page: [https://www.skybrary.aero/index.php/Global_Positioning_System_\(GPS\)](https://www.skybrary.aero/index.php/Global_Positioning_System_(GPS)))(Accessed: 27th December 2020)
13. Terrain awareness and warning system. Wikipedia. (Web page: https://en.wikipedia.org/wiki/Terrain_awareness_and_warning_system)(Accessed: 27th December 2020)
14. Tekin, M. ve Karakas, M. 2018. DME/DME Based Navigation for GNSS Interference Mitigation: Simulation, Algorithms. **IEEE Conference on Digital Avionics Systems (DASC)**, 978-1-5386-4113-2.
15. Mori, R. ve Fujita, M., 2020. Accurate Estimation of Ground Obstacle Collision Probability During ILS Approach. **IEEE Access**, 8, 66662 – 66671.
16. Wang, L., Li, M., Liu, L. ve Liu, L., 2018. Exhaust Gas Temperature Sensing Data Anomaly Detection for Aircraft Auxiliary Power Unit Condition Monitoring. **IEEE International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)**, 978-1-5386-6058-4.
17. Engine pressure ratio. Wikipedia. (Web page: https://en.wikipedia.org/wiki/Engine_pressure_ratio)(Accessed: 28th December 2020)
18. Wang, Y., Tang, B., Qin, Y. Huang, T., 2019. Rolling Bearing Fault Detection of Civil Aircraft Engine Based on Adaptive Estimation of Instantaneous Angular Speed. **IEEE Transactions on Industrial Informatics**, 16, 4938 – 4948.
19. Uçak durum göstergeleri. (Web page: <http://www.havaciyiz.com/-Kutuphane02-Durum.htm>)(Accessed: 29th December 2020)

20. Uçaklarda Yakıt Akış Gösterge Sistemi. (Web page: <https://www.technopat.net/sosyal/konu/ucaklarda-yakit-akis-goesterge-sistemi.677671/>)(Accessed: 25th 2020)
21. Kokpitteki Diğer Gösterge Ve Kumandalar. (Web page: <http://www.havaciyiz.com/Kutuphane02-Diger.htm>)(Accessed: 28th December 2020)
22. Mair, A. ve Thurner, T., 2010. Condition Monitoring for Reciprocating Aircraft Engines Using Fuzzy Logic. IEEE International Conference on Computational Intellegence for Measurement Systems and Applications, 978-1-4244-7230-7/10.
23. Lu, F., Huang, Y., Huang, J. ve Qiu, X., 2017. A Hybrid Kalman Filtering Approach Based on Federated Framework for Gas Turbine Engine Health Monitoring. **IEEE Access**, **6**, 9841-9853.
24. Skordilis, E. ve Moghaddass, R., 2020. A Double Hybrid State-Space Model for Real-Time Sensor-Driven Monitoring of Deteriorating Systems. **IEEE Transactionson Automation Science and Engineering**, **17**, 72-87.
25. Chen, S., H. ve Peng, C., C., 2019. A Model Following Based Real-Time Prediction and Monitoring of TFE-731 Turbofan Engine Compressors. **IEEE Access**, **7**, 159584 – 159598.
26. Saraswat, G., Singh, V., Verma, K. N., Salour, A. ve Liu, J., 2018. Prognosis of Diesel Engine (MBT) Using Feature Extraction Techniques: A Comparative Study. **IEEE International Conference on Prognostics and Health Management (ICPHM)**, 978-1-5386-1164-7/18.
27. Li, J., Li, X. ve He, D., 2019. A Directed Acyclic Graph Network Combined With CNN and LSTM for Remaining Useful Life Prediction. **IEEE Access**, **7**, 75464 – 75475.
28. Jaw, L., C., 1999. Neural Networks for Model-Based Prognostics. **IEEE Aerospace Conference**, 0-7803-5425-7.

29. Mushini, R. ve Simon, D., 2005. On Optimization of Sensor Selection For Aircraft Gas Turbine Engines. **IEEE International Conference on Systems Engineering**, 0-7695-2359-5.
30. Tumer, I. Y. ve Bajwa, A., 1999. A Survey of Aircraft Engine Health Monitoring Systems. In Proceedings 35th Joint Propulsion Conference, 20191-4344.
31. Viassolo, D. E., Adibhatla, S., Brunell, J. B., Down, J. H., Gibson, N. S., Kumar, A., Mathews, H. K. ve Holcomb, L. S., 2007. Advanced Estimation for Aircraft Engines. **IEEE American Control Conference**, 1-4244-0989-6.
32. Simon, B., 2008. Biogeography-Based Optimization. **IEEE Transactions on Evolutionary Computation**, 12, 702-713.
33. Zhang, P. ve Huang, J., 2008. Aeroengine Performance Monitoring and Fault Diagnosis Based on Transient Measurements. **IEEE International Symposium on Systems and Control in Aerospace and Astronautics**, 1-4244-2386-6.
34. Zhang, P. ve Huang, J., 2008. Aeroengine Performance Monitoring and Fault Diagnosis Based on Transient Measurements. **IEEE International Symposium on Systems and Control in Aerospace and Astronautics**, 1-4244-2386-6.
35. Sarkar, S., Rao, C. Ve Ray, A., 2009. Estimation of Multiple Faults in Aircraft Gas-turbine Engines. **IEEE American Control Conference**, 978-1-4244-4524-0.
36. Zhang, X., Tang, L. ve Decastro, J., 2013. Robust Fault Diagnosis of Aircraft Engines: A Nonlinear Adaptive Estimation-Based Approach. **IEEE Transactions on Control Systems Technology**, 1063-6536.
37. Zaidan, M. A., Mills, A. R. ve Harrison, R. F., 2013. Bayesian Framework for Aerospace Gas Turbine Engine Prognostics. **IEEE Aerospace Conference**, 978-1-4673-1813-6.
38. Alam, M. M., Bodruzzaman, M. ve Zein-Sabotto, M. S., 2014. Online Prognostics of Aircraft Turbine Engine Component's Remaining Useful Life (RUL). **IEEE Southeastcon**, 978-1-4799-6585-4.

39. Bluvband, Z. ve Porotsky, S., 2016. Prognostic and Health Management for Suspended Time-Series. IEEE Second International Symposium on Stochastic Models in Reliability Engineering, Life Science and Operations Management (SMRLO), 978-1-4673-9941-8.
40. Bluvband, Z. ve Porotsky, S., 2016. Prognostic and Health Management for Suspended Time-Series. IEEE Second International Symposium on Stochastic Models in Reliability Engineering, Life Science and Operations Management (SMRLO), 978-1-4673-9941-8.
41. Lan, G., Li, Q. ve Cheng, N., 2018. Remaining Useful Life Estimation of Turbofan Engine Using LSTM Neural Networks. IEEE CSAA Guidance, Navigation and Control Conference (CGNCC), 978-1-5386-1171-5.
42. Sağiroğlu, Ş., Beşdok, E. ve Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları. Erciyes Üniversitesi, Kayseri, 426 s.
43. Aydoğan, İ. ve Zırhlıoğlu, G., 2018. Öğrenci Başarılarının Yapay Sinir Ağları ile Kestirilmesi. **YYÜ Eğitim Fakültesi Dergisi**, **15**, 577-610.
44. Aşkın, D., İskender, İ. ve Mamızadeh, A., 2011. Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi. **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, **26**, 905-913.
45. Gültekin, F., Regresyon Analizi. (Web Page: **chrome-extension://ohfgljdgelakfkefopgkcohadegdpjf/http://w3.balikesir.edu.tr/~bsentuna/wp-content/uploads/2013/03/Regresyon-Analizi.pdf**) (Accessed: 20th December 2020)
46. Chatterjee, S. ve Hadi, A. S., 2012. Regression Analysis by Example. New York University, Amerika, 402s.
47. Ataseven, B., 2013. Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*, 101-115
48. Kahraman E., 2012. Konsolidasyon Özelliklerinin Arttırılmış Veri Seti İle İstatistiksel Analizi. İstanbul Teknik Üniversitesi, Yüksek Lisans Tezi.

49. Özocak, A., Yurtcu, Ş., 2016. İnce daneli zeminlerde sıkışma indisi'nin istatistiksel ve yapay zeka yöntemleri ile tahmin edilmesi. **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 31(3): 597-608.
50. Çalışkan, F., Yüksel, H. ve Dayık, M., 2016. Genetik Algoritmaların Tasarım Sürecinde Kullanılması. **Süleyman Demirel Üniversitesi Teknik Bilimler Dergisi**, 6, 21-27.
51. Öztürk E. E., 2020. Korelasyon Analizi (r) Nedir? (Web page: <https://www.veribilimiokulu.com/blog/korelasyon-analizir-nedir/>) (Accessed: 20th December 2020)
52. Saigal, S. ve Mehrotra, D., 2012. Performance Comparison Of The Time Series Data Using Predictive Data Mining Techniques. *Advances in Information Mining*, 4. 57-66.
53. Kamble, V. B. ve Deshmukh, S. N., 2017. Comparision between Accuracy and MSE, RMSE by using Proposed Method with Imputation Technique. **Oriental Journal of Computer Science and Technology**, 10, 773-779.
54. Chai, T. ve Draxler, R. R., 2014. Root mean square error (RMSE) or mean absolute error (MAE)? –Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7, 1247-1250.
55. Beldjazia, A., Alatou, D., 2016. Precipitation variability on the massif Forest of Mahouna (North Eastern-Algeria) from 1986 to 2010. **Int. J. Manag. Sci. Bus. Res.**, 5(3): 2226–8235.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Alperen Mehmet Sevinç

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 25 Eylül 1996, Aksaray

Medeni Durumu: Bekâr

Tel: +90 543 974 73 49

e-mail: alperenmehmetsevinc@gmail.com

Yazışma Adresi: Türk Hava Yolları Atatürk Havalimanı Aviyonik Modifikasyon Birimi
Bakırköy/İSTANBUL

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi	-
Lisans	Erciyes Üniversitesi	2019
Lise	Açık Öğretim Lisesi	2014

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2019- Halen	Türk Hava Yolları Teknik Aş.	Uçak Teknisyeni

YABANCI DİL

İngilizce