



**T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**UÇAK BAKIM PERİYOTLARI VE ARIZA SAYILARININ YAPAY
ZEKA TEKNİKLERİ KULLANILARAK TAHMİNİ**

Kadir ÇELİKMIH

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Ağustos-2020

KONYA

Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Kadir ÇELİKMIH tarafından hazırlanan “Uçak Bakım Periyotları ve Arıza Sayılarının Yapay Zeka Teknikleri Kullanılarak Tahmini” adlı tez çalışması 28/08/2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Erdiç KOÇER

Danışman

Prof. Dr. Harun UĞUZ

Üye

Doç. Dr. Halife KODAZ

Üye

Dr. Öğr. Üyesi Onur İNAN

Üye

Dr. Öğr. Üyesi Sait Ali UYMAZ

İmza

.....

.....

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması bilimsel araştırma projesi olarak Havelsan ve Kategori-C seviyesinde Savunma Sanayi Başkanlığı -SSB tarafından HVL-SÖZ-18/033 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this seminar document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Kadir ÇELİKMIH

Date: 28/08/2020

ÖZET

DOKTORA TEZİ

UÇAK BAKIM PERİYOTLARI VE ARIZA SAYILARININ YAPAY ZEKA TEKNİKLERİ KULLANILARAK TAHMİNİ

Kadir ÇELİKMIH

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Harun UĞUZ

2020, 81 Sayfa

Jüri

Prof. Dr. Harun UĞUZ

Doç. Dr. Halife KODAZ

Doç. Dr. Erdinç KOÇER

Dr. Öğr. Üyesi Onur İNAN

Dr. Öğr. Üyesi Sait Ali UYMAZ

Havacılık endüstrisi çok fazla verinin ve bilginin biriktiği bir alandır. Bu alanda bakım planları, arıza bildirimleri, tamir siparişleri, ekipman sökme/takma kayıtları, uçuş saatleri, sorti sayısı, faal/gayri faal durumları gibi bir çok veri saklanmaktadır. Bu verilerin analiz edilmesi, yanlış arıza sinyali ve yanlış bildirim ile gelen durumların ayırt edilmesi ve gerçek arızaların tespit edilmesi gerekmektedir. Ayrıca anlamlı verilerin çıkarılmasına, gereksiz verilerin ve özelliklerin de elenmesine ihtiyaç vardır. Kaynak yönetim sisteminde bu amaç için programlar yazarak, öncelikle seçilen uçak sistemine ait ekipmanların MTBF ve NFF değerleri hesaplanmış, malzemelerin üretici kataloğunda yazan bakım periyotları, hesaplanan MTBF değerleri ile karşılaştırılarak analiz edilmiştir. Ayrıca uçağın genel bakım periyotlarının ayarlanmasına yardımcı olmak amacıyla iki yıllık döneme ait elde edilen uçak faaliyet raporları üzerinden uçağın bir sonraki arızalanma günü yapay zekâ ve makine öğrenmesi metodlarıyla tahmin edilerek modelin başarısı ortaya konmuştur.

Tez kapsamında uçak ekipmanlarının arıza sayısının tahminine yönelik olarak yapay zeka/makine öğrenmesi ve optimizasyon algoritmaları ile çalışmalar yürütülmüştür. Bu amaçla arıza sayısı tahmininin başarısını artırmak için iki aşamalı hibrit veri hazırlama modeli önerilmiştir. İlk aşamada, nitelik değerlendirerek en etkili ve en etkisiz parametreleri bulmak için bir özellik seçme yöntemi olan ReliefF kullanılmıştır. İkinci aşamada gürültülü veya tutarsız verileri elemek için geliştirilmiş K-ortalama algoritmaları kullanılmıştır. Hibrit veri hazırlama modelinin ekipmanın bakım veri kümesindeki performansı, makine öğrenimi algoritmalarından; Yapay Sinir ağı (YSA) olarak Çok Katmanlı Algılayıcı (MLP), Destek Vektör Regresyonu (DVR) ve Doğrusal Regresyon (DR) ve optimizasyon algoritmalarından Genetik Algoritma (GA), Diferansiyel Evrim Algoritması (DE) ve Dağıtık Algoritma (DA) kullanılarak değerlendirilmiştir. Elde edilen sonuçlar ile hibrit veri hazırlama modelinin ekipmanın arıza sayısını tahmin etmede başarıyı artırdığı gösterilmiştir.

Anahtar Kelime: MTBF, NFF, Özellik Seçimi, Arıza Tahmini, Yapay Zekâ / Makine Öğrenmesi, Optimizasyon

ABSTRACT

PREDICTING AIRCRAFT MAINTENANCE PERIODS AND FAILURE COUNTS THROUGH ARTIFICIAL INTELLIGENCE TECHNIQUES

Kadir ÇELİKMIH
Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering

Advisor: Prof. Dr. Harun UĞUZ
2020, 81 Pages

Jury
Prof. Dr. Harun UĞUZ
Doç. Dr. Halife KODAZ
Doç. Dr. Erdiñ KOÇER
Dr. Öğr. Üyesi Onur İNAN
Dr. Öğr. Üyesi Sait Ali UYMAZ

Aviation industry is an area where a lot of knowledge and data are collected. In this area, it is typical to store a huge quantity of data, such as maintenance plans, failure notifications, repair orders, records of equipment's removal/installation, flight hours, number of sorties and active/inactive statuses. It is necessary to analyse these data to distinguish between the cases that come with false fault signals or false notifications and real faults. In addition, we need to extract meaningful data and eliminate unnecessary data and features. By writing programs for this purpose in the resource management system, firstly the MTBF and NFF values of the equipment that belong to the selected aircraft system were calculated, the maintenance periods specified in the manufacturer's catalogue of the materials were analysed in comparison with the calculated MTBF values. In addition, the success of the model was demonstrated by predicting the next failure day of the aircraft through the use of artificial intelligence/machine learning methods based on the aircraft activity reports obtained for a two-year period to help adjust the general maintenance periods.

Within the scope of this dissertation, studies were carried out using artificial intelligence/machine learning and optimization algorithms to estimate the number of failures of aircraft equipment. For this purpose, a two-stage hybrid data preparation model was proposed to increase the success of the failure estimation. In the first stage, ReliefF, a feature selection method, was used to find the most effective and ineffective parameters through quality evaluation. In the second, a modified K-means algorithm was used to eliminate noisy or inconsistent data. The performance of the hybrid data preparation model in the maintenance dataset of the equipment was evaluated, using machine learning algorithms, including Artificial Neural Network (ANN), Multilayer Perceptron (MLP), Support Vector Regression (DVR) and Linear Regression (DR) and optimization algorithms, including Genetic Algorithm (GA), Differential Evolution Algorithm (DE) and Scatter Search (SS). The results indicated that the hybrid data preparation model increases the success in estimating the number of failures of the equipment.

Keywords: MTBF, NFF, Feature Selection, Failure Prediction, Artificial Intelligence / Machine Learning, Optimization

ÖNSÖZ

Bu tez çalışmam da yol gösteren, destek ve yardımcı olan danışman hocam Prof. Dr. Harun UĞUZ' a, gerektiğinde yardımlarını esirgemeyen Dr. Öğr. Üyesi Onur İNAN'a ve İngilizce konusunda destek olan Doç. Dr. Arif BAKLA'ya,

Çalışmalarında verdiği destek nedeniyle HAVELSAN'a, proje desteği nedeniyle Savunma Sanayi Başkanlığı'na;

Eğitim ve öğrenim hayatım boyunca maddi, manevi desteklerini esirgemeyen anneme ve babama; çalışmalarım sırasında bana destek olan eşime ve çocuklarıma teşekkür ederim.

Kadir ÇELİKMİH

KONYA – 2020

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT.....	v
KISALTMALAR	xi
1. GİRİŞ	1
1.1. Bakım ve Güvenilirlik	2
1.2. Uçak Bakımı.....	5
1.1.1. Ekipman arızaları ve MTBF.....	6
1.1.2. NFF durumu	10
1.3. Tezin Amacı.....	11
1.4. Literatüre Katkısı.....	13
1.5. Tezin Organizasyonu	14
2. KAYNAK ARAŞTIRMASI.....	15
2.1. Bakım Süreçlerinde Kaynak Araştırması	15
2.2. Arıza Tahmini Alanında Kaynak Araştırması.....	19
3. MATERYAL VE METOTLAR.....	23
3.1. Materyal.....	23
3.1.1. Ekipman MTBF hesabı veri kümeleri.....	24
3.1.2. Uçak arızası gün tahmin verileri	25
3.1.3. Arıza sayısı tahmin verileri	25
3.2. Metotlar	27
3.2.1. Genetik algoritmalar.....	27
3.2.2. ReliefF özellik seçimi algoritması	31
3.2.3. K-Ortalamalar kümeleme yöntemi.....	32
3.2.4. Yapay sinir ağları	33
3.2.5. Destek vektör makinesi ve destek vektör regresyon	37
3.2.6. Doğrusal regresyon	39

3.2.7.	Dağıtık arama algoritması	40
3.2.8.	Diferansiyel evrim algoritması.....	43
3.2.9.	Performans değerlendirme kriterleri	45
3.2.10.	Optimizasyon algoritmaları ile tahmin modelleri.....	46
3.2.11.	Optimizasyon algoritmaları ile kullanılan amaç fonksiyonu	47
4.	UÇAK BAKIM PERİYODU TAHMİNİ	48
4.1.	Uçak Bakımı MTBF ve NFF Sonuçları	48
4.2.	Uçak Bakım Periyodu Tahmin Sonuçları	52
5.	EKİPMAN ARIZA SAYISININ TAHMİNİ	57
5.1.	Yapay Zekâ Yöntemleri ile Arıza Tahmini Sonuçları.....	59
5.2.	Optimizasyon Yöntemleri ile Arıza Tahmini Sonuçları	64
5.3.	Arıza Tahmini Genel Sonuçları	70
6.	SONUÇLAR	73
	KAYNAKÇA	76

ŞEKİLLER VE ÇİZELGELER

Şekiller	Sayfa
Şekil 1.1 Bakım Türleri.....	3
Şekil 1.2 Üç arıza dönemi dağılımına ait kuvvet eğrisi	10
Şekil 3.1 Yazılan programın akış diyagramı	26
Şekil 3.2 Genetik Algoritma akış diyagramı	30
Şekil 3.3 Yapay sinir hücresi	35
Şekil 3.4 Aktivasyon Fonksiyonları	36
Şekil 3.5 İleri Beslemeli Yapay Sinir Ağı	37
Şekil 3.6 İki sınıflı veriyi ayıran alt düzlem ve sınırları	38
Şekil 3.7 Dağıtık arama algoritması akış diyagramı	41
Şekil 3.8 Diferansiyel evrim algoritması akış diyagramı.....	44
Şekil 4.1 Ekipman tamir süreci akış diyagramı	50
Şekil 4.2 DR Algoritması için tahmin ve hedef verilerin korelasyon grafiği.....	54
Şekil 4.3 DVR Algoritması için tahmin ve hedef verilerin korelasyon grafiği.....	54
Şekil 4.4 MLP Algoritması için tahmin ve hedef verilerin korelasyon grafiği	55
Şekil 4.5 DR algoritması 1 kat cd tahmin ve hedef test verileri grafiği.....	55
Şekil 4.6 DVR algoritması 1 kat cd tahmin ve hedef test verileri grafiği.....	56
Şekil 4.7 MLP algoritması 1 kat cd tahmin ve hedef test verileri grafiği	56
Şekil 5.1 Hibrit veri hazırlama modelinin blok şeması.....	58
Şekil 5.2 Geliştirilmiş K-ortalamalar algoritması ile veri hazırlama modeli	58
Şekil 5.3 DR Algoritması için tahmin ve hedef verilerin korelasyon grafiği.....	62
Şekil 5.4 DVR Algoritması için tahmin ve hedef verilerin korelasyon grafiği.....	62
Şekil 5.5 MLP Algoritması için tahmin ve hedef verilerin korelasyon grafiği.....	62
Şekil 5.6 DR algoritması 1 kat cd tahmin ve hedef test verileri grafiği.....	63
Şekil 5.7 DVR algoritması 1 kat cd tahmin ve hedef test verileri grafiği.....	63
Şekil 5.8 MLP algoritması 1 kat cd tahmin ve hedef test verileri grafiği	64
Şekil 5.9 GA ile Doğrusal Kuadratik, Üstel ve Hibrit model grafiği.....	66
Şekil 5.10 GA algoritması için arıza sayısı tahmin ve hedef test verileri	66
Şekil 5.11 DA ile Doğrusal, Kuadratik, Üstel ve Hibrit Model Sonuçları.....	68
Şekil 5.12 DA algoritması için arıza sayısı tahmin ve hedef test verileri	68
Şekil 5.13 DE ile Doğrusal, Kuadratik, Üstel ve Hibrit model grafiği	70
Şekil 5.14 DE algoritması için arıza sayısı tahmin ve hedef test verileri	70

Çizelgeler	Sayfa
Çizelge 3.1 Ekipman Arıza Kayıtları	24
Çizelge 3.2 Uçak Arıza Günleri Verileri	25
Çizelge 3.3 Bakım verisinden elde edilen dokuz giriş ve bir çıkış verisi	26
Çizelge 3.4 Örnek bakım verileri	27
Çizelge 4.1 E1 Ekipmanının MTBF değerleri	51
Çizelge 4.2 E2 Ekipmanının MTBF değerleri	51
Çizelge 4.3 Tüm ekipmanların hesaplanan verileri.....	51
Çizelge 4.4 En az 50 uçuş saati olan ekipmanların hesaplanan verileri.....	51
Çizelge 4.5 En az 100 uçuş saati olan ekipmanların hesaplanan verileri.....	51
Çizelge 4.6 Ayarlanmış DVR parametreleri.....	52
Çizelge 4.7 Ayarlanmış MLP parametreleri	53
Çizelge 4.8 Ayarlanmış DR verileri	53
Çizelge 4.9 (522 x 6) veri kümesi (5giriş 1 çıkış) için performans değerleri	53
Çizelge 5.1 ReliefF algoritması ile seçilen en etkili dört özellik	58
Çizelge 5.2 Ayarlanmış DVR parametreleri.....	59
Çizelge 5.3 Ayarlanmış MLP parametreleri	59
Çizelge 5.4 Ayarlanmış DR verileri	60
Çizelge 5.5 (585 x 10) veri kümesi (9 giriş 1 çıkış) için performans değerleri	60
Çizelge 5.6 (585 x 5) veri kümesi (4 giriş 1 çıkış) için performans değerleri	60
Çizelge 5.7 (510 x 5) veri kümesi (4 giriş 1 çıkış) için performans değerleri	61
Çizelge 5.8 Genetik algoritma parametreleri	65
Çizelge 5.9 DA Algoritması parametreleri.....	67
Çizelge 5.10 DE Algoritması parametreleri	69
Çizelge 5.11 GA, DA, DE ve önceki çalışma sonuçlarının karşılaştırılması.....	71

KISALTMALAR

ARIMA	: Otomatik Regresif Entegre Hareketli Ortalama (Auto-Regressive Integrated Moving-Average)
CC	: Korelasyon Katsayısı (Correlation Coefficient)
DA	: Dağınık Arama (Scatter Search)
DE	: Diferansiyel Evrim
DVM	: Destek Vektör Makineleri
DVR	: Destek Vektör Regresyon
ERP	: Kurumsal Kaynak Planlama (Enterprise Recourse Planning)
FMEA	: Arıza Modu ve Etki Analizi
FMECA	: Arıza Modu Etkileri ve Kritiklik Analizi
GA	: Genetik Algoritma
LRU	: Line Replaceable Unit (Hat Seviyesi Değiştirilebilir Ünite)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MLP	: Çok Katmanlı Algılayıcı Ağları (MultiLayer Perceptron Neural Network)
MRO	: Bakım Onarım ve Revizyon (Maintenance, Repair and Overhaul)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
MTBF	: Arızalar Arası Ortalama Süre (Mean Time Between Failure)
MTBUR	: Plansız Değiştirme Arasında Geçen Ortalama Süre
MTTF	: Arızaya Kadar Geçen Süre
MTTR	: Tamire Kadar Geçen Süre
NFF	: Arıza Bulunamadı (No Fault Found)
PM	: Bakım Modülü (Plant Maintenance)
RCM	: Güvenilirlik Merkezli Bakım (Reliability Centered Maintenance)
RMSE	: Kök Ortalama Karesel Hata (Root Mean Squared Error)
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Uçak bileşenlerinin güvenilirliği ve kullanılabilirliği havacılık endüstrisinde her zaman önemli bir konu olmuştur. Olası arızaların doğru tahmini, uçak bileşenlerinin ve sistemlerinin güvenilirliğini artıracaktır. Bakım operasyonlarının planlanması ve programlanması, uçak bileşenlerinin genel bakım ve yenilenme maliyetlerinin belirlenmesine yardımcı olur. Bakım maliyetleri, uçak sistemlerinin toplam işletme giderlerinin önemli bir bölümünü oluşturmaktadır.

Bakım faaliyetleri günümüzde işletmenin gelir ve giderini etkileyen önemli bir işletme fonksiyonu olarak değerlendirilmektedir. İşletmeler kendi bakım sistemlerini tanımlarken ihtiyaç ve kaynaklarını göz önünde bulundurmalıdır. Beklenmeyen ekipman arızaları işletmeler için pahalı bir tecrübe olmakta ve büyük zararlara yol açabilmektedir. Bu nedenle sistemlerde güvenilirlik (reliability), bakım yapılabilirlik (maintainability) ve hazır bulunabilirlik (availability) gibi konular çok önemli hale gelmektedir. Günümüz teknolojisi, sürekli olarak artan sistem karmaşıklığı, sistem ve sistemi oluşturan bileşenlerin güvenilirliğini kritik bir konu haline getirmiştir (Gürbüz ve Cömert, 2012). Bakım faaliyetlerinin en iyi şekilde yürütülmesi için bakım birimlerinin organizasyonu, aralarındaki bilgi alışverişi çok önemlidir. Bakım faaliyetleri ile hazır bulunabilirliğinin sağlanması, iyileştirilmesi, geliştirilmesi, ürünlerin kaliteli, zamanında verimli ve etkin kullanılabilmesi sağlanmaktadır Bu nedenle bakımın stratejik önemi artmıştır. Bakımın amacı işletmede bulunan her türlü bakımı yapılan tesis ve ekipmanların çalışma şartları içerisinde arıza yapmadan çalışmasını sağlamaktır. Nihai hedef artan bakım karmaşıklığının artan maliyetleri ile birlikte, artan yüksek arıza oranları sonucunda oluşan maliyetleri de göz önüne alarak uygun, optimum bir plan gerçekleştirmektir (Uzun ve Özdoğan, 2011).

Makine öğrenmesi hızla gelişen ve gelecekte daha da gelişmesi beklenen yükselen teknolojilerdendir. Makine öğrenmesi yöntemleri kestirimci/önleyici sistemler, iletişim, güvenlik, enerji yönetimi ve benzeri alanlarda sıklıkla uygulanmaktadır (Din ve ark., 2019). Veri hazırlama seviyesi, makine öğrenmesinin ve karar alma sisteminin temel bir parçasıdır. Verileri kullanışlı hale getirmek ve karar alma için yönetir. Karar verme, gelecekteki öngörüye, arıza olayına ve ekipmanın kullanılabilirliğine bağlıdır (Jan ve ark., 2019). Veri madenciliği, verileri anlaşılabilir bilgilere sınıflandırmanın ve ayrıştırmanın bir yoludur. Uygulanabilir modelleri bir yığın bilgidan kavrar ve gizli


verileri ortaya çıkarmak için farklı yaklaşımlar benimser. Veri madenciliği, ham verilerden anlaşılabilir bilgi türetme olarak tanımlanabilir (Din ve ark., 2018).

Havacılık endüstrisi çok fazla verinin ve bilginin biriktiği bir alandır. Bu alanda bakım planları, arıza bildirimleri, tamir siparişleri, ekipman sökme/takma kayıtları, uçuş saatleri, sorti sayısı, faal/gayrı faal durumları gibi bir çok veri saklanmaktadır. Bu verilerin analiz edilmesine anlamlı verilerin çıkarılmasına ve gereksiz verilerin, özelliklerinde elenmesine ihtiyaç vardır. Özellik seçimi, veri tahmini ve makine öğrenmesi algoritmalarında, öngörülen tahminle en ilgili özelliklere odaklanan temel bir alandır (Durgabai ve Bhushan, 2014). Bir durumun gözlemlenmesi sonucu toplanan verilerin, özelliklerin hepsi aynı derecede önemli değildir. Normalde operasyonel veriler eksik, yetersiz, kısmen anlamlı olabilir veya hiç anlamlı olmayabilir. Bazıları gürültülü, gereksiz veya alakasız olabilir. Özellik seçimi, belirli bir görevle ilgili bir özellik kümesi seçmeyi amaçlamaktadır. Bu sorun karmaşık ve çok boyutlu bir konudur (Rosario ve Thangadurai, 2015). Gürültülü, tekrarlanan veya gereksiz özellikleri azaltmaya odaklanmıştır. Hesaplama hızındaki performans ve sınıflandırma doğruluğu, ilgisiz özelliklerin çıkarılmasıyla geliştirilebilir. Veri işleme yöntemleri, verilerin kalitesini artırmaya ve veri madenciliğinin doğruluğunu artırmaya yardımcı olur, böylece veriyi daha verimli hale getirir (Hsu ve Hsieh, 2010). Veri kalitesinin iyi olması, bilgi keşfi, veri anormalliklerini kontrol etme, karar verme, tahmin ve analiz süreçleri için önemlidir (Grbz, 2011). Buna bağlı olarak ekipman arızalarını tahmin etmek, onarım ve ekipman maliyetlerini azaltmak ve ekipman kullanılabilirliğini artırmak için gereklidir (Fan ve Fan, 2015).

1.1. Bakım ve Güvenilirlik

Bakım bir sistemin kullanım ömrü boyunca bozulabilecek karakteristiklerini daha önceden belirlenmiş nitelik veya nicelik seviyelerinde tutmak veya bu seviyeye getirmek için yapılan işlerin tümü olarak tanımlanabilir. Bakım fonksiyonel bir birimin bileşenin önceden belirlenmiş şartlarda beklenen fonksiyonlarını yerine getirmek üzere test etme, ekipman sökme/takma, ayarlama, tamir etme gibi faaliyetlerle düzeltilmesi ve sürekliliğinin sağlanmasıdır (Uzun ve Özdoğan, 2011). Bakımın karakteristikleri emniyet, güvenilirlik, uçuşa hazır durumda bulunma şeklinde sıralanabilir. Bakım bir ekipmanı çalışır durumda tutabilmek amacıyla servis, tadilat, yenilenme, kontrol ve durum tespiti yapmak gibi işlerden oluşan faaliyetlerdir. Bakım bir parçanın istenilen ömür çevrimi içerisinde gerekli fonksiyonlarını yerine getirebilecek şekilde korunması için teknik eylemlerin bir bütünü olarak tanımlanabilir.

MTBF (Mean Time Between Failure); sistemlerin, ekipmanların güvenilirliğini ifade etmede, yaşam döngüsü tahmininde ve arıza oranı hesabında kullanılan bir terimdir. İki arıza arasında geçen süreyi ifade eder. Uçuş faaliyetlerinde emniyetin sağlanması, uçağın uçuşa hazır durumda bulunmasının sağlanması ve emniyet faktöründen ödün vermeden maliyetlerin azaltılması amacıyla yapılan işlere de bakım denir. Bakım yapılırken bakım planlarına, bakım el kitaplarına, üretici ve havacılık otoritesinin talimatlarına göre gerekli işlemler yapılır. Tüm bu talimatlar uçuş güvenliğini arttırmak ve emniyeti sağlamak amacıyla zamanla ortaya çıkmış talimatlardır. Bakım bir parçanın istenilen ömür çevrimi içerisinde parçanın gerekli fonksiyonlarını yerine getirebilecek şekilde korunması için bütün teknik eylemlerin bir bütünü olarak tanımlanabilir. Bakım maliyetleri, üretim tesislerinin toplam işletme maliyetleri içinde önemli bir yer tutmaktadır. Bakım etkinliği ile ilgili yapılan çalışmalarda bakım maliyetlerinin üçte biri için harcanan paranın gereksiz veya düzgün olarak gerçekleştirilmeyen bakım faaliyetleri olarak boşa yapılan harcamalar olduğu görülmüştür. Günümüzde bakım, düzenli servis, periyodik inceleme ve takip etme, önleyici değiştirme ve durum tabanlı bakım inceleme gibi kendini geliştiren yaklaşımları içermektedir. Bakım çeşitleri bakım süreçlerinin gelişimine paralel olarak ortaya çıkmıştır. İşletmelerde gerçekleştirilen bakım faaliyetleri Şekil 1.1'deki gibi sınıflandırılmıştır (Garmabaki, 2016).



Şekil 1.1 Bakım Türleri

Bakımlar yapılış amacına göre ikiye ayrılır: Önleyici Bakım ve Düzeltici Bakım.

Düzeltilici Bakım: Bu bakım ile oluşan arızalar giderilir. Arıza yapma olasılığı zamana bağlı olmayan bileşenleri içerir. Plansız yapılan bakımlar düzeltici bakım kapsamında yer alır. Bir bileşenin bilinen veya ortaya çıkan arızasının düzeltilerek normal duruma geri getirmek için yapılan bakım faaliyetleri olan plansız bakımlar, meydana

gelen arızaların veya hasarların giderilmesi için uygulanırlar. Uçuş sırasında veya kontroller esnasında ortaya çıkan herhangi bir arızanın, plansız bakım ve tamir işlemlerinin hemen uygulanması gerekmekte ve düzeltici işlem yapılmadan uçağın faal duruma geçmesi mümkün olmamaktadır. Bu durumda acil bir şekilde düzeltici bakım yapılır. Arızanın önemine göre erteleme mümkün ise düzeltici bakım ertelenir.

Önleyici Bakım: Sistemlere gerekli bakımlar arıza ortaya çıkmasını beklemeden önceden yapılır. Böylece arızalar önlenmiş olur. Önceden programlı bu bakımlar yapımçı firma tarafından bakım el kitaplarında belirlenen aralıklarla uygulanan uçak yapısındaki sistemler, yapımçı firma tarafından belirlenen sınırlayıcı koşullara uygunluğunun belirlendiği, uymuyorsa değiştirildiği günlük, aylık veya yıllık olarak programlanabilen bakımlardır. Faaliyetlerin zaman aralıkları, toplam süreleri, insan gücü, yedek parça ve diğer kaynak ihtiyaçları, malzemenin ve ekipmanın özelliklerine ve geçmiş tecrübelere dayanılarak ve önceden belirlenerek yapılan bakımdır. Planlı bakım ve kestirimci bakım işlemlerini faaliyetlerini içerir.

Planlı bakım faaliyeti olan Önleyici Bakım, fonksiyonel bir birimin gelecek bir dönemde arızalanıp arızalanmayacağını değerlendirmek ve bu arızanın engellenmesi için gerekli önlemlerin alınması esasına dayanan bakım politikasıdır. Önleyici Bakım, Önceden Belirli Bakım ve Durum Tabanlı Bakım olmak üzere ikiye ayrılır. Önceden Belirli Bakım makine veya ekipmanın arızalanma ihtimalini düşürmeyi hedefler, zamana bağlıdır. Hedef sistemin performansını normal seviyede tutmaktır. Durum tabanlı bakımda yapılan analiz çalışması sonrasında ekipmanın durumu incelenerek değiştirilip değiştirilmeyeceğine karar verilir. Bir ekipmanı değiştirmek için uçağı gayrı faal yapıp durdurmak hem zaman kaybı, hem de faaliyet kaybı nedeniyle pahalı bir durumdur.

Güvenirlilik; herhangi bir ürünün belirli şartlar altında, istenilen emniyet seviyesinde belirlenen süreye kadar fonksiyonunu arızasız olarak yerine getirme ihtimalidir. Ürünlerin sağlamlıklarının tayin edilmesi ile ürünlerin istenilen güvenirlilikte belirli çevre şartlarında fonksiyonlarını arızasız olarak ne zamana kadar getirecekleri saptanır. Bu hesaplamada en önemli etkenlerin başında ekipmanın hiç arıza yapmadan hizmet verdiği zaman bilgisi gelir. Güvenirlilik analizleri yapılarak ve elde edilen sonuçlar kullanılarak uçağın bakım programı sürekli iyileştirilir. Uygun olmayan ve eksik yapılan bakım güvenirliliği düşürebilir. Arıza meydana gelmeden önce önleyici bakım yapılarak arızanın önüne geçilmiş olunur. Ekipman parçalarındaki hataya sebep olan koşulları ne kadar düzeltirseniz, o kadar yüksek güvenirlilikli ekipmanlara sahip olursunuz

ve iş operasyonlarınızı o denli hatasız ve duraklamalara meydan vermeden yürütebilirsiniz.

Parçaların arızalanma riskleri düşük tutulduğu müddetçe, görevlerini uzun süre ve hatasız yapmaları sağlanır. Bu da ancak, işletme sırasında cihazın durumunun izlenmesi (condition monitoring) ile duyarlı ve sürekli bakım planlarının uygulanması sayesinde mümkün olur. Tekrarlanan arızalar belirlenerek; uçak, sistem ve ekipmanların performanslarını iyileştirmek için gerekli düzeltici işlem geliştirilir. Gerekğinde düzeltici işlem ile ilgili maliyet/fayda analizi yapılır. Performans istenilen seviyeye gelene kadar, sistem periyodik olarak geri beslemeler yapılmalıdır. Güvenilirliğin kendisinden başka, bir sistemin güvenilirliğini karakterize etmede kullanılan başka ölçümlerde mevcuttur. Tamir edilebilen sistemlerde; iki arıza arasındaki ortalama süre (MTBF) kullanılır.

$MTBF = \text{Çalışma Süresi} / \text{Gerçek arıza sayısı}$, formülü ile hesaplanır.

1.2. Uçak Bakımı

Uçak sistemlerinin güvenilirliği, uçağın faal olarak uçuşa hazır olması, uçuş sırasında ekipmanlarının arızaya düşme sürelerinin uzun olması, güvenlik, maliyet ve performans açısından çok önemlidir. Uçağın ekipmanlarının çalışabilir durumda olması ve çalışma ömürlerinin uzun olması için öncesinde bakım planlarının takibi ve optimum seviyede yapılması da büyük önem taşımaktadır. Uçak bakım faaliyetlerinde amaç, emniyetin sağlanması, uçağın uçuşa hazır durumda bulunmasının sağlanması ve emniyet faktöründen ödün vermeden maliyetlerin azaltılması şeklinde özetlenebilir. Bakım faaliyetlerinde uçağa uygulanacak bakım tipleri ve periyotları belirtilir. Uygulanan bakımların içeriği, süresi bakıma alınan uçağın tipine ve uçuş süresine bağlıdır.

Uçakların sistem ve teknik birimlerindeki arızaları doğru bir şekilde ortaya koyabilmek için ilgili bakım, arıza, tamir, sökme / takma zamanı gibi verileri toplanır. Bu veriler istatistiksel ve matematiksel yöntemler ile işlenir ve elde edilen nitelikler raporlar, tablolar ve grafikler ile sunularak analiz edilir. Bir ekipmanın güvenilirliği ifade edilirken ekipmanın yerine getirmesi gereken fonksiyon, arızayı oluşturan sebepler açıkça tanımlanmalıdır. Bir ekipmanın yaşam süresi ölçülmeden önce ekipmandan beklenen fonksiyon, çalışma koşulları ve neyin arıza olduğu açıkça tanımlanmalıdır. Ekipman güvenilirliği; ekipman performansının uçuş sayısı veya saatine göre istatistiksel olarak ölçülmesidir. Bu veriler kullanılarak arızalar arasındaki ortalama süre, plansız sökümle arasındaki ortalama süre, planlı sökümle arasındaki ortalama süre ve sökümle arası süre

bilgileri analiz edilir. Güvenilirlik, çalışma koşullarına, çevresel faktörlere göre değişiklik gösterebilir.

Uçak sistemlerine uygulanan bakım planları, uçağın üretildiği ülkenin sivil havacılık yetkilisi tarafından onaylanan ve uçak üreticisi tarafından yayınlanan bakım analiz raporu ve bakım planlama dokümanlarında tanımlanan kurallar ve prensipler doğrultusunda uçağın bulunduğu ülkenin sivil havacılık yetkilisi onayı ile uygulanır. Teknik bakım planlarında uçağa uygulanacak bakım tipleri ve periyotları tanımlıdır. Uygulanacak bakımların içeriği, süresi bakıma girecek uçağın tipine, sorti sayısına ve uçuş süresine bağlıdır.

1.1.1. Ekipman arızaları ve MTBF

Uçak bakımında ekipman sökme, takma ve arıza verilerinin analizi çok önemlidir. Bakım işlemlerinde özellikle önemli bir parametre, belirli bir tamir edilebilir ekipmanın güvenilirliği ile ilgili bir terim olan MTBF, arızalar arasında geçen ortalama süredir. MTBF, adından da anlaşılacağı gibi belirli bir ekipmanın arızalar arasında gerekli işlevini başarıyla yerine getirdiği ortalama süredir (Oladokun and, 2010). Bu anlamda MTBF tamir edilebilir ekipmanların güvenilirliklerini ölçmek için kullanılır (Nguyen, 2008). MTBF sonuçlarına göre, ekipman güvenilirliğini ve bakım yapılabilirliğini belirlemek ve hangi ekipmanın sistem performansında kritik olduğunu tespit etmek mümkündür. Arıza verileri farklı tedarikçilerden alınan ekipmanlar arasında karşılaştırmak için MTBF değerleri kullanılır ve tedarikçiler de ekipmanlar için kendi hesapladıkları MTBF değerlerini sağlarlar.

MTBF kavramı güvenilirlik literatüründe oldukça sık görülür ve arıza durumunda değiştirilebilen onarılabilir ekipmanlar için geçerlidir. Bu tür ekipmanlar tamirden sonra yeni gibi kabul edilebilir. Tamir edilebilir bileşenler, bileşenin değiştirilmesi dışında bir prosedürle yeterli performansı sağlamak için yenilenebilir (Garmabaki, 2016). Müşteriler genellikle hangi ürünü satın alacaklarına karar verirken güvenilirlik verilerini de incelerler. Tamir sürelerinin, arızalar arasındaki sürelerle kıyasla küçük olduğunu varsayarlar. Bu çalışmada aynı zaman aralığında gözlemlenen aynı Hat Değiştirme Ünitesi LRU (Line Replacement Unit) içinde kullanılan iki farklı üreticinin malzemelerini ele almaktadır. Aynı ünitenin güvenilirliği; tasarım yapısı, üretim prosedürü, operasyonel pozisyonlar ve çevresel durumlar gibi farklı faktörler nedeniyle değişebilir.

MTBF bir ekipmanın bileşenin güvenilirliği ile ilgilidir ve maliyet-fayda analizi için tarafından önerilen güvenilirlik özelliklerinden elde edilen bir performans ölçütüdür

(Baptista, 2018) (Elerath, 2012). Ekipman arızaları arasındaki ortalama süre için istatistiksel bir değerdir ve bir tüketicinin hangi alternatiflerini satın alabileceğine karar verirken çok önemlidir. Bununla birlikte bu değer yanıltıcı olabilir ve hesaplanması da çok zor olabilir. MTBF hesaplamaları, arıza olasılığını belirlemek için kullanılır ve tüketiciler bir bileşenin MTBF değerlerine bakarak ve buna göre varsayımlar yaparlar.

Dakikalar mertebesinde çalışmama süresi uçakların çalışmasını olumsuz etkileyebileceğinden, uçak sisteminin durumunun güvenilir olması şarttır. Kritik bir görevde, başarısızlıklardan kaçınmak her zaman en önemli önceliktir. MTBF güvenilirliklerin karşılaştırılmasında kullanılan tipik bir ölçüdür. Malzemelerin belirlenmesi ve seçimi için çeşitli faktörlerden biri olarak kullanılabilir. MTBF uçak ekipmanlarını karşılaştırırken genellikle kilit bir karar alma kriteri olarak önerilmektedir. Üreticiler bazen kullanıcıyı bir karşılaştırma yapmakta yetersiz bırakan yanlış bilgilendirici değerler sağlarlar. Sonuçta MTBF, onaylanmış arızanın tanımı net değilse veya varsayımlar yanlış anlaşılırsa işe yaramaz (Torell, 2011).

Günümüzde bir ekipmanın satın alma maliyeti ve kalitesi gittikçe önem kazanmaktadır. Ayrıca, yaşam döngüsü boyunca bakım ve tamir maliyetleri müşterilerin karar alma süreçleri üzerinde çok büyük bir etkiye sahiptir. MTBF parametresi, ekipmanın beklenen performansı gösterdiğinde arıza oranını ve aktif zamanı ölçmek için sayısal veriler sağlar. Bu, bir ekipmanın yaşam döngüsü hakkında en yaygın analizdir. Bir ekipman kritik bir sistemde kullanıldığında MTBF parametresinin önemi daha da artar. MTBF karar verme sürecinin ayrılmaz bir parçasıdır ve bunu güvenilirlik veya sistem mühendisleri takip eder. Doğru bakım planlaması, MTBF, Ortalama Arıza Süresi (MTTF), Ortalama Onarım Süresi (MTTR) gibi yaklaşık ilgili bakım sistemi parametrelerinin hesaplanmasıyla belirlenir (Oladokun and, 2010). Bu parametreler parçaların birbirine tepki verdiği karmaşık durumlardan etkilenir.

MTBF hem güvenilirliği hem de kullanılabilirliği etkiler. Ancak güvenilirlik ve kullanılabilirlik arasındaki fark genellikle tam olarak bilinmemektedir. Güvenilirlik, bir sistemin veya bileşenin, gerekli işlevleri belirli bir süre için belirtilen koşullar altında gerçekleştirme olasılığıdır. Öte yandan, kullanılabilirlik, bir sistemin veya bileşenin kullanım için gerektiğinde ne kadar işlevsel ve erişilebilir olduğudur (Kiureghian ve ark., 2007). Yüksek güvenilirlik ve kullanılabilirlik, düşük yaşam döngüsü maliyetleri ile tüm bakım programları için ortak hedeflerdir (Morelli, 2016) (1991).

Bir malzeme seçerken, karar verme kriterleri maliyet ve kalan faydalı ömür RUL (Remaining Useful Life) kullanılması, MTBF yerine operasyonel bir risktir. Günümüzün

karar destek süreci duyarlı ve planlanmamış bakım üzerine inşa edilmiştir. Düzeltme işlemi, bir sorunun gerçek nedenini tanımlar ve daha sonra gerekli bakım işlemleri gerçekleştirilebilir. MTBF programı malzeme karşılaştırmaları için iyi geliştirilmiş bir kullanıcı ara yüzü ortamı sağlar, böylece planlamacının karar vermesine yardımcı olur (Papakostas, 2010).

MTBF karşılaştırmasına olan güveni değerlendirirken, arıza ve tamir verilerinin analiz edilmesi için bakım sürecinin anlaşılması önemlidir. Açıkça tanımlanmış ve belgelenmiş bir bakım süreci, güçlü bir kalite politikası uygulamak için çok önemlidir. Bu durum doğrulanmış bir arıza için teşhis ve analiz aşamalarında tutarlılık ve kesinlik sağlar. Alan verilerinin toplanması ve analiz edilmesi sırasında birçok özellik ve varsayım kullanılır ve her biri karar üzerinde önemli bir etkiye sahip olabilir. MTBF karşılaştırmasında kullanılan uçak sistemleri bileşeninin özellikleri eşdeğer olmalıdır. Her bileşen bir sistemde farklı ayarlanmışsa, bunların taraflı karşılaştırılması kaçınılmazdır. MTBF değerleri karşılaştırılacağında, her bir malzemenin kabul edilebilir bir nüfus aralığında olup olmadığı çok önemlidir. MTBF değerleri karşılaştırılan malzemelerin eşdeğer olmaları önemlidir. LRU bileşenlerinin birbirlerinin yerine kullanılabilmesi için aynı konfigürasyon yapısında değiştirilebilir muadil olmaları gerekir. Karşılaştırılan bileşenler, işlevsel yeteneklerde ve uygulamada benzer olmalıdır.

Planlı önleyici bakım ve düzeltici bakım gibi geleneksel bakım stratejileri, birçok endüstriyel alanda güvenilirlik ve güvenlik gereksinimlerini karşılamada giderek azalmaktadır (Zhao, 2017). Düzeltici bakım arızanın oluşmasından sonra gerçekleştirilir. Tamirler daha fazla işlevsel kullanım kaybına neden olan bir arızadan sonra planlanır. Önleyici bakım işlemleri planlanan zaman aralıklarında gerçekleştirilir. Bakımla ilgili bilgiler, üretici tarafından sağlanan ekipmanın teknik dokümanlarında verilmektedir (Bunea, 2008).

Duruma dayalı kestirimci bakımda bir sistemin operasyonel verimliliğini artırmak ve alınacak önlemleri belirlemek için ekipmanların çalışma koşulları, çalışma geçmişi ve teknik koşulları izlenir (Daniewski, 2018). Duruma dayalı bakımda belirli göstergeler, performansta azalma veya yaklaşan bir arıza gösterdiğinde bakım yapılması gerekir. Bileşenlerin göstergeleri doğru ölçümler, grsel analiz, performans verileri ve testler için kontrol edilir. Duruma dayalı kestirimci bakım, kritik ekipmanların veya havacılık ekipmanı gibi maliyetli çalışmama süreleri olan sistemlerin güvenilirliğinde giderek daha fazla öneme sahip olmaktadır (Zhao, 2017).

Ekipman arızalarını azaltmada önleyici bakımın ve operasyonel bakımın başarısının son derece kritik olduğu yaygın olarak kabul edilmektedir. Önleyici bakım yaklaşık olarak durum tabanlı ve zamana tabanlı bakım olarak alt gruplara ayrılabilir. Sensör teknolojisindeki son gelişmeler, durum temelli bakımın önemine katkıda bulunmuştur. Diğer yandan, durum izlemesi bazı sistemler için mümkün olmayabilir ve durum temelli bakım faaliyetlerinin zaman içinde planlanması zor olabilir (2015).

Küvet eğrisi, zaman içinde değişen ekipman arızası oranını gösterir. Şekil 2'de gösterilen üç adet küvet eğrisi periyodu vardır. Bebek ölüm oranı (erken yaşam), başlangıçta daha yüksek arıza oranlarına sahip zayıf bileşenlerin arızası ve bunu takiben sabit bir düşüştür. İlk dönem azalan bir arıza oranı ile karakterize edilebilir. Daha zayıf ekipmanlar başarısız olur ve daha katı bir nüfus bırakır. Olgunluk dönemi, rastgele arıza süresi, ekipmanın kullanılabilir ömrünü temsil eden düşük sabit bir orandır. Faydalı ömür arıza oranı, aşırı yük gibi dış kuvvetlerden etkilenir. Bu süre zarfında arızalar rastgele bir sırada meydana gelir. Yaşlılık döneminde aşınma süresi, bileşenlerin ömrünün sona erdiğini gösteren sürekli artan bir orandır. Bunun nedeni, bileşenlerin eskimesi ve artan oranda bozulmaya başlamasıdır (DoD, 1998). Küvet eğrisi, tek bir bileşen yerine, toplam ekipmanların zaman içindeki arıza oranını temsil eder. Bir ürünün yaşam döngüsü, zaman içinde



Şekil 1.2'de gösterilmiştir.



Şekil 1.2 Üç arıza dönemi dağılımına ait kuvvet eğrisi

Yeni ürünler çok sayıda kurulumunda etkisi ile daha fazla arızaya ve arıza bulunamadı NFF olaylarına neden olur ve kuvvet eğrisinde ilk dönem (bebek ölüm oranı) başarısızlık oranını sunar. Düzenli bir değerlendirme süreci sağlamak için onaylanmış arıza olayları net olarak tanımlanmalıdır. Herhangi bir ekipmanın arızasını teşhis etmeden önce üreticinin açık bir arıza tanımı vermesi önemlidir. Bazen MTBF'yi hesaplamak için üreticiler birden fazla arıza tanımı yaparlar.

1.1.2. NFF durumu

Bir operatör bir sistem arızası gerçekleştiğinde bunu kaydeder ve sistem arızasının nedenini araştırması için durumu bakım personeline bildirir. Bu durumda herhangi bir neden bulunamazsa bu arıza NFF (No Fault Found) arıza bulunamadı olarak etiketlenecektir (Khan, 2014b). Tüm süreç boyunca bu duruma katkıda bulunan çeşitli nedenler olabilir. NFF oluşumları ile ekipmanın tipi, ekipmanın kullanımı ve karmaşıklığı arasında bir ilişki vardır. Havacılık endüstrisi, öncelikle uçak aviyonik sistemlerinde olmak üzere elektronik NFF arızalarının önemini kabul etmiştir. Uçaklar, NFF için önemli yıllık harcamalara neden olan başka birçok faktöre sahiptir. Buna ek olarak, tipik bir filo için NFF yükünün yıllık milyon dolar olduğunu gösteren yedek parçalar, bakım çalışma saatleri, uçak duruş süreleri ve benzeri dâhil olmak üzere uçak teşhis ve kurtarma maliyetlerinin gizli maliyetleri vardır. Çoğu havacılık mühendisi, herhangi bir sistem veya ekipman için tahmini NFF oranlarının % 30 ila % 50 arasında olduğu konusunda hemfikirdir (Khan, 2014b). Bu durum NFF sorununun operasyonel kullanılabilirliği azalttığı, maliyet ve kaynaklar üzerinde önemli bir etkiye sahip olduğu anlamına gelir.

NFF olayları bakım, onarım düzeyinde zaman alıcı ve pahalıdır. Servis tezgâhları; analiz yöntemleri, kapsamlı testler ve ayrıntılı ölçümleri değerlendirerek bu sorunu

ortadan kaldırabilir. Yanlış alarmlar, uçak sistemlerinin bakımında büyük problemlerdir. Havacılık teknolojisinde son on yılda yanlış alarm olayları üzerinde çalışmalar çok ilgi görmektedir (Khan, 2015). NFF kavramını anlamaya çalışırken, aşağıdaki dört konu göz önünde bulundurulmalıdır: (1) NFF arızasının belirli ekipman türleri (hem finansal hem de performans açısından) üzerindeki etkisi, (2) arızaların sıkça ortaya çıktığı koşulları tanımlamak (3) NFF başarısızlıklarının yeniden ortaya çıkma oranı ve (4) altta yatan nedenler (Khan, 2014b). Mekanik sistemlerde başarısızlığın ana nedenleri genellikle eskime, yetersiz bakım, yanlış montaj veya kullanımdır (Khan, 2014a). Mekanik arızalar doğada kesintili olabilir ve belirli çalışma koşullarında ortaya çıkabilir.

NFF olayları operasyonel kullanılabilirliği azaltır ve maliyetler / varlıklar üzerinde olumsuz bir etkiye sahiptir. Kılavuzlardaki kalite ve kapsamlı teknik içerik eksikliği bakım personelinin arıza nedeninin doğru teşhisine ulaşma kabiliyetini etkiler. Zaman baskısı, arızayı doğru bir şekilde teşhis edememenin ana nedenidir (Hockley, 2017). (Ungar, 2015) 'ye göre NFF durumları (cannot duplicate, CND), yanlış alarmlar ve tekrar test (retest OK, RTOK) durumlarından etkilenir.

Birçok profesyonel, NFF olaylarına katkıda bulunan önemli faktörlerin, yetenek kümeleri, hesap verebilirlik, kurumun organizasyon kültürü, personellerin NFF ile ilgili kararlar alma tecrübesi, kuruluşun teknisyenleri, bakım mühendisleri ve yönetim personeli arasındaki iletişim eksikliği olduğu konusunda hem fikirdir. NFF olaylarını etkileyen diğer faktörler arasında genellikle iletişim eksikliği, doğru prosedürleri takip etmeme, kişisel davranışlar, eğitim eksikliği, uygun cihazların kullanılması ve operasyonel baskı gibi bireysel davranışlar bulunmaktadır (Khan, 2017). NFF olaylarına ilişkin kararlar, fiziksel ortam, çalışma koşulları, zaman baskısı ve fazla belirsizlikler gibi konulardan etkilenebilir. Bireylerin sorun giderme süreçlerindeki deneyimi büyük ölçüde iş süreç tecrübelerine bağlıdır. NFF maliyetleri düzeltici ve önleyici bakım arasında dağıtılır. NFF maliyetinin çoğu (yaklaşık% 90) düzeltici bakım sırasında ve geri kalanı önleyici bakımda keşfedilir. Uçak aviyonik sistemlerindeki NFF maliyetleri, kaybolan çalışma saatleri, makine arıza süreleri, elverişsiz maliyetler ve onarım maliyetlerini içerebilir (2016).

1.3. Tezin Amacı

Bakım bir parçanın istenilen ömür çevrimi içerisinde gerekli fonksiyonlarını yerine getirebilecek şekilde korunması için teknik eylemlerin bir bütünü olarak tanımlanabilir. Uçak sistemlerinin güvenilirliği, uçağın faal olarak uçuşa hazır olması, uçuş sırasında ekipmanların arızaya düşme sürelerinin uzun olması, güvenlik, maliyet ve performans

açısından çok önemlidir. Uçağın ekipmanlarının çalışabilir durumda olması ve çalışma ömürlerinin uzun olması için öncesinde bakım planlarının takibi ve optimum seviyede yapılması da büyük önem taşımaktadır.

Bu tez kapsamında amaç geçmiş uçak bakım ve arıza verilerini kullanılarak malzeme ve ekipman bazında MTBF hesabı yapmak ve yapay zeka uygulamaları ile ileride oluşabilecek arıza sayısı tahmininde bulunarak bakım periyotlarını, malzeme ihtiyaç planlamasını ve depolardaki malzeme miktarını ona göre düzenlemektir. Ayrıca plansız sökme ve takmaların azaltılması, beklenmeyen arızaların azaltılması, gereksiz bakımların iptal edilmesi, planlı bakım aralıklarının verimli bir şekilde ayarlanması, uygulanan bakımların etkinliğinin ölçülmesi ve bakım maliyetinin düşürülmesi hedeflenmektedir. Geç arızalanan ekipmanların bakım periyodunu genişleterek bakım maliyetlerini düşürmek ve sık arızalanan ekipmanların bakım periyotlarını sıklaştırarak uçakların daha uzun faal kalmasını sağlamakta amaçlardan biridir.. Elde edilecek sonuçlar atölyelerde, bakım birimlerinde mühendisler tarafından incelenerek bakım planlama değişikliği, malzeme ihtiyaç planlaması, depolarda malzeme miktarı konularında öngörü olarak kullanılacaktır.

Bir uçak için uçuş öncesi yapılan bakım faaliyetleri ile uçuş sonrasında yapılan planlı bakım ve/veya tamir faaliyetleri bakım modülünde kaydedilmektedir. Buna ek olarak bakım planlarına, bakım el kitaplarına, üretici talimatlarına göre de bakım süreleri otomatik olarak sisteme aktarılmakta, ekipmanların bakımı, bakım periyotlarına göre planlı olarak gerçekleştirilmektedir. Planlı bakım faaliyetlerinin yanında arızaya bağlı olarak kaynak yönetim sisteminde arıza bildirimleri oluşturulmakta, bu bildirimlere öncelik sırasına göre cevap verilmektedir.

Kaynak yönetimi sisteminde bakım modülünde biriken arıza ve bakım verilerinden önemli olanları belirlemek, gereksiz olanları elemek için özellik seçimi algoritmaları kullanılmıştır. Bu şekilde veri analizi yapılarak verilerin önem derecesi belirlenecek ve yapay zekâ ve makine öğrenmesi algoritmalarının performansının artırılması hedeflenmiştir. İki aşamalı hibrit veri hazırlama yöntemi ile veri eleme işlemi yapılarak örnek bir veri hazırlama yöntemi belirlenmiştir. Hazırlanan veriler yapay zeka makine öğrenmesi algoritmaları ve optimizasyon algoritmaları ile modellenerek sonuçları ve performansları karşılaştırılarak en etkin olanın tespit edilmesi amaçlanmıştır. Böylece ekipman arıza sayısı tahmin sonuçları analiz edilerek en etkin metotlar belirlenmiştir. Elde edilen sonuçlar ile malzeme yedek parça kullanımı, malzeme ihtiyaç planlaması ve kestirimci bakım planlaması konularında öngörü olarak kullanılacaktır.

1.4. Literatüre Katkısı

Havacılık endüstrisinde bakım ve güvenilirlik her zaman önemli olmuştur, çünkü bunlar sadece uçağın performansını değil sektördeki finansı da etkilemektedir. Bu nedenle, bir güvenilirlik parametresi olarak arızalar arası ortalama süre MTBF, uçak ekipmanı ve malzemelerinin bakımında kritik öneme sahiptir. Öngörülü bir bakım planı için, ekipman güvenilirliği koşulları hakkında her bilgi güvenilirlik mühendisleri tarafından incelenmelidir. Önleyici ve kestirimci bakım planlaması sadece arıza sürelerini ve maliyetleri azaltmaya yardımcı olmakla kalmaz, aynı zamanda uçakta kullanılabilirliği faal kalma süresini de artırır. Doğrulanmış arıza sayıları dikkate alınırsa, etkili MTBF hesaplamaları doğru şekilde yapılır. Potansiyel arıza bulunamadı NFF olayları ekipman arızasından sonra belirlenmelidir. Arıza, tamir atölyesi testinden sonra teyit ve servis verilebilir olduğundan, tamir işleminin bakım verileri izlenmelidir. Bu tez kapsamında belirli tipteki uçak sisteminde kullanılan ekipmanlarının bakım ve arıza kayıtları analiz edilmiştir. Farklı üreticilerin malzemelerinin ekipman verileri kullanılarak güvenilirlik parametresi MTBF, NFF durumları dikkate alınarak hesaplanmış ve karşılaştırılmıştır. Eski bakım verileri kullanılarak elde edilen sonuçlar uçak güvenilirliğine ve kullanılabilirliğine katkıda bulunabilir ve karar verme sürecine destek vererek bakımın iyileştirilmesine yardımcı olabilir. Bu tezin literatüre katkılarında bir tanesi MTBF hesabı sırasında gerçek arızaları tespit ederken izlenen yöntemler, yazılan programlar olabilir.

Havacılık endüstrisinde, gelecekteki eylemlerin öngörülmesinde anlamlı sonuçlar elde etmek için kullanılabilecek çok sayıda bilgi ve bakım verisi bulunmaktadır. Uçak sistemlerinin arızalarını tahmin etmek için özellik seçimi ve veri elenmesine dayalı makine öğrenme modellerini tanıtmayı amaçlamaktadır. İki yıl boyunca uçak ekipmanlarının bakım ve arıza verileri toplanmış, dokuz girdi ve bir çıktı değişkeni titizlikle tanımlanmıştır. Arıza sayısı tahmininin başarısını artırmak için iki aşamalı hibrit veri hazırlama modeli önerilmiştir. İlk aşamada, nitelik değerlendirerek en etkili ve en etkisiz parametreleri bulmak için bir özellik seçme yöntemi olan ReliefF kullanılmıştır. İkinci aşamada gürültülü veya tutarsız verileri elemek için geliştirilmiş K-ortalamlar algoritması kullanılmıştır. Hibrit veri hazırlama modelinin ekipmanın bakım veri kümesindeki performansı, makine öğrenimi algoritmalarından; Yapay Sinir Ağı (YSA) olarak Çok Katmanlı Algılayıcı (MLP), Destek Vektör Regresyonu (DVR) ve Doğrusal Regresyon (DR) ile değerlendirilmiştir. Ayrıca bu modellerin performanslarını karşılaştırmak için Korelasyon Katsayısı (CC), Ortalama Mutlak Hata (MAE) ve Kök

Ortalama Kare Hatası (RMSE) gibi performans kriterleri kullanılmıştır. Sonuçlara göre hibrit veri hazırlama modelinin ekipmanın arıza sayısını tahmin etmede başarıyı artırdığı gösterilmiştir. Literatüre katkı olarak iki aşamalı hibrit veri hazırlama yöntemi ile satır ve sütun olarak veri eleme yöntemleri gösterilebilir.

Uçak ekipmanlarındaki arıza sayısını tahmin etmek için optimizasyon algoritmalarından genetik algoritma (GA), dağıtık arama (DA) ve diferansiyel evrim (DE) algoritmaları doğrusal, kuadratik, üstel ve hibrit modellerle uygulanmıştır. Üç algoritmanın (GA, DA, DE) sonuçları, dört farklı modele (doğrusal, kuadratik, üstel ve hibrit) göre karşılaştırılmıştır. Sonuçlar GA'nın kuadratik modellerde daha başarılı olduğunu, DA ve DE algoritmalarının üstel ve hibrit modellerinde daha başarılı olduğunu göstermiştir. Buna ek olarak optimizasyon tabanlı tahmin yöntemlerinin daha başarılı olduğu aynı veri kümesinde makine öğrenimi yapay zeka tabanlı tahmin sonuçları ile elde edilen sonuçların karşılaştırılmasıyla ortaya çıkarılmıştır. Ayrıca literatüre katkı olarak uçak bakım ve arıza verilerinden bakım alan uzmanları ile bu alanda tespit edilen nitelikler ve bu nitelikler arasında en etkin olanların tespit edilmesi de eklenebilir.

1.5. Tezin Organizasyonu

Yapılan tez çalışması 6 başlıkta ele alınmıştır. İlk başlık olarak uçak bakımı hakkında genel bilgiler verilmiştir, Bakım nedir, süreçleri nelerdir, MTBF ve NFF hakkında genel bilgiler verilmiştir. Arıza ve bakım verisi toplama ve özellik seçimi aşamasından yola çıkarak yapılan tez çalışmasının içeriği, amacı ve literatürdeki yeri gibi bilgilere değinilmiştir. İkinci bölümde MTBF, NFF, arıza tahmini, tahmin algoritmaları, optimizasyon algoritmaları hakkında literatür taramalarına yer verilmiştir. Üçüncü bölümde ise tez çalışmasında kullanılan materyal ve metotlar hakkında bilgiler verilmiş, kullanılan yazılım ve yöntemlere değinilmiştir. Dördüncü bölümde uçak bakım periyodu tahminine yönelik çalışmalar ele alınmıştır. Beşinci bölümde ekipman arıza sayısının yapay zeka ve makine öğrenmesi algoritmaları ile uçak ekipmanlarının arıza sayısı tahmini ve hibrit veri hazırlama yöntemleri anlatılmış, nasıl uygulandığı hakkında bilgiler verilmiştir. Elde edilen sonuçlar incelenip, karşılaştırmalar yapılmıştır. Aynı veriler kullanılarak optimizasyon algoritmaları ile tahminler yapılarak elde edilen sonuçlar incelenip, karşılaştırmalar yapılmıştır. Altıncı bölümde elde edilen sonuçlar incelenmiştir.

2. KAYNAK ARAŞTIRMASI

2.1. Bakım Süreçlerinde Kaynak Araştırması

Güvenilirlik analizleri, arızalar arasında geçen süre ve gerçek arıza durumu, yanlış arıza alarmı ve arıza bulunamadı durumu (NFF), konularında pek çok çalışma bulunmaktadır. Bu bölümde bu konular ile ilgili yapılmış çalışmalardan örnekler verilecektir.

Oladokun ve arkadaşları (Oladokun ve, 2010) otomobil lastiği üreticisi bir şirketin verileri ile yapılan çalışmada üretim ekipmanlarının 12 aylık bakım verilerinden, arızalar arası ortalama süre (MTBF) ve bazı anahtar etkenler (mekanik, elektriksel arızalara, sıcaklık, gece, gündüz vs.) kullanılarak YSA modeli çıkarmışlardır. Bu yapay sinir ağıları modeli ile ekipmanların MTBF süre tahmini yapılmıştır. Çok katmanlı geriye yayılma algoritması ile YSA modeli oluşturulmuştur. Makinenin 12 aylık toplanmış bakım verisi kullanılmıştır. Veri parçaları 3 sete bölünerek eğitim, doğrulama ve test verisi olarak analizde kullanılmıştır. Geri yayılım metodu ile YSA öğretilmiş ve test edilmiştir. Modelin doğruluk oranı %82 olarak hesaplanmıştır. Bu çalışmada elde edilen YSA modelinin kullanışlı bir bakım yönetim aracı olarak hizmet vereceği gösterilmiştir.

Jun yaptığı çalışmada (Jun, 2012) güvenilirlik analizinin ve Arıza Modu Etkisi ve Kritiklik Analizi (FMECA) yöntemlerinin uygulanmasının ekipmanın ömrünü uzattığı ve operasyonel güvenilirliğini artırdığı göstermiştir. Uçak ekipmanlarının güvenilirlik modellemesi yapılmış ve MTBF değeri tahmin edilmiştir. FMECA yöntemi, ekipmanı kullanırken ve bakımını yaparken güvenilirliğini artırmak ve arıza modellerini teşhis etmek için kullanılmıştır. Bu çalışmada aynı tip uçak ekipmanlarının MTBF değerleri karşılaştırılmıştır ve FMECA yöntemi kullanılarak korunan ekipmanın MTBF değerinin diğer ekipmanlardan daha uzun olduğu tespit edilmiştir.

Braglia (Braglia, 2012) çok değişkenli veri sınıflandırması ve MTBF tahmini analiz yaklaşımı çalışmasında belirli çalışma koşullarına tabi tutulan mekanik bileşenlerin arıza arasındaki ortalama süre (MTBF) açısından sınıflandırılmasını destekleyen çok değişkenli bir istatistiksel yaklaşım sunmaktadır. Çalışma koşullarının ve/veya çevresel faktörlerin MTBF üzerindeki etkisinin değerlendirilmesi, etkili bir koruyucu bakım planının geliştirilmesi için bir ön koşul olduğu ortaya konmuştur. Bu yaygın sorunu çözmek için, adım adım çok değişkenli veri sınıflandırma tekniği önerilmiştir. Bu çalışma sadece analiz edilen bileşenlerin MTBF değerini tanımlamakla kalmaz aynı zamanda

gözlemlenen verilerin değişkenliğinin çoğunu açıklayan çalışma parametrelerini tanımlamayı da mümkün kılmıştır.

Chen ve arkadaşları (Chen, 2008) yapay sinir ağları tabanlı SOM tekniğini kullanarak uçak ekipmanlarının MTBF odaklı arıza tahmin modeli tanıtılmıştır. SOM kullanılarak arıza verileri ile uçak ekipman güvenilirliği tahmin edilmiştir. MTBF odaklı tahmin modelinin etkinliği, MTBF çalışması ve analiz sonuçları ile gösterilmiştir. Uçak ekipmanlarının weibull güvenilirlik modeli de kurularak ayrıca desteklenmiştir. Bu metot olası arızalar oluşmadan önce yeterli hazırlık zamanı olacak şekilde gerçek sistem arızalarını teşhis etmeye yardımcı olmuştur. Bu şekilde önleyici bakımın planlanmasına fırsat vererek çalışmada süresi maliyetini önemli derecede düşürmüştür. Sonuç olarak bu çalışmada uçak ekipmanı güvenilirlik analizi için SOM'un güvenilir ve sağlam bir sistem olduğu gösterilmiştir. SOM durum tabanlı önleyici bakım kavramı gerçekleştirilmiştir.

Daniewski ve arkadaşları (Daniewski ve ark., 2018) bir gıda endüstrisi şirketindeki bir imalat işletme sisteminde uygulanan bakım süreçlerindeki 10 aylık veriler ile gerçekleştirilen eylemlerin ve onarımların etkinliğini açıklayan göstergelerin analizleri ve sonuçları raporlamışlardır. Bu etkinlik göstergelerinin analizi, bakım hizmetlerinin işleyişini iyileştirmiş, yüksek bir seviyeye çıkmasını sağlamış ve bakım işlerinin organizasyonu üzerinde olumlu etkisi görülmüştür. Bu makalede, söz konusu şirketin bakım hizmetleri tarafından kullanılan dört etkinlik göstergesi; ortalama arıza süresine (MTTF), ortalama arızalar arasındaki süre (MTBF), (MTTR) ve genel ekipman etkinliği (OEE) kullanılmıştır. Analizin amacı, yukarıdaki göstergelerin doğru bir şekilde belirlenmesi ve bunların sonuçlarının doğru bir şekilde yorumlanıp bakım hizmetleri biriminin arızalar gerçekleşmeden önce etkili önlemleri almasıdır.

Jeon ve arkadaşları (Jeon ve ark., 2015) dizel motorların dört yıllık garanti verilerini kullanarak arıza modelleri incelemişlerdir. Üretim koşulları, arıza ilişkileri, arızalar arasında geçen süre MTBF ve sıralı arıza dizileri analiz etmişlerdir. Weibull dağılımı kullanılarak önemli değişkenlerin tanımlanmış kurallar içinde arıza zamanını etkilemesine bakmışlardır. Parçaların imalatı hakkında daha fazla bilgi, ürün bilgileri, üretim süreci, arıza durumundaki kullanım uyarlamaları ile stok ve teslimat hakkında bilgilerin arıza ile bağlantıları, iyileştirme önerisi sunarken bunlarla bağlantılı olduğunu göstermişlerdir. Ortak arızalar arasındaki ortalama süreyi (MTBF) tahmin etmek için değişkenler, imalat ve ürünler hakkındaki kategorik verileri analiz için kullanmışlardır. Arızalar arasında geçen süreyi (MTBF) tahmin etmek için bir model oluşturmak ve etkili

karar verme aracı tasarlamak için detaylı imalat ve parça verileri ile ürün verileri kullanmışlardır.

Changhua ve arkadaşları (Hu ve ark., 2015) yaptıkları çalışmada son teknoloji arıza giderme ve ömür tahmin teknikleri ve yaklaşımlarını tanıtmışlardır. Ekipman seçimi için pratik mühendislik deneyimine göre temel olarak maliyeti ve test süresini kullanmışlardır. Bu çalışmada ekipman arızası giderme, çalışan ekipmanın kalan kullanışlı ömür zamanı tahmini, ekipman depolama, ömür tahmini gibi mühendislik problemlerine bakış açısı incelenmiştir. Nitel bilgi ve nicel kaynaşmayı birleştiren ömür tahmini bilgisi, çalışma süresi, depoda geçen süre vb. durum değişiklikleri ile ekipmanın ömür tahmini arasında ömür dönüşümü incelenmiştir. Bir ekipmanın ömrünü tahmin etmenin, arızalar arasındaki ortalama süre (MTBF) ve olasılık güvenilirliği analizi mühendisliği kullanılarak mümkün olduğu gösterilmiştir.

Khan ve arkadaşları (Khan ve ark., 2018) arıza bulunamadı (NFF) olaylarının sistem ömür döngüsü üzerindeki etkisini incelemişlerdir. Sensor yerleştirilmesinin mevcut bir tasarım üzerindeki etkilerini araştıran bir model, yanlış ekipman sökme sayısını etkileme açısından incelenmiştir. Arıza bulunamadı (NFF) olayları, bir sistem içinde arıza analizlerinin gerçekleştirilmesinde önemli sorunlar yaratmaktadır. Bu nedenle ekipmanların başarısız arıza teşhisleri yönetilerek, bakım maliyetleri ve test edilebilirlik gereksinimleri araştırılmıştır. NFF olaylarını etkili bir şekilde düzenlemek için ilkeler ve hesap verilebilirliğin önemi vurgulanmıştır. Bu çalışmada bir sistemin tanı analizinin NFF olaylarının sebebini, sayısını tanımak ve azaltmak için nasıl kullanılabileceği araştırılmıştır. Bu tür çalışmalar, kıyaslama için ve aynı zamanda bir sistemin öngörülen kullanım ömrü boyunca bakım gereksinimlerinin nasıl değişebileceğinin bir ölçüsü için kullanılabilir.

Keivanpour ve arkadaşları (Keivanpour ve ark., 2015) yaptıkları çalışmada uçak motoru bakım faaliyetlerinin güvenilirliğini, ekonomik, çevresel ve sosyal performansını aynı anda entegre etmek için kavramsal bir çalışma çerçevesi sunmuşlardır. Bu çalışma çerçevesinin bir uçak motorunda uygulanması için pratik bir kılavuz gösterilmiştir. Sorunla ilgili geçmiş araştırmaların ana katkısını ve uçak motoru bakım operasyonlarında sürdürülebilirlik yaklaşımını dikkate almadaki mevcut boşluk vurgulanmıştır. Araştırmacılar ve üreticiler için fikir sağlayan ana alanlar açığa çıkarılmıştır.

Arno ve arkadaşları (Arno ve ark., 2015) bakım faaliyetlerinin tüm kritik bölümlerini optimize etme yöntemlerinin temel olarak anlaşılmasını sağlamıştır. Bu çalışma, tek bileşenlerin arıza durumlarına, arızaların ne kadar öngörülebilir olduğuna ve

etkili bir bakım stratejisinin belirli türdeki arızaları nasıl ele alacağına genel bir bakış sunmaya odaklanmaktadır. Bu çalışmanın başarılı sonuçlarının gerçek dünyada hayata geçirilmesi ile şu konularda kazanç sağlanacağı sunulmuştur: İş emirlerinin zamanında uygulanması ile bakım maliyetlerinin % 30 azalacağı, durum tabanlı bakımın gerçek zamanlı uygulaması ile ekipman bütünlüğünden ödün vermeden bakım işlemleri maliyetlerinde binlerce dolar tasarruf edileceği, bakım personellerinin, beceri seviyelerinin ve aldıkları eğitimlerin optimize edileceği, uygun maliyetli bakım sözleşmelerinin yapılabileceği anlatılmıştır. Sonuç olarak bakım süreçlerinde başarı derecesinin, maliyet tasarrufunun büyük ölçüde işletmenin organizasyon yapısına ve bakım stratejisine bağlı olduğu anlatılmıştır.

Papakostas ve arkadaşları (Papakostas ve ark., 2010) bir havacılık işletmesinin hava alanlarındaki dönüş gecikme süresi sırasında hat bakım faaliyetlerinin kısa dönem bir planlama metodolojisini açıklamışlardır. Önerilen yöntem, yüksek filo işletilebilirliği ve düşük bakım maliyeti hedefleyerek, uçakların sevkیاتını etkileyen bakım işlemlerinin ertelenmesine yönelik karar almayı desteklemektedir. Seçilen karar verme kriterleri maliyet, kalan faydalı ömür (RUL), operasyonel risk, ekipman arıza aralıkları (MTBF) ve uçuş gecikmesidir. Bu çalışmada önerilen yaklaşımı doğrulamak ve test etmek için bir dizi deney yürütülmüştür.

Guo ve arkadaşları (Guo ve ark., 2016) güvenilirlik merkezli önleyici bakım optimizasyonu için uçakların göstergelerini incelemişlerdir. Bu çalışmada uçak operasyonlarına destek olarak bakımın, sürdürülebilir kullanılabilirlik, operasyona hazır olma ve güvenlik açısından önemli bir rol oynadığı sunulmuştur. Bu araştırmada, uçak göstergeleri güvenilirlik bilgilerine dayanarak beklenen uzun dönem işletme maliyetini en aza indirerek önleyici bakım aralığını optimize etmek amaçlanmıştır. MTTF, MTBF ve MTBUR metrikleri önleyici bakım aralığı optimizasyon modeli için girdi olarak kullanılmıştır. Optimize edilmiş önleyici bakım aralığı ve güvenilirlik analizi sonuçlarının, arıza oranları açısından arıza kök nedenleri ve arıza mekanizması hakkında bilgi sağladığı ortaya konmuştur.

Varol (2013), yüksek lisans tezinde weibull metodu kullanarak uçak motorlarının öngörülemeyen hasarlanma ve servis dışı kalma zamanları hesaplamaya çalışmıştır. Weibull analizinde önemli olan weibull parametrelerinin hesaplanması olduğu için bu çalışmada parametrelerin hesaplanmasında analitik ve grafik metotları kullanılmıştır. Grafik metodunun, mühendislik çalışmalarında sık kullanılması ve sağlama yapma imkânını vermesi nedeniyle çalışmada, grafik metodu kullanılmıştır. Weibull metoduyla

bütün motorların servis dışı kalma zamanları analiz edilmiş ve bu analizle elde edilen Weibull parametreleri örnek bir filo için değerlendirilmiştir. Yüksek motor bakım maliyetleri dikkate alındığında bu çalışmanın verdiği geri bildirim, havayolu şirketleri için hayati öneme sahip olmuştur. Bu çalışmanın sonucu olarak, herhangi bir operatör elindeki motor filosunun motorlarının durumlarını değerlendirerek, filosunun güvenilirlik seviyesini ölçebilir ve aynı zamanda filosunun muhtemel servis dışı kalma sürelerini de önceden öngörerek, planlamasını ve bütçe yapısını buna göre belirleyebilir.

Duarte ve arkadaşları (Duarte ve ark., 2016) arıza analizinin uçuş güvenliğinin iyileştirilmesinde kilit rol oynadığı tezini desteklemişlerdir. Yaptıkları çalışmada motorlardan, uçak yapılarına ve iniş sistemlerinden hidrolik sistemlere geçen farklı alanları kapsayan arıza analizinin incelenmesi için birkaç vaka çalışması ele almışlardır. Malzeme arıza nedenlerini daha iyi anlamak ve bunlar için stratejiler geliştirmek için çalışmalar yapmışlardır. Çalışmada operatör çalışma gruplarının kurulmasının önemini yanı sıra uçak tasarım ve servis problemlerini tanımlamak ve çözmek için üreticiler ve operatörler arasındaki yakın ve açık bir çalışma ortamının önemini vurgulamışlardır. Ayrıca bu çalışmada insan faktörünün uçak sistemleri ve bileşenlerinin arızalanmasında önemli bir rol oynadığı da açıkça belirtilmiştir. Malzeme arıza incelemelerinin çoğunda arıza olaylarının kök nedeninin doğrudan veya dolaylı olarak insani nedenlerle ilişkili olduğu sunulmuştur.

2.2. Arıza Tahmini Alanında Kaynak Araştırması

Güvenilirlik analizleri ve arıza tahmini konularında pek çok çalışma bulunmaktadır. Bunlarında içinde YSA, DVM ve GA öne çıkmaktadır.

Altay ve arkadaşları (Altay ve ark., 2014) yaptıkları çalışmada Türk Hava okulundaki 60 uçağın 2 yıllık 532 arıza verisini kullanarak uçakların arıza zamanlarını tahmin etmişlerdir. Tahmin için iki model; ileri beslemeli geri yayılım YSA modeli ile GA modeli kurularak karşılaştırma yapılmıştır. İki modelde verilerin %70'i eğitim için, %30'u test için kullanılmıştır. Aynı verilerin kullanıldığı iki modelin algoritmalarının da tatmin edici başarılı sonuç verdiği çalışmada, YSA modelin verdiği sonuçlar biraz daha doğru çıkmıştır. Bu çalışmada uçakların arıza zamanları tahmin edilmiştir ve elde edilen sonuçlar önleyici bakım planlaması için destekleyici olmuştur.

Gurbuz ve arkadaşları (Grbz ve ark., 2011) Türkiye'de bir hava yolu işletmesinin parça bakım raporları üzerinde veri madenciliği çalışması yapmışlardır. Uçaklarda kullanılan ekipmanların bir arıza oluşmadan önce önleyici bakımın yapılması için arıza ikaz seviyelerinin bulunmasına yönelik kural geliştirilmiştir. Ekipmanların arıza ikaz

seviyelerini ifade edecek anlamlı bir kural çıkarılmış ve bu kurallar doğrulukları ve güvenilirlikleri açısından test edilmiştir. Yapılan çalışma ile yaygınlaşmakta olan hava taşımacılığının bakım alanında geliştirilmesinde veri madenciliği metotlarının kullanılabilirliği ve bunlardan faydalanılabileceği ortaya konulmuştur.

Kutlyowska ve arkadaşları (Kutyowska ve ark., 2015) arıza oranı modellemesinde yapay sinir ağları uygulamasının olasılığını sunulmuştur. Polonya'daki bir su tesisinden elde edilen veriler arıza frekansının çıkış değerlerini tahmin etmek için kullanılmıştır. Tahmin sonuçlarına göre yapay ağları su temin sistemlerindeki hasar sıklığını modellemek için kullanılabilir. YSA , 173 veri ve 147 veri (sırasıyla ev boru bağlantıları ve dağıtım boruları) kullanılarak eğitilmiştir. Tüm verilerin% 50'si eğitim, % 25'i test ve % 25'i doğrulama için seçilmiştir. Öğrenme aşamasında deneysel ve tahmin edilen veriler (sırasıyla ev bağlantıları ve dağıtım boruları) arasındaki korelasyon $R^2 = 0,9510$ ve $R^2 = 0,9268$ performans metrikleri ile karakterize edilmiştir. Oluşturulan model, gelecekte su hizmetleri tarafında arıza frekansı seviyesini belirlemek ve bozulmuş boruların yenilenmesini planlamak için kullanılabilir.

Ramos ve arkadaşları (Ramos ve ark., 2014) arızaları ve bakım işlemlerini tespit etmek için ARIMA (zaman serilerini tahmin etmek için kullanılan çok yönlü doğrusal modellerden biridir) ve Yapay Sinir Ağları tahmin modellerinin performanslarını, sensörlerin gelecekteki değerlerinin tahminlerine dayalı olarak karşılaştırmışlardır. Hem YSA hem de ARIMA modellerinin disk değişimini tahmin etme yeteneğine sahip olduğu sonucuna varmışlardır. ARIMA tahminindeki düşüş YSA tahminindeki düşüşten daha belirgin olmuştur. ARIMA modeli, değiştirme işleminden önce ve sonra diskler arasındaki mesafenin artışı, YSA'ya kıyasla daha iyi tahmin etmiştir.

Kozik ve arkadaşları (Kozik ve ark, 2012) PZL 10W motor yenileme sırasında (zor zamana göre çalışırken) yedek parça talebinin değiştirilmesini tahmin etme sırasında uygulanabilir teknikler üzerinde çalışmışlardır. Motorun zor zaman çalışmasında ihtiyaç miktarı zamanını tahmin etmeye dayalı yeni bir tahmin metodu ve yedek parça miktarını tahmin etmede YSA metodu deneysel sonuçlarda sunulmuştur. Elde edilen sonuçlar motorun zor zaman hesaplamasında gerçekleştirilen tahmin yönteminin, MRO (bakım, onarım ve yenileme) tesislerinde yalın üretimin uygulanmasında önemli bir güç olduğunu göstermiştir.

Lan ve arkadaşları (Lan ve ark., 2016) A330-300 uçaklarının yüksek basınç vanalarının bakım kayıtlarını kullanarak geri beslemeli YSA modeli kurmuşlardır. yüksek basınç vanalarının ömrünü tahmin etmek için bu YSA modeli kurularak eğitilmiş ve

doğruluğu gösterilmiştir. Bu araştırmanın sonuçlarına göre yüksek basınç vanalarının hava yollarına kurulumundan önce, kritik önemde bakım verileri modeller giriş olarak verilip kurulumun uçuş süresinin tahmin edilmesi gerekmektedir. Bu çalışmada kurulan tahmin modeli modelinin havayolu şirketleri tarafında uçak yedek parçalarının yönetim stratejilerinde ve önleyici bakım çalışmalarında yol gösterici olması sunulmuştur.

Trani ve arkadaşları (Trani ve ark., 2004) yapay sinir ağlarını kullanarak uçak yakıt tüketimini tahmin etmek için temel bir yöntem getirmişlerdir. YSA tarafından desteklenen bir yakıt tüketimi modeli, uçağın performans kılavuzunda verilen veriler kullanılarak oluşturulmuştur. Bu çalışmada Rolls-Royce Tay 650 motorları ile çalışan Fokker 100 uçağının verileri kullanılmıştır. İkinci olarak SAAB 2000 turboprop uçağının verileri ile iyi sonuçlar elde edilmiştir. Bu yöntemin pistonlu ve turboprop tipi araçlar da dahil olmak üzere herhangi bir uçak tipinde güvenle denenebileceği ortaya konmuştur. YSA modelinden elde edilen sonuçlar analitik modellerle karşılaştırılmıştır. Bu çalışmanın sonucunda üç katmanlı bir doğrusal olmayan transfer fonksiyonlarına sahip yapay sinir ağının, uçuşun tırmanma, seyir ve iniş aşamaları için karmaşık uçak yakıt tüketim işlevlerini doğru bir şekilde temsil edebileceğini ortaya koymuşlardır.

Ossmann (Ossmann, 2014) uçak aktüatör sistemi için arıza tespit ve teşhis sistemlerinin optimizasyona dayalı bir şekilde ayarlanmasını önermiştir. Optimizasyona dayalı teknik, belirsizlikleri ve modelleme hatalarını en aza indirmek için, arıza tespit ve teşhis sisteminin parametrelerini en iyi şekilde seçmek için kullanılmıştır. Optimizasyonlar birçok fonksiyon değerlendirmesinin paralel olarak çalıştırılmasına izin veren, DE arama yöntemi kullanılarak gerçekleştirilmiştir.

Bazargan ve arkadaşları (Bazargan ve ark., 2015) planlı bakımına en yakın olan uçağı sevk edeceği varsayılan uçak sevkiyat stratejisini geliştirmek için bir optimizasyon yaklaşımı modellemişlerdir. Analizde optimizasyon işlemlerinin diğer stratejilere göre yıllık bakım maliyeti üzerinden % 2 - % 5 tasarruf sağlayabileceği gösterilmiştir. Bu strateji mevcut kullanımlarda maliyet tasarrufu ve gelişmiş uçak kullanılabilirliği sağlamıştır. Minimum toplam bakım faaliyeti olan çözüm, minimize edilmiş maliyet yerine tercih edilmiştir. Bu strateji tüm uçaklarda sabit bir kullanım sağlarken, mevcut uygulamalara göre hem maliyet tasarrufu hem de gelişmiş uçak kullanılabilirliği sağlamıştır.

Wijk ve arkadaşları (Wijk ve ark., 2017) güncellenmiş kullanımdan kaldırma planı değişikliklerini, güncellenmiş hata oranlarını, PM aralıklarını, dönüş sürelerini ve maliyetleri hesaplamak için güçlü bir araç yönetimi için bir optimizasyon yöntemi

önermişlerdir. Üç optimizasyon yöntemi olarak kaba kuvvet algoritması (brute force), en dik iniş algoritması (steepest descent) ve GA optimizasyonu kullanılmıştır. Bu üç algoritmanın sonuçları karşılaştırılmıştır. GA yaklaşımı, en hızlı olan ve problem boyutu büyüdükçe daha iyi derecelendirme özelliklerine sahip bir optimizasyon yöntemi olarak önerilmiştir. Yöntem, bir uçak filosunun kullanımdan kaldırılma senaryosuna uygulanmıştır ve burada belirli bir aşınmadan sonra değiştirilmesi gereken uçak parçası için optimum durdurma-bakım stratejisi belirlenmiştir.

Yang ve arkadaşları (Yang ve Yang, 2012) amortisman maliyetinin hedef fonksiyonuna dayalı olarak uçak bakım planı prosedürünün optimizasyon modelini önermiştir. Optimizasyon modelinin ayarını yapmak için GA kullanılmıştır. Modelin ve optimizasyon algoritmasının kullanışlılığı, bir havayolu şirketi örneğiyle belirlenmiştir. Ortaya çıkan çözümler ile çeşitli bakım planları uygulanarak kısıtlamalar optimize edilmiştir ve bakım maliyetleri en aza indirilmiştir.

Ahmed ve arkadaşları (Ahmed ve ark., 2017) ekipmandan gelen arıza sonrası gerilimlere ve akımlara dayanan yeni optimizasyon algoritmalarını kullanarak güç sistemindeki arıza konumu tahminini incelemişlerdir. Farklı optimizasyon algoritmaları (GA), Uyum Arama (HS) ve Öğretme-öğrenmeye dayalı optimizasyon (TLBO) algoritması) belirtilen hedef fonksiyondan uygun arıza konumunu elde etmek için modellenmiştir. GA doğru yolu bulmuştur ancak arıza yerini elde etmek için dört dakika süre geçmiştir. HS algoritması yaklaşık 45 sn ile daha kısa sürede aynı doğru yola ulaşmıştır. TLBO tekniği yaklaşık 7 sn gibi çok daha kısa bir sürede aynı doğru yola ulaşmıştır. Arızayı hızlı bir şekilde temizlemek için zaman çok önemlidir, bu nedenle TLBO algoritması açıklanan diğer iki yöntemden daha fazla önerilmiştir.

Chang ve arkadaşları (Chang ve ark., 2020) konumlarına bağlı olarak çeşitli ömür dağılımlarına sahip tahrik tekerleği için erken aşamada bir bakım stratejisi önermişlerdir. Tahrik tekerleklerinin güvenilirlik bakım verileri toplanmıştır. Her bakım koşulunda güvenilirliği en üst düzeye çıkararak ve maliyeti en aza indirerek bakım aralığı optimize edilmiştir. Bakım sayımı için çok kullanımlı bir fonksiyonun optimizasyon tekniği olan baskın olmayan sıralama genetik algoritması (NSGA-II) uygulanarak çalışılan optimum bakım aralıkları ayarlanmıştır.

3. MATERYAL VE METOTLAR

Tez çalışmasında kullanılan veriler, algoritmalar ve yöntemler hakkında detaylı bilgiler bu bölümde ele alınmıştır.

3.1. Materyal

Bu tez kapsamında üzerinde çalışılan veriler Türkiye'de bir havacılık şirketinin bakım biriminden toplanmıştır. Aynı tip uçakların aviyonik alt sistem malzemeleri incelenmiştir. Ekipmanın sistemden veya alt sistemden sökölme-takılma durumlarını içeren iki yıllık bakım ve arıza verileri elde edilmiştir. Veriler, arıza bildirimlerinin kayıtlarını, ekipmanın sökölme kayıtlarını, onarım siparişlerini ve durumlarını, servis edilebilir depolardan servis edilemeyenlere malzeme hareketlerini ve bunun tersini, ekipmanın bakım süresini ve bakım faaliyetleri ile ilgili diğer verileri içermektedir. Ayrıca teyit edilen arıza sayısını bulmak için ekipmanın zaman içindeki ölçüm noktaları ve uçuş saati verileri de elde edilmiştir. Bu veriler içerisinde NFF durumları tespit edildi ve gerçek arızalardan ayrılmıştır. Arıza bildirimlerine dayanarak, arızaların teyit edildiği durumları belirlemek için tüm sökme takma işlemleri takip edilmiştir (onarım siparişleri, servis verilebilir veya servis edilemeyen depolara malzeme hareketleri). Böylece iki farklı üreticinin seri nolu malzeme ekipmanlarının onaylanmış arıza sayıları hakkında veriler elde edilmiştir. Daha sonra ekipmanlarının MTBF değerleri hesaplanarak karşılaştırılmıştır. İki malzemenin NFF olaylarının ve NFF durumlarının oranı, NFF olaylarının ne sıklıkta ve ne zaman (yani orijinal sürümden sonra veya ilk onarımın ardından) ortaya çıktığı karşılaştırılmıştır.

Seçilen ekipmanların arızaları, MTBF'yi ve NFF'yi etkileyen ana faktörler gözlemlenerek tesis bakım alanındaki alan uzmanları, sistem mühendisleri, teknisyenler ve operatörlerle tartışılmıştır. Ekipmanın tek başına kaydedilmiş kendi ölçüm noktası yoksa bu ekipmanlar genellikle bir uçaktan çıkarılıp diğerine takılabildiği için, iki yıl içinde takıldığı her bir uçağın uçuş saatine bağlı olarak bu ekipmanların uçuş saati hesaplanmıştır. İki farklı üreticinin malzemeleri üç gruba ayrılmıştır: (1) uçuş süresi dikkate alınmadan tüm ekipmanlar, (2) minimum 50 saatlik uçuşa sahip ekipmanlar (3) minimum 100 saatlik uçuşa sahip ekipmanlar. Birinci grupta, tüm ekipmanların MTBF değerleri uçuş saatlerine bakılmaksızın analizlere dâhil edilmiştir. Malzemelerle ilgili veriler karşılaştırılarak analiz edilmiş ve incelenmiştir. Ayrıca, malzemelerin bakım periyotları hesaplanan MTBF değerleri ile karşılaştırılmıştır.

3.1.1. Ekipman MTBF hesabı veri kümeleri

Yapılan çalışmada belli model-tipte uçakların iki yıllık bakım, sökme takma ve arıza kayıtları kullanılmıştır. Uçak sistemleri arıza bildirim kayıtları kurumsal kaynak yönetimi (Enterprise Recourse Planning, ERP) platformunda, Bakım modülü (Plant Maintenance, PM) içinde tutulmaktadır. Bunun için ERP'nin programlama dili ile bir program yazılmıştır. Programlama dili ile veri tabanından doğrudan tablolardan veri çekilebilmektedir. Yazılan programda seçim ekranında belli model/tipte uçaklar seçtirilmektedir. Seçilen uçakları arızaya düşüren, en üst etkisi gayri faal olan bildirimler veri tabanından çekilmiştir. Bu bildirimlerin açıldığı, uçak konfigürasyonunda bağlı olduğu pozisyonlardan, sistem, alt sistem bulunmuştur. Her bildirime bağlı malzeme, seri no, sipariş, varsa referans bildirim, arıza başlangıç ve arıza bitiş tarih/saati okunmuştur. Bu veriler derlenerek uçak üzerinde sistem, alt sistem, alt alt sistem için açılan bildirim sayıları hesaplanmıştır. Verilen iki yıllık tarih aralığında uçağın ölçüm noktalarından uçuş saati ve sorti sayısı karakteristikleri hesaplanmıştır. Her uçak sistemi için toplam uçuş saati ve toplam sorti sayısı, arıza bildirim sayısına bölünerek Uçuş saati MTBF değeri hesaplandı.

Analiz için bir aviyonik sistem / alt sistem bileşeni ve bunun yerine farklı bir firma tarafından üretilen yedek parça seçilmiştir. Her iki firmadan son iki yıldır uçaklarda kullanılan 150 adet aviyonik ekipman belirlenmiştir. Ekipmanın iki yıl (2015-2017) bakım ve arıza verileri elde edilmiştir. E1 ve E2 malzemelerinin bazı ekipmanları için örnek arıza verileri Çizelge 3.1'de gösterilmektedir. Bu veriler MTBF hesaplaması için kullanılmıştır.

Çizelge 3.1 Ekipman Arıza Kayıtları

Ekipman	Arıza Tarihi	Bildirim Tipi	Etkisi	NFF
E_11	16.02.2015	Bakım	Arıza	X
E_12	30.03.2015	Arıza	Arıza	
E_21	18.04.2015	Arıza	Arıza	X
E_22	15.05.2015	Bakım	Arıza	X
E_23	24.06.2015	Arıza	Arıza	

3.1.2. Uçak arızası gün tahmin verileri

Uçakların genel olarak bakım periyotları süresi için hazırlanan diğer bir veri kümesi arızalandıkları gün aralıkları arka arkaya sıralanarak bir sonraki arızalanma günü çıkarılmıştır. Bunun için 28 adet aynı tipteki uçağın 2 yıllık faaliyet raporu çalıştırılarak uçuş sonrası gerçekleşen gerçek arızaların günleri sıralanmıştır. Giriş verisi olarak kaç gün sonra arızalandığı bilgisi, bu günlerin ardarda toplamı, 2 yıllık sürede aktif faaliyet yüzdesi, 2 yıllık sürede bakımda geçen süre yüzdesi ve 2 yıllık sürede arızada geçen süre yüzdesi alınmıştır. Çıkış verisi olarak bir sonraki arıza günü alınmıştır.

Çizelge 3.2 Uçak Arıza Günleri Verileri


Arıza günü	Toplam Arıza Günü	Faal olma yüzdesi %	Bakım yüzdesi %	Arıza yüzdesi %	Bir sonraki arıza günü
18	25	62.55	2.97	3.21	32
7	32	62.55	2.97	3.21	35
3	35	62.55	2.97	3.21	57
22	57	62.55	2.97	3.21	62

3.1.3. Arıza sayısı tahmin verileri

Arıza sayısı tahmininde kullanılmak üzere kurumsal kaynak planlama, Enterprise Recourse Planning (ERP) platformunda, veri toplamak ve veri kümesini makine algoritmaları yoluyla analiz için bir program geliştirilmiştir. Değişkenler girdi değişkenleri olarak gruplandırılırken, arıza sayısı çıktı değişkeni olarak kabul edilmiştir.

Geliştirilen programın akış diyagramı Şekil 3.1'de sunulmaktadır. İlk olarak seçilen malzemelerin iniş takımı sisteminde kullanılan seri numaralı ekipmanları seçilmiştir. Bakım ve arıza verilerinin nitelikleri, bakım personeli ve teknisyenleri ile işbirliği içinde belirlenmiştir. Arıza bulunmayan her NFF durumu, onaylanmış arıza verilerini bulmak için incelenmiştir. Farklı uçaklardaki her bir ekipman parçası için toplam uçuş saati, seçilen 2 yıllık aralıkta hesaplanmıştır. Ekipmanın arızasını etkileyen dokuz giriş değişkeni tespit edilmiştir. Arıza sayısı bir çıkış değişkeni olarak alınmıştır. Bu dokuz giriş değişkeni ve bir çıkış değişkeni, çalışmada kullanılan makine öğrenme algoritmalarının (MLP, DVR ve DR) modellenmesinde kullanılmıştır.

Çalışmada; özellik seçimi, veri temizleme ve tahmin işlemlerinde MATLAB 2014 (8.3) kullanılmıştır. Tüm deneyler 2,8 GHz CPU, 4 GB RAM, 500 GB HDD ve Windows 7 işletim sistemi olan bir bilgisayarda yürütülmüştür.



Şekil 3.1 Yazılan programın akış diyagramı

Yazılan programlar ile bakım modülünden iki yıllık 585 satır bakım verileri elde edilmiştir. Veri kümesi dokuz giriş değişkeninden ve bir çıkış değişkeninden (arıza sayısı) oluşur. Giriş değişkenleri / faktörleri, arıza meydana gelmeden ve arıza meydana gelmeden önce çalışma uzunluğunu etkileyebilecek operasyonel ve çevresel parametrelerdir. Girdi değişkenleri, uçuş saatleri, ekipman sökme sayısı ve planlanan / planlanmayan sökme hata sayısını içerir. Bu veriler analiz edilmiş ve modelleme için uygun bir formatta temsil edilmiştir ve değişkenler Çizelge 3.3'de gösterilen karşılık gelen alan sınıflandırması ile karakterize edilmiştir. Çıktı değişkeni, ekipman arızalarının sayısıdır. Veri kümesinin bir örneği Çizelge 3.4'de verilmektedir.

Çizelge 3.3 Bakım verisinden elde edilen dokuz giriş ve bir çıkış verisi

Parametre	Tanım
Uçuş Saati (FH)	Son 24 ayda ekipmanın toplam uçuş saati
RM	Son 24 ayda ekipmanın sökölme sayısı
PR	Son 24 ayda ekipmanın planlı sökölme sayısı
UR	Son 24 ayda ekipmanın plansız sökölme sayısı
OR	Son 24 ayda ekipmanın diğer sökölme sayısı
FR	Son 24 ayda ekipmanın arızalı çıkan söküm sayısı
FPR	Son 24 ayda ekipmanın planlı sökümünün arızalı çıkma sayısı
FUR	Son 24 ayda ekipmanın plansız sökümünün arızalı çıkma sayısı
SR	Son 24 ayda ekipmanın söküm sonucu faal çıkma sayısı
NF (Çıkış)	Son 24 ayda ekipmanın arıza sayısı

Çizelge 3.4 Örnek bakım verileri

FH	RM	PR	UR	OR	FR	FPR	FUR	SR	NF
272.8	8	0	8	0	7	0	7	1	7
332.5	6	1	6	1	3	0	3	3	3
329.1	8	0	8	0	6	0	5	2	6
285.2	8	0	7	0	7	1	6	1	7
433.7	12	0	11	0	9	0	10	2	9

3.2. Metotlar

3.2.1. Genetik algoritmalar

GA, doğal seçim ve evrim teorisi ilkelerine dayanan bir arama ve optimizasyon yöntemidir. GA, Michigan Üniversitesi'nden bilgisayar bilimi uzmanı olan J.H. Holland tarafından 1975 yılında geliştirilmiştir. Mekanik öğrenme konusunda çalışan Holland, Darwin'in evrim kuramından etkilenecek biyolojik olarak canlılardaki genetik aşamaları bilgisayar ortamında uygulamıştır. Holland'ın doktora öğrencisi David Golberg gaz boru hattının GA ile kontrolünü içeren çalışması bu alandaki çalışmaların temelini oluşturmuştur (Gülbüz, 2009). Bu çalışmadan sonra GA genel olarak kullanılmaya başlanmıştır.

GA'nın temel kavramlarını aşağıdaki gibi sıralayabiliriz.

Gen: Bireylerin karakterlerinin belirlenmesinde etkisi olan, anlamlı bilgi içeren en küçük genetik birimdir. Bu yapıların birleşmesiyle, çalışılan alanla ilgili bilgileri içeren kromozomlar oluşur. GA'da oluşturulan gen yapısı kullanıcının yazdığı programa göre belirlenir. Genin içeriği ikili tabandaki sayılar olabileceği gibi onluk ve onaltılık tabandaki sayı değerleri de olabilmektedir.

Kromozom: Genlerin birleşmesiyle meydana gelen uğraşılacak problemle ilgili bilgilerin tamamını içerir. Popülasyon içerisindeki bireylerdir. Problemin çözümü için oluşabilecek alternatif çözümleri barındırmaktadır. Genlerin bir araya gelmesiyle oluşan yapıya kromozom denir (Taşkın ve Emel, 2009). Kromozom, GA'nın çözmeye çalıştığı problemin alternatif çözümlerini temsil eden sayısal bir değeri veya değerleri ifade etmektedir. Kromozomlar ele alınan problemin olası çözüm bilgilerini taşımaktadır (Elmas, 2016). Kromozom üzerindeki parametrelerin, GA'nın en iyi çözümü araması için gerekli olan bilgilerin tamamını kapsayacak şekilde ayarlanması gerekir. Bu şekilde genetik işlemler ile daha iyi sonuçlar elde edilebilir.


Allel: Doğada bir genin alabileceği değerlere allel denir. GA'da allel nitelik değeridir. Örneğin saç renginin bir gende belirtiminde bu genin allelleri kahverengi, siyah ve sarı olarak ifade edilebilir (Cura, 2008).

Popülasyon: Kromozomların bir araya gelerek oluşturdukları yapıya denir. Popülasyondaki kromozomlar da gerçek hayattaki gibi bazen yaşamını yitirir, yerlerine yeni kromozomlar gelir ve bu şekilde popülasyon büyüklüğü korunur. Popülasyon, büyüklüğü kullanıcı tarafından belirlenen bir parametredir ve GA'nın performansını, başarısını etkilemektedir.

Standart bir GA'nın işlem adımları aşağıdaki gibi açıklanabilir:

1. İlk olarak rastgele oluşturulan bir çözüm kümesi ile başlangıç popülasyonu oluşturulur. Başlangıç popülasyonu oluştururken belirli bir sayıya bağlı kalınmamaktadır. Bu değer belirlenmesinde yapılan çalışmanın karmaşıklığı ve yapılacak olan aramanın derinliği önem arz etmektedir. Popülasyon sayısına karar verildikten sonra kromozomların kodlanması işlemine geçilir.
2. Popülasyondaki her kromozom uygunluk fonksiyonunda yerine yazılarak uygunluk değeri bulunur. Uygunluk fonksiyonu GA'nın çok önemli bir aşamasını oluşturur. Yapılan çalışmaların verimli ve başarılı bir sonuç vermesi uygunluk fonksiyonuna bağlıdır. Çözümü aranan her problem için bir uygunluk fonksiyonu mevcuttur. Belirli bir kromozom için uygunluk fonksiyonu, o kromozomun temsil ettiği çözümün kullanımıyla orantılı olan bir uygunluk değeri verir.
3. Seçilmiş olan bazı kromozomlar eşlenerek yeniden kopyalandıktan sonra değiştirme işlem basamaklarına tabi tutulur. Bu işlem sonucunda yeni kromozom oluşmaktadır. Kromozomların uygunluk değeri temel alınarak eşleme yapılır. Turnuva seçimi ve rulet tekerleği seçimi gibi seçme teknikleri kullanılarak eşleme yapılabilir. Yeniden kopyalama denilen işlem basamağı bir genin birinden diğer bir gene geçmesi durumu olduğu için bu işleme çaprazlama denir. Çaprazlama toplumlarda çeşitliliği artırır. GA'da en önemli operatör çaprazlamadır. Bu basamak, eski nesil kromozomların karıştırıldığı ve yeni bir kromozom nesli oluşturmak için birleştirildiği bir aşamadır. GA'da çaprazlama, popülasyonun genetik çeşitliliği üzerinde çok olumlu etkisi oluşturmaya bile kromozomların iyi genlerinin bulunmasına ortam oluşturur.

4. Çaprazlama işleminin sonucunda oluşan yeni kromozomlara yer açmak için uygunluk değeri düşük olan kromozomlar popülasyondan çıkartılır. Mutasyon popülasyona çeşitlilik katmak için devreye girer. Çaprazlama sonucu oluşamayacak yeni farklılıkları oluşturmak için mutasyon yapılır. Mutasyon yoluyla kromozomdaki genler değiştirilir.
 5. Yeni popülasyonun başarısını belirlemek için bütün kromozomların uygunluk değerleri yeniden hesaplanır.
 6. Bu işlemler tekrarlanarak daha iyi bir popülasyonun ortaya çıkması hedeflenir.
 7. Son işlem olarak başlangıçta belirtilen durdurma şartlarına bağlı kalınarak en iyi kromozomların var olduğu çözüm bulunur. Bu sürecin döngü içerisinde sonsuza kadar devam etmemesi için sonlandırma koşullarının belirlenmesi gerekir.
- GA'nın çalışma şekli Şekil 3.2'deki gibidir:



Şekil 3.2 GA akış diyagramı

Genetik algoritmalar en iyi kromozomun uygunluk değerini elde edene kadar tekrarlanır. Bu durum algoritmanın bir çözüme yaklaştığı anlamına gelir. Genellikle her bir çalıştırma işleminin sonunda gerçek probleme uygun bir çözüm olarak en az bir kromozom bulunmaktadır. Algoritmanın yazılışına bağlı olarak, bulunan kromozom şimdiye kadar ki elde edilen popülasyonun en uygunu olabilmektedir. GA'nın çalışması sonucunda en iyi kromozom elde edilir.

Genetik algoritmalar; optimizasyon, makine öğrenmesi, ekonomik ve sosyal sistem modelleri, finans, pazarlama, üretim, çizelgeleme problemleri, atama problem, araç rotalama problem gibi alanlarda sıklıkla uygulanmaktadır.

3.2.2. ReliefF özellik seçimi algoritması

Özellik seçimi, orijinal veri kümesini temsil edebilecek en iyi altkümenin seçimi olarak tanımlanmaktadır. Özellik seçimi (diğer adıyla nitelik seçimi), kullanılan algoritmaya göre özellikleri değerlendirerek veri kümesindeki n adet nitelik arasından en iyi k adet niteliği seçme işlemidir (Durgabai ve Bhushan, 2014). Özellik seçimi, ilgilenilen problem için en faydalı ve en önemli özellikleri seçerek veri kümesindeki nitelik sayısının azaltılmasını amaçlamaktadır (Rosario ve Thangadurai, 2015). Özellik sayısının azaltılması analiz sürecinde araştırmacıya birçok avantaj sağlamaktadır. Özellik seçimi ile nitelik kümesinin boyutu düşürülür ve algoritma çalışma hızı artırılır. İlgisi olmayan gürültülü veri ortadan kaldırılır. Veri kalitesini artır ve veri kümesi daha basit bir şekilde tanımlanabilir, anlaşılabilir hale getirilir. Veri kümesini oluşturma sırasında gereken veri toplama işleminde kaynak tasarrufu sağlanır. Veri depolamak için gerekli olan hafıza miktarını azaltır ve elde edilen modelin başarısını artırır.

Kira ve Rendell (Kira ve ark., 1992) (Kira ve Rendell, 1992) tarafından önerilen Relief yöntemi, özelliklerin değerini aralarındaki bağımlılıkları ortaya çıkartmaya çalışarak bulmaktadır. Yöntem, ikili sınıflandırma problemlerinde özellik seçimi için kullanılmaktadır. Yöntemin mantığı komşuluk algoritmalarına benzemekte olup, özelliğin bulunduğu örneğin ait olduğu ve olmadığı sınıflarda yer alan en yakın örnekleri ağırlıklandırarak çalışmaktadır. Relief algoritmasını oluşturan üç aşama aşağıdaki gibidir.

1. Aynı sınıfa ait en yakın örnekteki ilgili nitelik değeri ve farklı sınıfa ait en yakın örnekteki ilgili nitelik değerinin tespit edilmesi
2. İlgili niteliğin ağırlığının hesaplanması,
3. Niteliklerin ağırlıklarına göre sıralanması ve belirli bir eşik değerin üstündeki k adet niteliğin seçilmesi

ReliefF nitelik seçim algoritması, Relief istatistiksel modelinin geliştirilmiş halidir (Kononenko, 1994). İki sınıflı sınıflandırma problemlerindeki gereksiz ve eksik nitelikleri ayırt etmekte başarılıdır. Bu yöntem, ilk olarak veri kümesinden bir örnek seçer. İkinci olarak ilgili örneğin, kendi sınıflarındaki diğer örneklerle yakınlığı ile farklı sınıflarla olan uzaklığına göre bir model oluşturur ve bu işlemlerin ardından nitelik seçme işlemini gerçekleştirir. ReliefF nitelik seçim algoritması, niteliklerin değerlerini ve

aralarında ilişki olup olmadığını belirlemeye çalışır. Bu sonucu elde etmek için, niteliklerin ait olduğu sınıflardaki birbirine yakın örnekleri karşılaştırır. Başlangıçta iki sınıflı sınıflandırma problemleri için geliştirilmiştir ve sonrasında çoklu sınıf problemlerinde de kullanılmıştır (Hsu ve Hsieh, 2010).

3.2.3. K-Ortalamlar kümeleme yöntemi

Kümeleme analizi, verilerin benzerliklerine göre sınıflandırılması ve homojen alt gruplara ayrılması için kullanılmaktadır. K-Ortalamlar yöntemi, en çok bilinen, kullanılan kümeleme yöntemlerinden biridir ve hiyerarşik olmayan bir yapıya sahiptir. K-ortalamlar algoritması ilk olarak MacQueen (1967) tarafından önerilmiştir (MacQueen, 1967). K-ortalamlar yöntemi, büyük miktarlarda ve karmaşık verilerden basit, anlamlı kümeler oluşturmak üzere kullanılan bir kümeleme algoritmasıdır. K-ortalamlar yöntemi, bir veri kümesini k gruba ayırmak için kullanılan bir kümeleme yöntemidir (Yılmaz ve ark., 2014). Yöntem k başlangıç küme merkezlerini seçerek ve ardından bunları aşağıdaki gibi tekrarlayarak günceller:

1. Her bir veri örneği, en yakın küme merkezine atanır.
2. Her bir küme merkezi, kendisini oluşturan örnek verilerin ortalaması olarak güncellenir.

K-ortalamlar kümeleme algoritmasının aşamaları aşağıdaki gibi tanımlanmıştır:

- Başlangıç aşaması: Örnek verileri rasgele k kümeye ayırır.
- Tekrarlama aşaması: Her bir kümenin merkezini, verilerin ortalaması olarak hesaplar. Her verinin her kümeye uzaklığı (Öklid uzaklığı) hesaplar. Karesel hata fonksiyonu hesaplanır.
- İyileştirme aşaması: Her örnek veriyi en yakın merkeze göre kümeye atar.
- Durma aşaması: Bu işlem bütün veri örneklerinin kümeleri hareket ettirmedikçe zamana kadar devam eder.

K-Ortalamlar algoritması en ilkel kümeleme yöntemlerinden olduğu için anlaşılması ve programlama dillerinde uygulanması kolaydır. Öklid uzaklık formülüne göre çalışır (Fahad ve Alam, 2016). Karmaşıklık $Q(tkn)$ 'dir. Burada k: küme sayısı, t: tekrar sayısı, n: veri sayısıdır. Başlangıçta k değeri bilinmelidir ve K değerini dışardan aldığı için her zaman aynı sonucu vermez. Sadece ortalamanın tanımlı olduğu verilerde çalışır, kategorilere ayrılmış verilerde kullanılamaz. Bu yüzden kümelerde anlamsız yığılmalar olabilir. Gürültü ve bozuk veriye karşı güçlü değildir.

3.2.4. Yapay sinir ağıları

Yapay sinir ağıları insan beynindeki sinirlerin çalışmasını taklit ederek geliştirilmiştir. YSA ile bilgiler biyolojik sinir sisteminin çalışma sistemi taklit edilerek işlenmektedir. Biyolojik sinir hücreleri nöronlardan oluşmaktadır. Yapay sinir ağıları da nöronların birbirine bağlanmasıyla oluşmaktadır. YSA'lar hafızaya alma, öğrenme, öğrenme sonrası genelleştirme, veriler arasındaki bağlantıyı ortaya çıkarma yeteneğine sahiptirler. Bu özelliklerle YSA, herhangi bir problemi ya da olayı, ağı sunulan verilerden öğrenir ve böylelikle daha önce rastlamadığı olaylar için yeni sonuçlar elde eder. Bilgisayar teknolojisinin gelişmesi sayesinde YSA'lar nano saniyeler mertebesinde işlem yapabilmektedir. YSA'lar başarılı sonuçlar verdiği için zaman geçtikçe uygulama alanı artmaktadır. YSA'lar, nöronların eş zamanlı olarak çalışması neticesinde karmaşık fonksiyonları çözebilirler. Zaman içerisinde nöronlardan her hangi birisi işlevini kaybetse bile model çalışmasını sürdürebilir (Öztemel, 2003).

YSA'lar yapay zekânın alt dallarından biri olarak makine öğrenmesi gerçekleştirebilirler. Gösterilen olayları öğrenerek benzer başka olaylar karşısında mantıklı sonuçlar verebilirler. YSA'nın bilgiyi işleme teknikleri geleneksel programlama tekniklerinden farklı olması nedeniyle geleneksel programlamanın birçok olumsuz durumunu ortadan kaldırılabılır. YSA'larda bilgiler ağına tamamına dağıtılmıştır ve değerler ağı bağlantılarında ağırlık olarak tutulur. Yapay sinir hücrelerinin ağırlık ve bağlantı katsayıları, ağına bilgisini gösterir. Tek bir bağlantı kendi başına bir anlam ifade etmemektedir. YSA'lar gösterilen örnek olayları kullanarak öğrenme gerçekleştirirler. YSA'nın öğrenebilmesi için önce örnek olayların tespit edilmesi, bu örneklerin ağına gösterilmesi ve sonrasında hedef çıkış değerlerine göre ağına eğitilmesi işlemi yapılır. Yapay sinir ağının başarısı ağına eğitimi için seçilen örnekler ile doğru orantılıdır. YSA'lar daha önce görülmemiş girişler için bilgi üretebilirler. YSA'lar eğitimleri sırasında kendilerine verilen örnek olaylardan genellemeler çıkarabilirler ve bu genellemeler ile yeni olaylar hakkında bilgi üretebilirler.


YSA'lar eksik bilgi ile çalışabilirler. Geleneksel sistemlerin aksine YSA'lar eğitildikten sonra veriler eksik bilgi içerse bile çıktı üretebilirler. Bu durum performans kaybı oluşturmaz. Hata toleransına sahiptirler. YSA'ların eksik bilgilerle çalışabilmeleri ve bazı hücreleri bozulsa bile çalışabilmeleri, onları hatalara karşı toleranslı yapar. Örüntü tamamlama yapabilirler. YSA'ya eksik bilgiler içeren örüntüler verildiğinde, eksik bilgilerin tamamlanması sırasında başarılıdır. Kendi kendine öğrenebilme ve organize olma becerileri vardır. YSA'lar kendi kendilerini eğitebilirler. Daha önce hiç görülmemiş

olaylar hakkında bilgi üretebilirler. YSA'lar eğitimleri sırasında kendilerine verilen örnek olaylardan genellemeler çıkarırlar ve bu genellemeler ile yeni örnekler için bilgi üretebilirler.

YSA'ların pek çok avantajlarının yanında bazı dezavantajları da vardır. Bunlardan bazılarını şöyle sıralayabiliriz. YSA'ların en önemli sorunu donanım bağımlı olmalarıdır. YSA'ların var oluş nedenlerinden birisi olan paralel işlem yapabilme becerisi, paralel çalışan işlemciler ile performans gösterir. YSA'larda probleme uygun ağ yapısının belirlenmesi için geliştirilmiş bir kural yoktur. Uygun ağ yapısı deneyim ve deneme yanılma yolu ile bulunmaktadır. YSA'larda öğrenme katsayısı, hücre sayısı, gizli katman sayısı gibi parametrelerin belirlenmesinde belirli bir kural yoktur. Bu değerlerin belirlenirken her problem için farklı bir yöntem söz konusu olabilmektedir. YSA'lar nümerik bilgiler ile çalışabilmektedirler ve olaylar ağlara tanıtılmadan önce nümerik değerlere çevrilmek zorundadırlar. Ağın eğitiminin ne zaman bitirilmesi gerektiğine dair bir kural yoktur. Ağın olaylar üzerindeki hatasının belli bir değerin altına inmesi eğitimin tamamlandığını gösterir. Ağın davranışları açıklanamamaktadır. YSA bir probleme çözüm ürettiği zaman, bunun neden ve nasıl olduğuna dair bir bilgi vermez. Bu durum YSA'ya olan güveni azaltan bir sebeptir.

YSA'lar Yapay sinir hücreleri de biyolojik sinir hücrelerine benzer yapıdadır. Yapay nöronlar da aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Aynı biyolojik nöronlarda olduğu gibi yapay nöronların da giriş sinyallerini aldıkları, bu sinyalleri toplayıp işledikleri ve çıktılarını ilettikleri bölümleri bulunmaktadır. Bir giriş katmanı, bir çıkış katmanı ve bazı gizli katmanlar içeren çok katmanlı (MLP, multilayer perceptron) ileri beslemeli YSA'lar, çok kullanışlı yapılardan biridir. MLP'yi eğitmek için uygun bir maliyet fonksiyonunun en aza indirilmesine dayanan geri beslemeli algoritma kullanılır. Genel olarak bir MLP Şekil 3.5'te gösterilmiştir. Genel birçok katmanlı MLP, gizli girdi ve çıktı katmanlarını içerir. Katmanlar ileri beslemeli bir şekilde bağlanır. Aynı katmandaki nöronlar arasında bağlantı yapılmaz.

Bir yapay sinir hücresi Şekil 3.3'te görüldüğü gibi beş bölümden oluşmaktadır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır.




Şekil 3.3 Yapay sinir hücresi

Girişler : Girişler (X_1), bir YSA modelinde işlem yapılacak olaya ait ağa verilen verileri içerir. Girişler girilen bu verilerin üzerinde herhangi bir matematiksel işlem yapmadan bir sonraki katmana aktarır.

Ağırlıklar : Ağırlıklar (W_{nj}) , ağa verilen girişlerin nöronlar üzerindeki etkisini belirleyen katsayılarıdır.

Transfer Fonksiyonu : Transfer fonksiyonu (birleştirme fonksiyonu) ile bir nörona iletilen net girişler hesaplanır. Transfer fonksiyonunda bir nörondaki her bir giriş ile bu girişe ait ağırlıklar çarpılır ve bu çarpımların toplanması ile net giriş elde edilir.

Aktivasyon Fonksiyonu : Bu fonksiyon hücreye gelen net girişi işleyerek hücrenin bu girişe karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonu genellikle doğrusal olmayan bir fonksiyon olarak seçilir. Yapay sinir ağlarının “doğrusal olmama” özelliği aktivasyon fonksiyonlarının doğrusal olmamasından gelmektedir. Aktivasyon fonksiyonu seçilirken dikkat edilmesi gereken bir konu fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Geri beslemeli ağlarda aktivasyon fonksiyonunun türevi de kullanıldığı için hesaplamaların hızlı olması için türevi kolay hesaplanabilir bir fonksiyon seçilir (Mia ve ark., 2015).




Şekil 3.4 Aktivasyon Fonksiyonları

YSA hücresinde dış ortamdan ya da diğer hücrelerden alınan girişler, ağırlıklar, transfer fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla sinir ağı hücrelerine bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Transfer fonksiyonu ise net girişi hesaplar. Net giriş, girişler ve bunların ilgili ağırlıkları çarpımının toplamıdır. Aktivasyon fonksiyonu net çıkışı hesaplar. Bu işlem aynı zamanda nöron çıkışını vermektedir. Genelde aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur. Aktivasyon fonksiyonları Şekil 3.4'te verilmiştir (Öztemel, 2003).

YSA'da, nöronların arasındaki bağlantılar farklı biçimlerde oluşturulabilir. Bu şekilde oluşturulan nöronlar arasındaki bağlantılar ve ağ yapıları, mimari yapıya göre farklı isimlendirilir. Bu nedenle, YSA akış yönleri ya da beslenme şekilleri göz önünde bulundurularak İleri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere ikiye ayrılır (Lan ve ark., 2016).

1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları; nöronların katmanlar halinde bir araya gelerek genellikle bir girdi katmanı, bir ve/veya birden fazla gizli katmanlar ve bir çıktı katmanı olmak üzere üç katmandan oluşturulur. İleri beslemeli YSA'nın girdi katmanındaki nöronlardan girişi yapılan veriler, çıktı katmanına doğru bağlantılar ile tek yönlü olarak aktarılır (Öztemel, 2003). Örnek bir ileri beslemeli sinir ağının yapısı Şekil 3.5'de verilmiştir.



Şekil 3.5 İleri Beslemeli Yapay Sinir Ağı


2. Geri Beslemeli Yapay Sinir Ağı

Geri beslemeli yapay sinir ağlarında bir hücrenin çıktısı sadece kendinden sonra gelen hücrenin katmanına giriş olarak verilmez. Kendinden önceki veya kendi katmanındaki herhangi bir hücreye de giriş olarak bağlanabilir. Bu şekildeki yapısı ile geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir davranış gösterirler. Geri besleme özelliğini sağlayan bağlantıların şekline göre aynı yapay sinir ağıyla farklı özellikte ve yapıda geri beslemeli yapay sinir ağları elde edilebilir. Dinamik hafızasından dolayı geri beslemeli yapay sinir ağları özellikle tahmin işlemlerinde başarıyla uygulanmaktadır (Oladokun and, 2010).

3.2.5. Destek vektör makinesi ve destek vektör regresyon

Destek vektörleri yöntemi V.N. Vapnik tarafından 1960'lı yıllarda geliştirilen bir makine öğrenmesi yaklaşımı olup iki sınıflı bir sınıflandırma yöntemidir (Cortes ve Vapnik, 1995). Destek vektörleri yöntemi en basit model ile doğrusal olarak ayrılabilen veriler için uygulanan bir modeldir. Sınıflandırma için giriş verilerini orijinal giriş

uzayına göre ayrıştırılabilir şekle getiren lineer olmayan kernel (çekirdek) fonksiyonları kullanarak yüksek boyutlu bir uzaya dönüştürür (Yılmaz ve ark., 2014). Gerçek dünyada karşılaştığımız problemlerin birçoğu doğrusal olarak ayrılabilen verilere sahip değildir. Bu durumda problem klasik yöntemlerle çözülmeyebilir. Böyle durumlarda ise doğrusal olmayan sınıflandırma yöntemleri kullanılmaktadır. İstatistiksel öğrenme ve makine öğrenmesindeki sağlam matematiksel temeli ile destek vektör makineleri; el yazısı tanıma, ses tanıma, yüz tanıma, tahmin işlemleri, veri analizi madenciliği ve görüntü işleme gibi birçok alanda yüksek performans ile kullanılmaktadır.



Şekil 3.6 İki sınıflı veriyi ayıran alt düzlem ve sınırları

Destek Vektör Makinesi (DVM), gürültülü ve yüksek boyutlu verileri sınıflandırabilme konusunda çok başarılıdır. DVM, sınıflandırma ve regresyon analizi için geliştirilen istatistiksel bir sınıflandırma yöntemidir. DVM sınıflandırıcısı temel olarak iki sınıfa ait verileri birbirinden orantılı bir şekilde ayırmaktadır. DVM’de eğitim verileri kullanılarak sınıflandırma yapılır ve en elverişli bir hiper düzlem çizgisi bulunur. Test verileri sınır çizgisinin hangi tarafında kalıyorsa o alana göre sınıflandırma gerçekleştirilir. En elverişli hiper-düzlem çizgisinin bulunabilmesi için sınırları belirleyen ve hiper düzleme paralel iki düzlem çizgisi belirlenir. Bu paralel düzlemleri oluşturan çizgiler “destek vektörleri” olarak isimlendirilir. DVM işlemi Şekil 3.6’de gösterilmiştir.

DVM’lerin başarısının iki önemli sebebi vardır. Bunlardan ilki bazı örnek verilerin diğerlerinden çok daha önemli olmasıdır. Örnek uzayı lineer olarak ayıracak olan hiper düzlemin belirlenmesinde marjın üzerinde ve marjini geçmiş olan değerlerin etkisi vardır. Diğer örneklerin değişmesinin hiper düzleme etkisi olmaz. DVM’lerin başarısını

sağlayan diğer ikinci özellik ise çekirdek fonksiyonu denilen kavramdır. Bu kavram sayesinde DVM'ler normalde lineer olarak ayıramayacakları sınıfları küçük bir matematiksel işlem sayesinde ayırabilirler. Bu işlem çok fazla bir matematiksel yük gerektirmez. DVM'nin matematiksel ve mantıksal modelleri incelendiği zaman basitçe anlaşılabilir.

DVM ile kurulan model, regresyon için DVR olarak adlandırılır. DVR yapay sinir ağlarının geleneksel denetimli öğrenme metotları ile karşılaştırıldığında, sadece deneysel ölçüm hatasını değil, aynı zamanda genelleme hatasının üst sınırını da azaltmayı amaçlayan yapısal riski minimuma indirme ilkesini kullanır. İstatistiksel öğrenme teorisi bağlamında geliştirilen DVR regresyon fonksiyonlarını oluşturmak amacıyla kullanılan yeni bir parametrik olmayan metottur. DVR'nin kullanım amacı genelleme performansını optimize etmektir. DVR test veri kümesinde çok iyi bir genelleme performansına ve tahmin etme yeteneğine sahiptir. DVR yüksek boyutlu özellik alanında küçük riskli bir regresyon hiper düzlemini bulmaya çalışan, doğrusal olmayan bir çekirdek temelli regresyon yöntemidir (Benkedjouh ve ark., 2013).

DVR uygulamasında iki temel özellik vardır. Bunlar ikinci dereceden programlama ve çekirdek fonksiyonlardır. DVR'nin parametreleri, doğrusal eşitlik ve eşitsizlik sınırlamaları ile ikinci dereceden programlama problemini çözerek sağlanabilir. Çekirdek fonksiyonlarının esnekliği sayesinde tekniğin geniş bir çözüm aralığını araması sağlanır. Çekirdek fonksiyonunun klasik örnekleri doğrusal, polinom, Gauss vb. şeklindedir (das Chagas Moura ve ark., 2011). DVR metodu için iyi bir fonksiyon seçmek de bir problemdir. Genellikle Gauss çekirdek fonksiyonları daha iyi sonuçlar vermektedir. Doğrusal DVR'lerin yorumlanması kolaydı fakat düşük tahmine dayalı sonuçlar verebilir. Doğrusal olmayan DVR'lerin yorumlanması ise daha zordur fakat daha doğru tahminler, sonuçlar verebilir. DVR'nin doğrusal çekirdek modelinin yorumlanması kolay ancak model esnekliği düşüktür.

3.2.6. Doğrusal regresyon


Regresyon kavramı ilk olarak İngiliz istatistikçisi Francis Galton tarafından 19. yüzyılda, bir biyolojik inceleme yapılırken ortaya çıkmıştır. Francis Galton bu araştırmaları sırasında regresyon kavramını ve metodunu geliştirmiştir (Schuld ve ark., 2016). Regresyon analizi; bağımlı ve bağımsız değişkenler arasındaki sayısal ilişkiyi incelemek amacıyla kullanılan bir metottur. Bağımlı değişken (açıklanan değişken, sonuç değişkeni olarak da isimlendirilir) bağımsız değişkenden etkilendiği kabul edilen bir değişkendir. Bağımsız değişken (açıklayıcı değişken, etken değişken olarak da

isimlendirilir) ise bağımlı değişkeni etkilediği varsayılan değişkendir. Regresyon analizinde bir tane bağımlı ve bir tane de bağımsız değişken var ise basit regresyon analizi, bir tane bağımlı değişken, birden fazla bağımsız değişken var ise çoklu regresyon analizi, birden fazla bağımlı değişken var ise çok değişkenli regresyon analizi metotları uygulanır. Değişkenler arasındaki ilişki doğrusal ise doğrusal regresyon analizi, doğrusal değil ise eğrisel regresyon analizi olarak isimlendirilir.

Regresyon analizi, aralarında neden-sonuç ilişkisi bulunan iki ya da daha çok değişken arasındaki ilişkiyi, o konu ile ilgili tahminler yapabilmek için regresyon modeli olarak adlandırılan matematiksel bir model ile karakterize eden bir analiz tekniğidir. Bir istatistik analiz tekniği olan DR tez kapsamında YSA modeliyle ve destek vektör regresyon analizi ile kıyaslama yapmak amacıyla kullanılmıştır. DR metodundan bir değişkenin değerini başka bir değişkenin değerine göre tahmin etmek için yararlanılır. Bu analiz yöntemi bağımlı değişkenin değerini en iyi şekilde tahmin eden bir ya da daha fazla bağımsız değişkeni değerlendirerek lineer denklemin katsayılarını tahmin eder. DR tahmin edilen ve gerçek çıkış değerleri arasındaki farkları en aza indiren düz bir çizgiye veya alana yerleşir.

3.2.7. Dağıtık arama algoritması

Kapsamları ve kuralları ilk olarak 1977 yılında Glover tarafından önerilen DA'nın (scatter search) temelleri, 1960'lı yıllarda karar kuralları ve kısıtlamalar için tavsiye edilen stratejilere dayanır (Glover ve ark., 2000). GA'lar gibi diğer evrimsel metotlardan farklı olarak rasgele seçimler kullanmak yerine yeni çözümler üretmek için sistematik tasarımların ve metotların fazlaca yarar sağladığı çalışmalarda bulunmuştur. DA birçok problemin çözümünde kullanılarak başarılı sonuçlar veren meta sezgisel bir algoritmadır (Haklı ve Ortacay, 2019). DA ilk önce yeni çözümler elde edebilmek için bir referans çözüm kümesi oluşturur. Daha sonra DA daha iyi çözümlere ulaşmak için nitelikli örnekleri ve çeşitlilikleri birleştirerek referans kümedeki çözümleri mantıklıca birbirleriyle bütünleştirir. Her iterasyonda DA, iyileştirmeler yapar ve referans kümeyi güncelleştirir. Bu işlem durdurma kriteri sağlanana kadar tekrarlanır. Esnek bir yapıya sahip olan DA algoritması temel olarak 5 bileşenden oluşmaktadır (Martí ve ark., 2006). Şekil 3.7'de metodun akış diyagramı verilmiştir. Esnek bir yapıya sahip olan DA algoritması beş aşamada açıklanabilir:



Şekil 3.7 Dağıtık arama algoritması akış diyagramı

1. Farklılaştırma Üretim Yöntemi: Bu metot bir dizi farklı çözümler üretmek amacıyla arama uzayı içerisinde etkili bir popülasyon

oluşturmak için kullanılmaktadır. Aramayı başlatmanı sebebinin oluşturan bir dizi farklı çözümler üretmek için kullanılır. Amaç, çeşitlilik ve kaliteyi dengeleyerek kullanılacak yöntem ile arama uzayı içinde değerli bir popülasyon oluşturmaktır. Farklılaştırma üretim yöntemi tamamen rassal olmadığında DA algoritmasının daha başarılı olduğu görülmüştür.

2. İyileştirme Yöntemi: İyileştirme yöntemi yeni çözümler oluşturulduktan sonra kullanılır. Yeni çözümler birleştirme metodu ile oluşturulan ilk deneme çözümleridir. Bu metot genellikle bir yerel arama metodu ile geliştirmeyi amaçlar. Bu kapsamda önemli konu, çözümleri iyileştirmek ve çözümleri geliştirmek için harcanan zamanı kontrol altında tutarak uygun, dengeli bir seçim yapabilmektir.

3. Referans Kümesi Güncelleme Yöntemi: Referans kümesi yeni çözümler oluşturma çok önemli bir bölümdür. Referans kümesi, çözüm birleştirme metodunu uygulayarak yeni çözümler oluşturmak için kullanılan yüksek kaliteli çözümlerin ve çeşitli çözümlerin toplamıdır. Önce kaliteli çözümler referans kümeye eklenir. Referans kümesi güncelleme metodu, her bir iterasyon için referans kümenin nasıl güncelleneceği ve devam ettirileceği ile ilgilenmektedir. Bu metodun ilk amacı, farklılaştırma yöntemiyle üretilen popülasyonda bulunan çözümleri analiz ederek başlangıç referans kümesini hazırlamaktır. Başlangıç referans kümesi oluşturulduktan sonra referans kümesini güncelleme metodu referans kümenin sürdürülmesi için çalışır. Farklı çözümler tespit edilirken, çözümlerin örnek alınma şekillerine bağlı olarak bir uzaklık metriği kullanılmaktadır. İterasyonlar süresince, referans kümenin güncellenmesi genel olarak çözümün değerli olmasına göre yapılmaktadır.


4. Altküme Oluşturma Yöntemi: Bu metot ile çözüm kombinasyonu yönteminin girişi olan referans kümesinin alt kümeleri üretilmektedir. Metodun genel uygulamasında, referans kümesinde bulunan bireylerden oluşabilecek tüm çözüm örnek çiftleri kullanılmaktadır. DA metodunda, daha büyük sayıda alt kümelerin kullanılması da mümkündür. Üçlü, dörtlü veya daha fazla sayıda çözümler bir alt küme haline getirilerek çözüm birleşimi metoduna uygulanabilir.

5. Çözüm Kombinasyonu Yöntemi: Çözüm kombinasyon yöntemi, altkümelere ayrılan referans yeni çözümler oluşturmak için kullanılır. Çözüm kombinasyonu yönteminin özel durumuna bağlı olarak, her altküme için bir veya

daha fazla yeni çözüm üretilebilir. Çözüm kombinasyon yöntemi ile elde edilen yeni çözümler uygunluk fonksiyonuna gönderilip analiz edilir. Bu duruma göre referans kümesinin güncelleme işlemi yapılır. Referans kümesinde oluşacak herhangi bir gecikmenin önüne geçmek için DA algoritması, referans kümesinin belli bir bölümünde değişikliğe gider ve bu şekilde arama uzayında faydalı bir arama yapabilmek için yeni çözümlerin çeşitliliği gerçekleştirilmiş olur.

3.2.8. Diferansiyel evrim algoritması

DE algoritması, optimizasyon problemlerinin çözümü için 1995 yılında Storn ve Price tarafından GA'nın temel işlemlerine dayanarak sunulan sezgisel ve popülasyon tabanlı bir algoritmadır (Storn ve Price, 1997). DE algoritması, özellikle sürekli verilerin kullanıldığı problemlerde etkili sonuçlar verebilen, çalışma ve operatörleri itibarıyla genetik almıtmaya benzeyen popülasyon temelli sezgisel optimizasyon tekniklerinden biridir. GA'daki seçim, çaprazlama ve mutasyon işlemleri DE'da da uygulanmaktadır. GA'dan farklı olarak her bir işlem tüm popülasyona sırayla uygulanmamaktadır. Kromozomlar tek tek ele alınmakta, rasgele seçilen diğer üç kromozomda kullanılarak yeni bir örnek ortaya çıkarılmaktadır. Bu işlemler sırasında mutasyon ve çaprazlama operatörleri kullanılmaktadır. Mevcut kromozomla elde edilen yeni kromozomun yararlılıkları karşılaştırılarak yararlı olan, daha iyi olan, yeni birey olarak bir sonraki popülasyona aktarılır. Bu şekilde seçim operatörü de kullanılmış olur. DE'ye ait işlemler Şekil 3.8'daki akış diyagramında verilmiştir. Ortaya çıkan çözümlerin kalitesi, amaç fonksiyonuna verilen değerle (uygunluk değeri) ölçülmektedir. DE diğer sezgisel algoritmalarla karşılaştırıldığında kolayca kodlanabilme konusunda daha başarılıdır. Diğer algoritmalar ile binlerce satır kodlama yapılırken DE için yaklaşık yirmi satırlık kod yeterli olur (Tuo, 2018).



Şekil 3.8 DE algoritması akış diyagramı

DE'nin temel prosedüründe dört farklı aşama bulunmaktadır:

- Başlangıç Populasyonu:** Her bir kromozom bir aday çözümü temsil etmekte ve belirlenen aralık değerleri içinde rasgele olarak bulunmaktadır. Probleme ait değişken sayısı her bir kromozoma ait gen sayısını

belirlemektedir. Kromozom sayısı her zaman üçten büyük olmalıdır. Çünkü DE da yeni kromozomların oluşturulması için mevcutların dışında üç adet kromozom gerekmektedir

2. **Mutasyon:** Mutasyon işleminde mevcut kromozomun bazı genleri üzerinde, rasgele belirlenmiş sayıda değişiklikler yapılmaktadır. Bu değişiklikler sayesinde kromozomun sağladığı çözüm noktası, çözüm uzayında dolaşmaktadır. Mutasyonun başarılı olması için, doğru yönde doğru sayıda hareketi sağlayacak değişikliklerin tespit edilmesi gerekmektedir.
3. **Çaprazlama:** Mutasyon işleminin sonucunda elde edilen kromozom ile hali hazırdaki kromozom çaprazlanarak yeni aday kromozom elde edilir. Düzgün çaprazlamada her bir gen ayrı olarak değerlendirilir ve eşit olasılıkla iki ebeveyn kromozomun birinden seçilir.
4. **Seçim:** Son olarak kromozomlar uygunluk değerlerine göre karşılaştırılır ve minimizasyon problemi için daha küçük uygunluk değerine sahip olan kromozom bir sonraki popülasyona aktarılır. Durdurma kriteri sağlanana kadar mutasyon, çaprazlama ve seçim işlem adımları tekrarlanmaktadır. Algoritma sonlanınca en iyi uygunluk değeri ve kromozom rapor edilmektedir. Şekil 3.8’de DE algoritmasının akış diyagramı bulunmaktadır.

3.2.9. Performans değerlendirme kriterleri

Performans değerlendirme alanında birçok hata ölçüm tekniği vardır ve bunlar en yaygın olarak hata ölçümlerini karşılaştırmak, analiz etmek için kullanılır. Tüm modellerin performans başarısını değerlendirmek için Ortalama Mutlak Hata (Mean Absolute Error, MAE), Kök Ortalama Karesel Hata (Root Mean Square Error, RMSE) ve Korelasyon Katsayısı (Correlation Coefficient, CC) kriterleri kullanılmıştır. Korelasyon katsayısı hedef değeri ve tahmin edilen değer arasındaki korelasyonu ölçmek için kullanılır. Ortalama mutlak hata MAE değeri tahmin değerinin hedef değere yakınlığını ölçmek için kullanılır. İki sürekli değişken değerler arasındaki farkın bir ölçümüdür. MAE değerinin büyük olması performansın düşük olduğu anlamına gelir. Kök ortalama karesel hatası RMSE değeri ortalama mutlak hata fonksiyonunun karekökü olarak değerlendirilebilir. Tahmin ile hedef değer arasındaki farkın kareleri toplamının karekökü olarak hesaplanır. Hataların karelerinin ortalamasını ölçmek için kullanılır. RMSE değerinin daha küçük olması daha az hata olduğunu gösterir.

Modellerin performans analizinde kullanılan hata denklemleri ve parametreleri sırasıyla Denklem 3.1, 3.2 ve 3.3'te sunulmuştur (Buyukyildiz ve Kumcu, 2017).

$$MAE = \frac{1}{N} \sum_{i=1}^N |X_i - Y_i| \quad 3.1$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)^2} \quad 3.2$$

$$CC = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad 3.3$$

Bu denklemlerde N veri sayısı, X_i hedef değeri, Y_i tahmin edilen değeri, $\bar{X}$ ortalama hedef değeri ve $\bar{Y}$ ortalama tahmin edilen değeri temsil eder.

3.2.10. Optimizasyon algoritmaları ile tahmin modelleri

Optimizasyon algoritmaları için dört farklı tahmin yöntemi kullanılmıştır. Bu modeller sırasıyla Denklem 3.1, 3.2, 3.3 ve 3.4'te verildiği gibi doğrusal, kuadratik, üstel ve hibrittir.

$$M_{doğrusal} = w_1X_1 + w_2X_2 + w_3X_3 + w_4X_4 + w_5 \quad 3.1$$

$$M_{kuadratik} = w_1X_1 + w_2X_2 + w_3X_3 + w_4X_4 + w_5X_1X_2 + w_6X_1X_3 + w_7X_1X_4 + w_8X_2X_3 + w_9X_2X_4 + w_{10}X_3X_4 + w_{11}X_1^2 + w_{12}X_2^2 + w_{13}X_3^2 + w_{14}X_4^2 + w_{15} \quad 3.2$$

$$M_{üstel} = w_1X_1^{w_2} + w_3X_2^{w_4} + w_5X_3^{w_6} + w_7X_4^{w_8} + w_9 \quad 3.3$$

$$M_{hibrit} = w_1\exp^{-w_2X_1} + w_3\ln X_1 + w_4X_1 + w_5X_1^{w_6} + w_7\exp^{-w_8X_2} + w_9\ln X_2 + w_{10}X_2 + w_{11}X_2^{w_{12}} + w_{13}\exp^{-w_{14}X_3} + w_{15}\ln X_3 + w_{16}X_3 + w_{17}X_3^{w_{18}} + w_{19}\exp^{-w_{20}X_4} + w_{21}\ln X_4 + w_{22}X_4 + w_{23}X_4^{w_{24}} \quad 3.4$$

3.2.11. Optimizasyon algoritmaları ile kullanılan amaç fonksiyonu

Arıza sayısı tahmin sürecinde amaç fonksiyonu olarak Denklem 3.5 kullanılmıştır.

$$Minf(v) = \sum_{r=1}^R (E_r^{gercek} - E_r^{tahmin})^2 \quad 3.5$$

Bu denklemde E_{gercek} ve E_{tahmin} parametreleri gerçek ve tahmin değerleri; R parametresi de gerçek değer sayısını ifade etmektedir.

4. UÇAK BAKIM PERİYODU TAHMİNİ

4.1. Uçak Bakımı MTBF ve NFF Sonuçları

Uçak ekipmanlarının bakım verilerini değerlendirmek için bir program geliştirilmiştir. Farklı üreticinin E1 ve E2 malzemelerinin MTBF değeri hesaplanıp ve karşılaştırılmıştır. Öncelikle malzemenin seri numaralı ekipmanları seçilmiştir. Tamir siparişleri, arıza bildirim kayıtları ve durum kayıtları (Silinen, iptal edilen veya onaylanan vb.) analiz edilmiştir. NFF kodları, arıza, servis edilebilir ve servis edilemeyen depo bilgileri de ayırt edilmiştir. Bu kayıtlardan ekipmanın tamir işlemi süreci gayrı faal deposuna veya faal depoya gelene kadar izlenmiştir. Bu aşamalarda gerçek arızayı ayırt etme sırasında NFF durumları yakalanmaya çalışılmıştır.

Bir bakım teknisyeni kaynak yönetimi programına bir sistem arızasını kaydettiğinde, bu arızanın nedenini araştırmaya başlaması için bakım personeline bildirim gönderilir. Arıza için herhangi bir neden bulunamazsa, bu arıza "NFF" olarak etiketlenir, ancak bu genel süreci etkileyen çeşitli nedenler olabilir. Operatörün veya bakım teknisyeninin sistem hakkında yeterli bilgiye sahip olmaması, arıza teşhisini gerçekleştirmek için yetersiz destek alması, arızanın gerçekleştiği ortamın şartlarının farklı olması gibi durumlar mümkündür. Ekipmanın Teknik doküman kılavuzu hakkında az bilgi sahibi olması veya operasyonel basınçlar dâhil ve bunlarla sınırlı olmamak üzere başka birçok neden olabilir.

MTBF hesabında uçuş saati, operasyonel süre için kriter olarak seçilmiştir. Ekipmanların ölçüm noktaları ve ölçüm belgeleri okunmuştur. Ekipmanın bir ölçüm noktası yoksa ilgili veriler ekipmanın takılı olduğu üst sistemden elde edilir. Bunun sebebi örneğin A1 uçağının alt sistemine takılı bir ekipman, 6 ay sonra A2 uçağının alt sistemine monte edilmiş olabilir. Böylece takılı olduğu zaman aralığında üst sisteminin uçuş saati ne ise o değer alınmış olur. Bu şekilde ekipmanların sökme ve takma aralıkları içinde tüm uçuş saatleri elde edilmiştir.

Arıza bildirimini takip eden bakım işleminde, bir teknisyen arızayı teşhis eder. Ardından, kurumsal kaynak planlama (ERP) sisteminde bir arıza bildirimini oluşturur. Ekipman tamir edilemezse, yeni ekipmanla değiştirilirken, tamir edilebilir ekipman için bir tamir siparişi açılır. Tamir edilebilir ekipman, gayrı faal depoya gönderilir. Burada tamir tezgâhında test edilir. Testlerin sonuçlarına dayanarak, arıza onaylanır veya arıza bulunamadı NFF etiketi atanır. Arıza onaylandıysa ekipmanın garantisi kontrol edilir. Ekipmanın garantisi hala geçerliyse, tamir için üretici şirkete gönderilir. Aksi takdirde

tezgâha tamir işlemine gönderilir. Tamir işleminden sonra, uçağa takılmaya hazır olarak faal depoya gönderilir. MTBF hesaplamasında gerçek arıza sayılarına ihtiyaç vardır. Tezgah testi Şekil 4.1’de verilen tamir sürecini takip edilerek çıkarılan ekipman tamir için gayrı faal depoya gönderilir. Depo seviyesi tezgâh testi, ekipmanın işlevselliğinde herhangi bir arıza bulamazsa, NFF kodu ile bir sipariş onay kaydı ile raporlanır ve bu bir arıza olarak kabul edilmez. Bu nedenle bu bildirim arıza sayısına eklenmez. Aşağıdaki akış diyagramı, arızalarla ilgilenmek ve hangilerinin onaylanmış bir arıza olduğunu belirlemek için kullanılır. MTBF hesaplaması için, ekipmanın işletim profiline bağlı olarak, sistemde kullanımına bağlı olarak, ekipmanın çalışma saatleri uçuş saati olarak hesaplanır. MTBF formül olarak Denklem 4.1’deki gibi verilebilir : (Garmabaki, 2016) (DoD, 1998) (Daniewski, 2018)


$$MTBF = \frac{T(t)}{r} \quad 4.1$$

Burada

$T(t)$ = Toplam çalışma zamanı

r = Onaylanmış arıza sayısı olarak hesaplanır.

E1 ve E2 ekipmanları için MTBF değerleri Çizelge 4.1 ve Çizelge 4.2’te verilmiştir. E_11, iki yıllık bir sürede 117.6 uçuş saati uçmuştur. Bu dönemde ekipmanın onaylanmış toplam arıza sayısı 4’tür. Bu şekilde E_11’in MTBF değeri yukarıda verilen MTBF formülüne göre 39.2 uçuş saati olarak bulunmuştur. Tüm ekipmanlar için MTBF değerini hesaplamak için aynı formül kullanılır. Bir malzemenin MTBF değeri, ona ait tüm ekipmanların MTBF değerlerinin ortalamasıdır. E1’in MTBF değeri 375 uçuş saati ve E2’nin MTBF değeri 339 uçuş saati olarak hesaplanmıştır.



Şekil 4.1 Ekipman tamir süreci akış diyagramı

Çizelge 4.1 E1 Ekipmanının MTBF değerleri

Ekipman	Uçuş Saati	MTBF (saat)	Arıza Sayısı
E_11	117.6	39.2	3
E_12	144.2	72.1	2
E_13	95.8	47.9	2
E_14	47.9	11.9	4
E_15	69	17,3	4

Çizelge 4.2 E2 Ekipmanının MTBF değerleri

Ekipman	Uçuş Saati	MTBF (saat)	Arıza Sayısı
E_21	213	71	3
E_22	367	72.5	3
E_23	155.3	75.7	2
E_24	105,9	78.5	2
E_25	99.7	49.8	2

Çizelge 4.3 Tüm ekipmanların hesaplanan verileri

Malzeme	Ekipman Sayısı (adet)	Arıza sayısı (adet)	MTBF değeri (uçuş saati)	NFF sayısı (adet)
E1	157	61	375	62
E2	72	41	339	19

Çizelge 4.4 En az 50 uçuş saati olan ekipmanların hesaplanan verileri

Malzeme	Ekipman Sayısı (adet)	Arıza sayısı (adet)	MTBF değeri (uçuş saati)	NFF sayısı (adet)
E1	148	46	491	43
E2	61	33	416	10

Çizelge 4.5 En az 100 uçuş saati olan ekipmanların hesaplanan verileri

Malzeme	Ekipman Sayısı (adet)	Arıza sayısı (adet)	MTBF değeri (uçuş saati)	NFF sayısı (adet)
E1	127	31	677	33
E2	57	31	432	7

Çizelge 4.3, Çizelge 4.4 ve Çizelge 4.5'te gösterildiği gibi, E1'in MTBF değeri E2'nin değerinden daha büyüktür. Birinci grupta, uçuş saatlerini sınırlamadan yapılan hesaplamalarda E1 ve E2'nin MTBF değerleri, minimum 50 uçuş saatine göre daha düşüktür. Ayrıca, minimum 50 uçuş saati olan E1'in MTBF değeri, minimum 100 saat uçuş saati olanlardan daha düşüktür. Bu sonuçlara göre, daha sık kullanılan ekipmanlar (daha uzun uçuş saatlerine sahip), daha az uçuş saatine sahip ekipmanlara göre daha güvenilir ve sağlamdır. MTBF değerleri, uçak ekipmanının erken ömür dönemlerinde daha yüksektir.

Tüm ekipmanlar ve bunlara karşılık gelen arıza sayıları, MTBF değerleri ve NFF sayılarının karşılaştırması değerlendirilmiştir. 157 adet E1 ve 72 adet E2 malzemeleri analiz edilmiştir. Ortalama arıza sayıları uçuş saatlerine bakılmaksızın E1 için 0.39 ve E2 için 0.57'dir ve uçuş saatlerine bakılmaksızın ortalama NFF sayıları E1 için 0,39 ve E2 için 0.26'dır. Minimum 50 uçuş saati olan ekipman için, ortalama arıza sayıları E1 için 0,31 ve E2 için 0,54'tür ve ortalama NFF sayıları E1 için 0,29 ve E2 için 0,16'dır. Minimum 100 uçuş saati olan ekipman, ortalama arıza sayıları E1 için 0,24 ve E2 için 0,54'tür ve ortalama NFF sayıları E1 için 0,26 ve E2 için 0,12'dir. Görüldüğü gibi, E1'lerin ortalama arıza sayısı E2'den düşüktür ve ortalama NFF sayıları E2'den yüksektir. Bu bulgular E1'in E2'den daha güvenilir olduğunu açıkça göstermektedir.

4.2. Uçak Bakım Periyodu Tahmin Sonuçları

Uçak arıza günlerini ve genel bakım periyodunu makine öğrenmesi algoritmaları yoluyla tahmin etmek için uçak faaliyet raporları analiz edilmiştir. Buradan aynı tipteki 28 uçağın iki yıl içindeki arıza günleri çıkarılmıştır. Seçilen uçakların sorti sonrası gerçekleşen arıza ve faaliyet verileri incelenmiştir. Bu verilerden beş giriş değişkeni ve bir çıkış değişkeni (bir sonraki arızalanma günü) belirlenmiştir. Toplam 522 satır, dokuz giriş ve bir çıkış (522 x 6) veri kümesi ile MLP, DR ve DVR modelleri eğitilmiştir ve test edilmiştir. Bu modellerde kullanılan algoritmaların parametreleri sırasıyla Çizelge 4.6 Çizelge 4.7 ve Çizelge 4.8'de verilmiştir.

Çizelge 4.6 Ayarlanmış DVR parametreleri

Parametre	Değeri
C	1.0
ε	0.001
Validation Method	10 fold cross validation
Kernel Function	Lineer

Çizelge 4.7 Ayarlanmış MLP parametreleri

Parametre	Değer
Gizli katman nöron sayısı	1
Gizli katman	2
Öğrenme oranı	0.4
Momentum	0.3
Epok	500
Goal	0.005

Çizelge 4.8 Ayarlanmış DR verileri


Parametre	Değer
Küme boyutu	100
Özellik seçim metodu	yok
sınır	1.0E-8

Örnek olarak (Altay ve ark., 2014) çalışmasında yapılan uygulamaya benzer model oluşturulmuştur. Modellerin performansını göstermek için 522 kayıt ve 6 özellikten oluşan veri kümesinin tahmin sonuçları Çizelge 4.9'da verilmiştir. Buna göre CC performans kriterine dayanarak en iyi sonuçlar DVR algoritması tarafından sağlanırken, DR algoritması MAE ve RMSE performans kriterlerine göre en iyi sonuçları vermiştir.


Çizelge 4.9 (522 x 6) veri kümesi (5giriş 1 çıkış) için performans değerleri

Metot	CC	MAE	RMSE
DR	0.9247	24.1779	32.8936
MLP	0.9053	69.9756	86.1537
DVR	0.9143	23.5671	35.6578


Çizelge 4.9'da gösterildiği gibi, CC, MAE ve RMSE performans kriterlerine dayanarak, en iyi sonuçlar önerilen sistemde DR algoritması tarafından sağlanmıştır. Test verileri için $CC = 0.9247$, $MAE = 24.1779$ ve $RMSE = 32.8936$ elde edilmiştir. Şekil 4.2, Şekil 4.3 ve Şekil 4.4'te sırasıyla DR, DVR ve MLP test verileri için hedef ve hedef sonuçlar arasındaki doğrusal korelasyon gösterilmiştir. Sonuçlara göre test verilerinin ve tahmin verilerinin regresyon çizgisi DR'nin $y = 0.9976x + 0.0155$; DVR olanlar $y = 0.9184x + 0.48$ ve MLP olanlar $y = 0.9999x - 0.0744$ denklemlerini sağlamaktadır.



Şekil 4.2 DR Algoritması için tahmin ve hedef verilerin korelasyon grafiği




Şekil 4.3 DVR Algoritması için tahmin ve hedef verilerin korelasyon grafiği




Şekil 4.4 MLP Algoritması için tahmin ve hedef verilerin korelasyon grafiği


DR, DVR ve MLP için test veri kümesindeki hedef ve tahmin değerler sırasıyla Şekil 4.5, Şekil 4.6 ve Şekil 4.7'de verilmiştir. Bu sonuçlar 1 kat çapraz doğrulama test sonuçlarının grafikleridir.



Şekil 4.5 DR algoritması 1 kat cd tahmin ve hedef test verileri grafiği



Şekil 4.6 DVR algoritması 1 kat cd tahmin ve hedef test verileri grafiği



Şekil 4.7 MLP algoritması 1 kat cd tahmin ve hedef test verileri grafiği

Çizelge 4.9’da görüldüğü gibi DR, DVR ve MLP modellerinin performans değerlerine göre en başarılı sonuç DR modelinden elde edilmiştir. DR, DVR ve MLP modellerinden elde edilen tahmin ve hedef değerlerin grafikleri sırasıyla Şekil 4.5, Şekil 4.6 ve Şekil 4.7’de verilmiştir.

5. EKİPMAN ARIZA SAYISININ TAHMİNİ

Havacılık endüstrisinde, gelecekteki eylemlerin öngörülmesinde anlamlı sonuçlar elde etmek için kullanılabilecek çok sayıda bilgi ve bakım verisi bulunmaktadır. Uçak sistemlerinin arızalarını tahmin etmek için özellik seçimi ve veri elenmesine dayalı makine öğrenme modellerini tanıtmayı amaçlamaktadır. İki yıl boyunca uçak ekipmanlarının bakım ve arıza verileri toplanmış, dokuz girdi ve bir çıktı değişkeni titizlikle tanımlanmıştır. Arıza sayısı tahmininin başarısını artırmak için iki aşamalı hibrit veri hazırlama modeli önerilmiştir. İlk aşamada, nitelik değerlendirerek en etkili ve en etkisiz parametreleri bulmak için bir özellik seçme yöntemi olan ReliefF kullanılmıştır. İkinci aşamada gürültülü veya tutarsız verileri elemek için güncellenmiş K-ortalama algoritması kullanılmıştır. Hibrit veri hazırlama modelinin ekipmanın bakım veri kümesindeki performansı, makine öğrenimi algoritmalarından; YSA olarak MLP, DVR ve DR ile değerlendirilmiştir. Ayrıca bu modellerin performanslarını karşılaştırmak için CC, MAE ve RMSE gibi performans kriterleri kullanılmıştır. Sonuçlara göre hibrit veri hazırlama modelinin ekipmanın arıza sayısını tahmin etmede başarılı olduğunu göstermektedir.


Uçak ekipmanlarındaki arıza sayısını tahmin etmek için, GA, DA ve DE algoritmaları doğrusal, kuadratik, üstel ve hibrit modellerle uygulanmıştır. Üç algoritmanın (GA, DA, DE) sonuçları, dört farklı modele (doğrusal, kuadratik, üstel ve hibrit) göre karşılaştırılmıştır. Sonuçlar GA'nın kuadratik modellerde daha başarılı olduğunu, DA ve DE algoritmalarının üstel ve hibrit modellerinde daha başarılı olduğunu göstermiştir. Buna ek olarak optimizasyon tabanlı tahmin yöntemlerinin başarısı, elde edilen sonuçların aynı veri kümesinde istatistiksel ve makine öğrenimi yapay zeka tabanlı tahmin sonuçları ile karşılaştırılmasıyla ortaya çıkarılmıştır.

Özellik seçimi Çizelge 3.3'te verilen on özellik kullanılarak gerçekleştirmiştir. Ekipman arızası sayısı analizin hedefidir. Bu amaçla ilişki ve ağırlıklandırma katsayısı bağımlılıklarını bulmak için ReliefF algoritması kullanılmıştır. Sıralama değerlerine göre en etkili dört özellik seçilmiştir. Çizelge 5.1'te bu özellikler verilmiştir.

Çizelge 5.1 ReliefF algoritması ile seçilen en etkili dört özellik

Parametre	Tanım
FH Uçuş Saati	Son 24 ayda ekipmanın toplam uçuş saati
RM	Son 24 ayda ekipmanın sökölme sayısı
UR	Son 24 ayda ekipmanın plansız sökölme sayısı
SR	Son 24 ayda ekipmanın söküm sonucu faal çıkma sayısı

Hazırlanan veri kümelerindeki gürültülü ve tutarsız veriler genellikle tahmini olumsuz etkiler ve sistemin performansını azaltır. Bu nedenle, kestirim performansını artırmak ve gürültülü, tutarsız verileri ortadan kaldırmak için geliştirilmiş K-ortalamlar algoritması kullanılmıştır. Algoritma 1'de verilen sözde kod kullanılarak geliştirilmiştir. Bu modelde, küme merkezleri başlangıçta tahsis edilir ve veriler kümelere uygun şekilde dağıtılmıştır. Önceden belirlenmiş bir sayı ($N = 5$) olarak alınarak her kümede merkeze en uzak kayıtlar elenmiştir. Mesafe kriteri Öklid uzaklık ölçümüdür. Elenen örnekler Şekil 5.2'de gösterilmektedir.

**Şekil 5.1** Hibrit veri hazırlama modelinin blok şeması**Şekil 5.2** Geliştirilmiş K-ortalamlar algoritması ile veri hazırlama modeli

Algoritma 1 Geliştirilmiş K-ortalamlar algoritmasının sözde kodu

```

1. Procedure veri_kümesini_hazırla.
2  Get veri_kümesi, kümenin merkezine uzaklık, eleme_sayısı
3  For i = 1 to küme_sayısı
4    Sort distance of veri_kümesi(i) to küme_merkezi(i) descending
5    For j = 1 to eleme_sayısı
6      Delete j. veri in veri_kümesi(i)
7    End for
8  End for
9 End procedure
  
```

Veri kümesinin 75 kaydı (yaklaşık% 13) önerilen veri hazırlama modelinin sözde kodu ile elenmiştir. Veri kümesinin 585 kaydından 510 kayıt elde kalmıştır. Önerilen hibrit veri hazırlama modelimiz Şekil 5.1’de gösterildiği gibi iki aşamadan oluşmaktadır. İlk aşamada, özellik seçimi ReliefF algoritması ile dokuz giriş özelliği dört özelliğe indirilmiştir. İkinci aşamada veri kümesi Şekil 5.2’deki gibi geliştirilmiş K-ortalamalar algoritması ile 510 kayda indirilmiştir. 510 kayıtlı elde edilen veri kümesi MLP, DVR ve DR tahmin algoritmalarında giriş olarak kullanılmıştır.

5.1. Yapay Zekâ Yöntemleri ile Arıza Tahmini Sonuçları

Arıza sayısı tahmini ve makine öğrenmesi algoritmaları yoluyla analiz için veri toplamak üzere bir program geliştirilmiştir. Seçilen ekipmanın bakım ve işletim verileri belirlenmiştir. Bu verilerden dokuz giriş değişkeni ve bir çıkış değişkeni tespit edilmiştir. Toplam 585 satır, dokuz giriş ve bir çıkış (585 x 10) verisine göre MLP, DR ve DVR modelleri eğitilmiştir ve test edilmiştir. Bu modellerde kullanılan algoritmaların ayarlanmış parametreleri sırasıyla Çizelge 5.2 Çizelge 5.3 Çizelge 5.4’de verilmiştir.

Çizelge 5.2 Ayarlanmış DVR parametreleri

Parametre	Değeri
C	1.0
ϵ	0.001
Validation Method	10 fold cross validation
Kernel Function	Lineer

Çizelge 5.3 Ayarlanmış MLP parametreleri

Parametre	Değer
Gizli katman nöron sayısı	2
Gizli katman	2
Öğrenme oranı	0.2
Momentum	0.2
Epok	500
Goal	0.005

Çizelge 5.4 Ayarlanmış DR verileri

Parametre	Değer
Küme boyutu	100
Özellik seçim metodu	yok
sınır	1.0E-8

Önerilen iki aşamalı hibrit sistemin performansını göstermek için 585 kayıt ve 9 özellikten oluşan ham veri kümesinin tahmin sonuçları Çizelge 5.5'de verilmiştir. Buna göre CC performans kriterine dayanarak en iyi sonuçlar DVR algoritması tarafından sağlanırken, DR algoritması MAE ve RMSE performans kriterlerine göre en iyi sonuçları vermiştir.

Çizelge 5.5 (585 x 10) veri kümesi (9 giriş 1 çıkış) için performans değerleri

Metot	CC	MAE	RMSE
DR	0.8967	0.7341	1.0646
MLP	0.8925	0.8125	1.0992
DVR	0.9008	0.741	1.0889

Tahminlerde en etkili olan özellikleri ortaya çıkarmak için ham verilere ReliefF algoritması uygulanmıştır. Özellik seçimi ReliefF algoritması dokuz giriş parametresine uygulanarak sıralanan değerlere göre, son beş tanesi elenmiştir. MLP, DR ve DVR modelleri seçilen 585 satır kayıt, dört giriş ve bir çıkış ile kurulmuştur. (585x5) veri kümesi bu modeller ile eğitildi ve test edilmiştir. Çizelge 5.6'da görüldüğü gibi, elde edilen tüm sonuçlar özellik seçimi olmadan elde edilen sonuçlara göre daha iyi çıkmıştır. MLP (CC = 0.9127, MAE = 0.7301, RMSE = 0.9853) tarafından sağlanan sonuçlar, diğer algoritmalarından daha iyi çıkmıştır. Tüm tahmin algoritmalarında elde edilen hata parametrelerinin performans sonuçları Çizelge 5.6'da verilmiştir.

Çizelge 5.6 (585 x 5) veri kümesi (4 giriş 1 çıkış) için performans değerleri

Metot	CC	MAE	RMSE
DR	0.8967	0.7341	1.0646
MLP	0.9127	0.7301	0.9853
DVR	0.9013	0.7415	1.0909


Son aşamada, gürültülü ve tutarsız verileri ortadan kaldırmak için veri kümesine geliştirilmiş K-Ortalamlar algoritması uygulandı (585x5). En iyi k değeri bulundu (k =

15). Her kümenin merkezinden en uzak beş parametre elimine edildi. Sonuç olarak, 75 kayıt elendi. Böylece bakım verilerine hibrit bir model yaklaşımı uygulanmış ve verilerin kalitesi artırılmıştır. DR, MLP ve DVR modelleri seçilen 510 kayıt, dört giriş ve bir çıkışla oluşturulmuştur. Seçilen veriler (510x5) eğitildi ve test edildi. Modelin performansı, özellik seçimi ve veri azaltma yapılarak elde edilen sonuçların diğer sonuçlara kıyasla oldukça başarılı olduğu gösterilmiştir. DR, MLP ve DVR algoritmalarının performansı Çizelge 5.7’de verilmiştir.


Çizelge 5.7 (510 x 5) veri kümesi (4 giriş 1 çıkış) için performans değerleri

Metot	CC	MAE	RMSE
DR	0.9316	0.6807	0.835
MLP	0.9284	0.6816	0.8555
DVR	0.9316	0.7108	0.8558


Hata! Başvuru kaynağı bulunamadı. Çizelge 5.7’de gösterildiği gibi, CC, MAE ve RMSE performans kriterlerine dayanarak, en iyi sonuçlar önerilen iki aşamalı hibrit sistemde DR algoritması tarafından sağlanmıştır. Test verileri için $CC = 0.9316$, $MAE = 0.6807$ ve $RMSE = 0.835$ elde edilmiştir. Şekil 5.3 Şekil 5.4 Şekil 5.5’te sırasıyla DR, DVR ve MLP test verileri için hedef ve tahmin sonuçları arasındaki doğrusal korelasyon gösterilmiştir. Sonuçlara göre test verilerinin ve tahmin verilerinin regresyon çizgisi DR’nin $y = 0.9976x + 0.0155$; DVR olanlar $y = 0.9184x + 0.48$ ve MLP olanlar $y = 0.9999x - 0.0744$ denklemlerini sağlar.



Şekil 5.3 DR Algoritması için tahmin ve hedef verilerin korelasyon grafiği




Şekil 5.4 DVR Algoritması için tahmin ve hedef verilerin korelasyon grafiği




Şekil 5.5 MLP Algoritması için tahmin ve hedef verilerin korelasyon grafiği


DR, DVR ve MLP için önerilen iki aşamalı hibrit sistemin test veri kümesindeki hedef ve tahmin değerler sırasıyla Şekil 5.6, Şekil 5.7 ve Şekil 5.8'de verilmiştir. Bu sonuçlar 1 kat çapraz doğrulama test sonuçlarının grafikleridir.



Şekil 5.6 DR algoritması 1 kat cd tahmin ve hedef test verileri grafiği



Şekil 5.7 DVR algoritması 1 kat cd tahmin ve hedef test verileri grafiği



Şekil 5.8 MLP algoritması 1 kat cd tahmin ve hedef test verileri grafiği

Şekil 5.6 Şekil 5.7 Şekil 5.8'deki iki aşamalı hibrit sistemden elde edilen tahmin ve hedef değerlerin grafiğini göstermektedir. Çizelge 5.5, Çizelge 5.6 ve Çizelge 5.7'de görüldüğü gibi önerilen hibrit veri hazırlama modeli DR, DVR ve MLP tahmin modellerinin performansını artırmıştır. Önerilen hibrit sistem en etkili özellikleri seçmemizi ve tahminlerin doğruluğunu azaltabilecek gürültülü ve gereksiz verileri ortadan kaldırmamızı sağladığı için tahminlerde daha yüksek doğruluk elde edilmesine yardımcı olmuştur.

5.2. Optimizasyon Yöntemleri ile Arıza Tahmini Sonuçları

Optimizasyon algoritmaları ile tahmin sürecinde %70 eğitim verileri ve %30 test verileri seçilmiştir. Önerilen modeller belirtilen katsayılarla 20 kez test edilmiştir ve en iyi sonuçlar derlenmiştir. Deneysel çalışmanın en iyi sonuçlarını veren GA, DA ve DE parametreleri sırasıyla Çizelge 5.8 Çizelge 5.9 veya Çizelge 5.10'da verilmiştir. Katsayıların arama uzayındaki başlangıç değerleri için aralık (-10 – 10) arasında sınırlandırılmıştır.

Çizelge 5.8 Genetik algoritma parametreleri

Parametre	Değer
Populasyon miktarı	100
Seçilen Teknik	Roulette wheel
Çaprazlama tipi	İki noktalı
Çaprazlama oranı	0.8
Mutasyon oranı	0.3
Maksimum iterasyon sayısı	1000

GA ile doğrusal, kuadratik, üstel ve hibrit model olmak üzere 4 farklı model ile arıza sayısı tahmini gerçekleştirilmiştir. Buradaki temel amaç her bir model için en uygun ağırlıkları (weights) belirleyerek tahmin başarısını artırmaktır. Eğitim verileri üzerinden elde edilen katsayılar ve bu katsayılar göre en uygun değerler aşağıdaki gibi elde edilmiştir.

$$M_{linear} = 0.3689X_1 + 8.8213X_2 + 3.2373X_3 - 4.4824X_4 - 7.1339 \quad (5.1)$$

$$f(v)_{linear} = 0.004044 \quad (5.2)$$

$$M_{quadratic} = -0.7114X_1 - 0.3854X_2 + 6.5503X_3 - 5.9464X_4 + 1.6607X_1 * X_2 - 6.0483X_1 * X_3 + 0.9012X_1 * X_4 - 2.5258X_2 * X_3 + 0.4755X_2 * X_4 + 0.5161X_3 * X_4 + 2.1334X_1^2 - 4.2254X_2^2 + 8.7945X_3^2 + 4.1678X_4^2 - 5.3866$$

$$f(v)_{quadratic} = 0.0039325 \quad (5.3)$$

$$M_{exponential} = 2.0351X_1^{0.1146} - 0.5556X_2^{-4.9372} + 1.78299X_3^{2.8433} - 0.1017X_4^{-8.6713} - 2.2408$$


$$f(v)_{exponential} = 0.0039311 \quad (5.4)$$

$$M_{hybrid} = 4.2766exp^{1.2890X_1} + 0.1854lnX_1 + 0.2939X_1 - 6.0029X_1^{-6.1463} + 0.6544exp^{5.9038X_2} + 7.8388lnX_2 + 7.8880X_2 + 8.2790X_2^{-9.9827} - 2.0254exp^{4.7689X_3} - 5.6246lnX_3 + 2.1592X_3 + 0.3664X_3^{2.9458} - 8.3916exp^{9.244X_4} - 6.7767lnX_4 - 5.5662X_4 - 5.6161X_4^{-2.5519}$$

$$f(v)_{hybrid} = 0.0038068$$


Eğitim veri kümesi üzerindeki Denklem (5.1 – 5.4) sonuçlarına göre 4 farklı model arasından en iyi uygunluk (best fitness) değeri doğrusal model ile elde edilmiştir.

Şekil 5.9’da eğitim veri kümesi üzerinde GA’nın doğrusal, kuadratik, üstel ve hibrit modeller ile katsayıların belirlenmesi sürecinde iterasyon sayısı ile en uygun değerlerinin değişimi görülmektedir.



Şekil 5.9 GA ile Doğrusal Kuadratik, Üstel ve Hibrit model grafiği

Şekil 5.10'da en uygun değere sahip Doğrusal model için test verileri ile örnek bir tahmin ve hedef GA sonuçları görülmektedir.



Şekil 5.10 GA algoritması için arıza sayısı tahmin ve hedef test verileri

Çalışmada kullanılan DA parametreleri Çizelge 5.9'da verilmiştir.

Çizelge 5.9 DA Algoritması parametreleri

Parametre	Değer
Populasyon boyutu	100
Seçim tekniği	yok
Referan küme boyutu	14
Elitizm sayısı	7
Maksimum iterasyon sayısı	1000

DA ile doğrusal, kuadratik, üstel ve hibrit model olmak üzere 4 farklı model ile arıza sayısı tahmini gerçekleştirilmiştir. Eğitim verileri üzerinden elde edilen katsayılar ve bu katsayılar göre en uygun değerler aşağıdaki gibi elde edilmiştir.

$$M_{linear} = 0.2443X_1 + 6.5533X_2 + 5.0385X_3 - 3.4754X_4 - 7.5969 \quad (5.5)$$

$$f(v)_{linear} = 0.004058 \quad (5.6)$$

$$M_{quadratic} = -0.0252X_1 - 0.0253X_2 - 1.8676X_3 - 0.0252X_4 + 0.0213X_1 * X_2 + 0.0213X_1 * X_3 + 0.0214X_1 * X_4 + 5.2621X_2 * X_3 - 1.8676X_2 * X_4 + 0X_3 * X_4 + 0.02134X_1^2 + 0.0214X_2^2 + 0.0213X_3^2 - 0.0252X_4^2 + 0$$

$$f(v)_{quadratic} = 0.004090 \quad (5.7)$$


$$M_{exponential} = -0.7604X_1^{5.0562} - 2.0367X_2^{-2.0332} + 3.1384X_3^{1.9109} - 0.0816X_4^{2.4749} + 0 \quad (14)$$

$$f(v)_{exponential} = 0.004045 \quad (5.8)$$

$$M_{hybrid} = -2.8600exp^{2.8601X_1} + 0.0283lnX_1 + 0.0283X_1 + 0.5258X_1^{-8.6165} + -4.9244exp^{1.8286X_2} + 8.0748lnX_2 + 0.0283X_2 + 0.5258X_2^{-9.1914} + 0.0283exp^{0.5258X_3} + 8.0748lnX_3 + 0.0284X_3 + 0.5258X_3^{-8.6165} + 5.13626exp^{3.3842X_4} - 2.8386lnX_4 + 0.0283X_4 + 0.02831X_4^{1.5054}$$


$$f(v)_{hybrid} = 0.004015 \quad (15)$$

Eğitim veri kümesi üzerindeki Denklem (5.5 - 5.8) sonuçlarına göre 4 farklı model arasından en uygun değer kuadratik model ile elde edilmiştir. Şekil 5.11’de eğitim veri kümesi üzerinde DA’nin doğrusal, kuadratik, üstel ve hibrit modeller ile katsayıların belirlenmesi sürecinde iterasyon sayısı ile en iyi uygunluk değerlerinin değişimi görülmektedir.



Şekil 5.11 DA ile Doğrusal, Kuadratik, Üstel ve Hibrit Model Sonuçları

Şekil 5.12’da en uygun değere sahip üstel model için test verileri ile örnek bir tahmin ve hedef DA modelinin sonuçları görülmektedir.



Şekil 5.12 DA algoritması için arıza sayısı tahmin ve hedef test verileri

Çalışmamızda kullanılan DE algoritması parametreleri Çizelge 5.10’da verilmiştir.

Çizelge 5.10 DE Algoritması parametreleri

Parametre	Değer
Popülasyon Boyutu	100
Ölçekleme Faktörü (F)	0.5
Çaprazlama oranı (CR)	0.9
Maksimum İterasyon Sayısı	1000

DE algoritması ile doğrusal, kuadratik, üstel ve hibrit model olmak üzere 4 farklı model ile arıza sayısı tahmini gerçekleştirilmiştir. Eğitim verileri üzerinden elde edilen katsayılar ve bu katsayılar göre en uygun değerler aşağıdaki gibi elde edilmiştir.

$$M_{\text{linear}} = 0.0547X_1 + 7.4218X_2 + 4.7382X_3 - 3.5910X_4 - 7.9604 \quad (5.9)$$

$$f(v)_{\text{linear}} = 0.004059$$

$$M_{\text{quadratic}} = -3.2917X_1 - 1.1322X_2 + 4.1122X_3 - 6.5593X_4 + 6.6829X_1 * X_2 + 1.0375X_1 * X_3 + 2.9910X_1 * X_4 - 4.7433X_2 * X_3 - 9.4737X_2 * X_4 + 3.6417X_3 * X_4 - 3.50884X_1^2 + 6.5545X_2^2 - 0.0771X_3^2 + 2.2095X_4^2 + 2.9883 \quad (5.10)$$


$$f(v)_{\text{quadratic}} = 0.003971$$

$$M_{\text{exponential}} = -1.3516X_1^{2.6495} - 1.8976X_2^{-1.1908} + 2.5277X_3^{2.1690} + 0.4749X_4^{-0.6227} + 0.6768 \quad (5.11)$$

$$f(v)_{\text{exponential}} = 0.003977$$


$$M_{\text{hybrid}} = -7.1694\exp^{2.3477X_1} + 0.9870\ln X_1 - 2.4765X_1 - 4.5942X_1^{-0.8610} + 0.9842\exp^{5.2981X_2} + 0.2102\ln X_2 + 3.8906X_2 + 1.8123X_2^{-7.3341} - 1.0184\exp^{2.0079X_3} + 4.2887\ln X_3 + 6.3812X_3 + 2.1394X_3^{-2.4742} + 4.57976\exp^{8.8266X_4} + 1.7211\ln X_4 - 4.0338X_4 - 1.3620X_4^{-2.0728} + 0.004097 \quad (5.12)$$

Eğitim veri kümesi üzerindeki Denklem (5.9 – 5.12) sonuçlarına göre 4 farklı model arasından en uygun değer hibrit model ile elde edilmiştir. Şekil 5.13’de eğitim veri kümesi üzerinde DE’nin doğrusal, kuadratik, üstel ve hibrit modeller ile katsayıların belirlenmesi sürecinde iterasyon sayısı ile en iyi uygunluk değerlerinin değişimi görülmektedir.



Şekil 5.13 DE ile Doğrusal, Kuadratik, Üstel ve Hibrit model grafiği

Şekil 5.14'te en uygun değeri sahip üstel model için örnek bir tahmin ve hedef test verileri DE sonuçları görülmektedir.



Şekil 5.14 DE algoritması için arıza sayısı tahmin ve hedef test verileri

5.3. Arıza Tahmini Genel Sonuçları

Çalışmamızda GA, DA ve DE optimizasyon algoritmaları ile gerçekleştirilen tüm tahmin sonuçları, tahmin performans kriterleri değerleri ile karşılaştırmalı olarak bu bölümde sunulmuştur. Ayrıca, mevcut sonuçlar, aynı veri seti üzerinde önceki çalışmamızda elde edilen sonuçlarla karşılaştırılmıştır. Çizelge 5.11'de GA, DA ve DE algoritmalarının farklı model ve sonuçlarla uygulanarak elde edilen performans değerlendirme kriter değerleri önceki çalışma (Inan, 2020) ile aynı test verilerinde verilmiştir.

Çizelge 5.11 GA, DA, DE ve önceki çalışma sonuçlarının karşılaştırılması

Modeller	Metotlar	CC	MAE	RMSE
Doğrusal	GA	0.9111	0.6765	0.8375
	DEA	0.9108	0.6795	0.8301
	DA	0.9107	0.6784	0.8397
Kuadratik	GA	0.9086	0.6791	0.8347
	DEA	0.9075	0.6865	0.8327
	DA	0.9081	0.6962	0.8292
Üstel	GA	0.9068	0.7048	0.8642
	DEA	0.9103	0.6827	0.8334
	DA	0.9113	0.6816	0.8382
Hibrit	GA	0.8828	0.7415	0.9397
	DEA	0.9089	0.6856	0.8312
	DA	0.9106	0.6792	0.8419
Önceki Çalışma	DR	0.9316	0.6807	0.835
	MPL	0.9284	0.6816	0.8555
	DVR	0.9316	0.7108	0.8558

Yukarıdaki tablo için GA, DE ve DA algoritmalarının doğrusal, kuadratik, üstel ve hibrit modeller ile uygulanması sonucunda elde edilen tahmin sonuçları CC, MAE ve RMSE ölçütlerine göre ayrı ayrı değerlendirilmiş ve takip eden maddeler halinde (1-9) yorumlanmıştır.

- 1- GA algoritmasının doğrusal, kuadratik, üstel ve hibrit modeller ile uygulanması sonucunda elde edilen tahmin sonuçları R ve MAE ölçütlerine göre değerlendirildiğinde en iyi sonuç doğrusal modelde (CC = 0.9111, MAE = 0.6765) en iyi RMSE değeri ise kuadratik modelde (RMSE = 0.8347) elde edilmiştir.
- 2- DE algoritmasının belirtilen modeller ile uygulanması sonucunda elde edilen tahmin sonuçları CC, MAE ve RMSE ölçütlerine göre değerlendirildiğinde her 3 ölçüte göre en uygun modelin doğrusal olduğu görülmektedir.
- 3- DA algoritmasının belirtilen modeller ile uygulanması sonucunda elde edilen tahmin sonuçları R ölçütüne göre değerlendirildiğinde en iyi sonuç R = 0.9113 değeri ile exponential modelde, MAE ölçütüne göre değerlendirildiğinde en iyi sonuç 0.6784 MAE oranı ile doğrusal modelde,

RMSE ölçütüne göre değerlendirildiğinde ise en iyi sonuç 0.8292 değeri ile kuadratik modelde elde edilmiştir.

- 4- GA, DA ve DE algoritmalarının doğrusal model ile uygulanması sonucunda elde edilen tahmin sonuçlarının CC ve MAE ölçütlerine göre değerlendirildiğinde en yüksek sonuç GA ($CC = 0.9111$ ve $MAE = 0.6765$) ile elde edilmiştir. Aynı model için RMSE ölçütüne göre en iyi sonuç 0.8301 ile DE algoritmasında elde edilmiştir.
- 5- GA, DA ve DE algoritmalarının kuadratik model ile uygulanması sonucunda elde edilen tahmin sonuçları CC ve MAE ölçütüne göre değerlendirildiğinde en iyi sonuç GA ile ($CC = 0.9086$ ve $MAE = 0.6791$) elde edilmiştir. Aynı model için RMSE ölçütüne göre en iyi sonuç 0.8292 ile DA algoritmasında elde edilmiştir.
- 6- GA, DA ve DE algoritmalarının üstel model ile uygulanması sonucunda elde edilen tahmin sonuçları CC ve MAE, ölçütlerine göre değerlendirildiğinde en iyi sonuç DA algoritması ile ($CC = 0.9113$, $MAE = 0.6816$) elde edilmiştir. Aynı model için RMSE ölçütüne göre en iyi sonuç 0.8334 ile DE algoritması ile elde edilmiştir.
- 7- Benzer şekilde GA, DA ve DE algoritmalarının hibrit model ile uygulanması sonucunda elde edilen tahmin sonuçları CC ve MAE, ölçütlerine göre değerlendirildiğinde en iyi sonuç DA algoritması ile ($CC = 0.9112$, $MAE = 0.6803$) elde edilmiştir. Aynı model için RMSE ölçütüne göre en iyi sonuç 0.8312 ile DE algoritması ile elde edilmiştir.
- 8- Tüm optimizasyon algoritmaları ve model sonuçları CC, MAE ve RMSE ölçütlerine göre birlikte değerlendirildiğinde en iyi CC değeri DA ve üstel modelde ($CC = 0.9113$), en iyi MAE değeri GA ve doğrusal modelde ($MAE = 0.6765$), en iyi RMSE değeri ise DA ve kuadratik modelde ($RMSE = 0.8292$) elde edilmiştir.
- 9- (1-8) sonuçları genel olarak değerlendirildiğinde doğrusal modelin daha ön plana çıkarak her 3 optimizasyon algoritmasında da daha başarılı tahmin sonuçları verdiği GA'nın doğrusal ve kuadratik modelde, DA ve DE algoritmalarının ise üstel ve hibrit modellerde daha başarılı sonuçlar elde edildiği görülmüştür.

6. SONUÇLAR

Tez kapsamında bakım ve arıza sayısı tahminine yönelik çalışma yapılmıştır. Uçak sistemlerinin güvenilirliği, uçağın faal olarak uçuşa hazır olması, uçuş sırasında ekipmanlarının arızaya düşme sürelerinin uzun olması, güvenlik, maliyet ve performans açısından çok önemlidir. Uçağın ekipmanlarının çalışabilir durumda olması ve çalışma ömürlerinin uzun olması için öncesinde bakım planlarının takibi ve optimum seviyede yapılması da büyük önem taşımaktadır. Bakım bir parçanın istenilen ömür çevrimi içerisinde parçanın gerekli fonksiyonlarını yerine getirebilecek şekilde korunması için bütün teknik eylemlerin bir bütünü olarak tanımlanmaktadır. Bakım etkinliği ile ilgili yapılan çalışmalarda bakım maliyetlerinin yüksek bir oranı gereksiz veya düzgün olarak gerçekleştirilmeyen bakım faaliyetleri olarak boşa yapılan harcamalar olduğu görülmüştür.

Tez kapsamında yapay zeka uygulamaları ile geçmiş uçak arıza verileri kullanılarak sistem, ekipman ve malzeme bazında MTBF hesabı yapılmıştır ve ileride oluşabilecek arıza sayısı tahmininde bulunarak malzeme ihtiyaç planlamasının, bakım planlarının ona göre düzenlemektir. Sonuç olarak plansız sökme ve takmaların azaltılması, beklenmeyen arızaların azaltılması, gereksiz bakımların iptal edilmesi, planlı bakım aralıklarının verimli bir şekilde ayarlanması ve bakım maliyetinin düşürülmesi hedeflenmektedir. Elde edilecek sonuçlar atölyelerde, bakım birimlerinde mühendisler tarafından incelenerek bakım planlama değişikliği, malzeme ihtiyaç planlaması konularında öngörü olarak kullanılacaktır.

Uçaklar, onları oluşturan özel ekipman ve malzemeler ile birlikte güvenilirlik gereksinimleri olan pahalı endüstriyel sistemlerdir. Günümüz dünyasında, uçak sistemleri gittikçe daha karmaşık hale gelmektedir ve bu nedenle bilinmeyen arızaların sayısı da bakım işlemleri sırasında artmaktadır. Bakım ve arıza verileri içinde gerçek arızalar tespit edilirken NFF faktörü analiz edilmiştir ve MTBF hesaplamalarında önemli bir yeri olduğu gösterilmiştir. Bazen teknisyenler ihmal veya başka nedenlerle tamir siparişi onay formuna NFF etiketi atamazlar ve bu şekilde NFF verileri gözden kaçır. Böyle bir durumda onaylanan arıza sayısı yanıltıcı olabilir. Tamir tezgâhındaki bakım personeli bu arıza kayıtlarını doğru bir şekilde tutması gerekir. Her arıza bildirimi onaylanmış bir arıza olmayabilir. Bu nedenle arıza bildiriminde tüm prosedürler sürecin başından sonuna kadar takip edilerek NFF durumları kontrol edilmiştir.

Uçaklar bazen gerçekten zorlu uçuş görevlerini üstlenirler ve bazen kolay eğitim etkinlikleri yaparlar, bu nedenle ölçüm değerleri çok değişken olabilmektedir. Elde edilen sonuçlar bakım birimlerinin tamir işlemleri sırasında daha etkili önlemler almalarına yardımcı olacaktır ve karar verme süreçlerinde MTBF ve NFF analizleri ile etkili güvenilirliğin ve kullanılabilirliğin artırılacağını göstermiştir. Bu şekilde bakım yöneticilerinin kaynak gereksinimleri hakkında malzeme ihtiyaç planlaması yapmalarına farklı üreticilerden alınan malzemeler arasında karar vermelerine yardımcı olacaktır.

Yapay zekâ yöntemleri ile arıza sayısı tahmininde elde edilen sonuçlar ile havacılıkta, güvenilirlik ve bakım maliyetlerinin analizinde geçmiş bakım verilerinden faydalanmak büyük önem taşımaktadır. Bunun nedeni kestirimci bakım planlamasının tahminler doğrultusunda uygun bir şekilde planlanabilmesidir. Kestirimci bakımın temel hedefi, karmaşık bir tamir edilebilir sistemin güvenilirliğini ve sürdürülebilirliğini analiz etmek için sistem bileşenlerinin yedek parçalarını, ekipman arızalarını ve planlama stratejilerini tahmin etmektir. Bunun için iniş takımı sisteminden seçilen ekipmanların bakım veri kümesindeki gürültülü ve tutarsız verileri ortadan kaldırmak ve en etkin nitelikleri seçmek için özellik seçimi ReliefF algoritması ve geliştirilmiş K-ortalamlar algoritması kullanılarak hibrit bir veri hazırlama modeli uygulanmıştır. Önerilen hibrit veri hazırlama yöntemi doğrusal regresyon DR, destek vektör regresyonu DVR ve YSA çok katmanlı algılayıcı MLP modelleri ile uygulamaya konulmuştur. Elde edilen sonuçlar DR modelinin arıza sayılarını tahmin etmede MLP ve DVR modellerinden daha iyi performans gösterdiğini göstermiştir. Sonuçlar önerilen hibrit veri hazırlama modelinin arıza sayılarının doğru tahminini önemli ölçüde geliştirdiğini göstermektedir. Bu tez çalışmasında uyguladığımız modeller ile makine öğrenme algoritmalarında ve veri madenciliğinde hibrit veri hazırlama yöntemlerinin kullanılması ve uygulanması yol gösterici bir çalışma olmuştur.

Aynı veriler ile optimizasyon yöntemleri kullanılarak da ekipman arızalarının sayısının tahmini yapılmıştır. GA, DA ve DE optimizasyon algoritmaları, uçak ekipmanlarındaki arıza sayısını tahmin etmek için lineer, kuadratik, üstel ve hibrit olmak üzere 4 farklı modelde uygulanmıştır. Üç farklı tahmin edicinin ve dört farklı modelin sonuçları temel tahmin başarı kriterlerine göre elde edilmiştir. Elde edilen sonuçları göre, GA doğrusal ve kuadratik modellerde daha başarılı, DA ve DE algoritmaları üstel ve hibrit modellerde daha başarılı olmuştur. Ayrıca sonuçlar aynı veri kümesindeki makine öğrenimi / yapay zekâ tabanlı modellerin tahmin sonuçlarıyla da karşılaştırılmıştır. Bu

sonuçlara göre optimizasyon tabanlı tahmin algoritmaları ile tahmin hatalarının azaldığını gösterilmiştir.

Uçak ekipmanları arıza sayılarının tahminine yönelik bu çalışma genel olarak değerlendirildiğinde, kullanıma bağlı olarak malzeme ve ekipmanın arıza sıklığının belirlenebilmesi ve bakım birimlerinde yer alan personellerin bakım planlama değişikliği, malzeme ihtiyaç planlaması, malzeme seçimi konularında öngörude bulunmasına yardımcı olacaktır. Belirli bir periyotta daha az sayıda arızalanan ekipmanların bakım sıklığının azaltılarak bakım maliyetlerinin düşürülmesine, daha yüksek sayıda arızalanan ekipmanların ise bakım sıklığının artırılarak faal kalma süresinin artırılmasına yardımcı olabileceği öngörülmektedir.



KAYNAKÇA

- 1991, IEEE Standard Computer Dictionary. A Compilation of IEEE Standard Computer Glossaries, p.
- 2015, Optimum maintenance strategy under uncertainty in the lifetime distribution, *Reliability Engineering and System Safety*, 133, 59--67.
- 2016, A framework to estimate the cost of No-Fault Found events, *International Journal of Production Economics*, 173, 207--222.
- Ahmed, A. S., Attia, M. A., Hamed, N. M. ve Abdelaziz, A. Y., 2017, Modern optimization algorithms for fault location estimation in power systems, *Engineering science and technology, an international journal*, 20 (5), 1475-1485.
- Altay, A., Ozkan, O. ve Kayakutlu, G., 2014, Prediction of Aircraft Failure Times Using Artificial Neural Networks and Genetic Algorithms, *Journal of Aircraft*, 51 (1), 47-53.
- Arno, R. a. D. N. a. S. R., 2015, Equipment failure characteristics and RCM for optimizing maintenance cost.
- Baptista, M. a. S. S. a. d. M. I. P. a. N. C. a. P. H. a. H. E. M. P., 2018, Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling, *Computers and Industrial Engineering*, 115, 41--53.
- Bazargan, M., 2015, An optimization approach to aircraft dispatching strategy with maintenance cost - A case study, *Journal of Air Transport Management*, 42, 10--14.
- Benkedjouh, T., Medjaher, K., Zerhouni, N. ve Rechak, S., 2013, Remaining useful life estimation based on nonlinear feature reduction and support vector regression, *Engineering Applications of Artificial Intelligence*, 26 (7), 1751-1760.
- Braglia, M. a. C. G. a. F. M. a. Z. F., 2012, Data classification and MTBF prediction with a multivariate analysis approach, *Reliability Engineering and System Safety*, 97 (1), 27--35.
- Bunea, C. a. M. T. A. a. S. S. a. C. H. C., 2008, Application of modern reliability database techniques to military system data, *Reliability Engineering and System Safety*.
- Buyukyildiz, M. ve Kumcu, S. Y., 2017, An estimation of the suspended sediment load using adaptive network based fuzzy inference system, support vector machine and artificial neural network models, *Water resources management*, 31 (4), 1343-1359.
- Chang, M. a. L. J., 2020, Early stage data-based probabilistic wear life prediction and maintenance interval optimization of driving wheels, *Reliability Engineering and System Safety*, 197.
- Chen, J. a. C. J. a. Z. X., 2008, MTBF-oriented prediction model for airborne equipment reliability based on SOM, 3660--3663.
- Cortes, C. ve Vapnik, V., 1995, Support-vector networks, *Machine learning*, 20 (3), 273-297.
- Cura, T., 2008, Modern sezgisel teknikler ve uygulamaları, Papatya Yayıncılık Eğitim, p.
- Daniewski, K. a. K. E. a. M. D., 2018, Analysis of the Correctness of Determination of the Effectiveness of Maintenance Service Actions., *Management & Production Engineering Review (MPER)*, 9 (2), 20--25.
- das Chagas Moura, M., Zio, E., Lins, I. D. ve Drogue, E., 2011, Failure and reliability prediction by support vector machines regression of time series data, *Reliability Engineering & System Safety*, 96 (11), 1527-1534.

- Din, I. U., Guizani, M., Hassan, S., Kim, B.-S., Khan, M. K., Atiquzzaman, M. ve Ahmed, S. H., 2018, The Internet of Things: A review of enabled technologies and future challenges, *Ieee Access*, 7, 7606-7640.
- Din, I. U., Guizani, M., Rodrigues, J. J., Hassan, S. ve Korotaev, V. V., 2019, Machine learning in the Internet of Things: Designed techniques for smart cities, *Future Generation Computer Systems*, 100, 826-843.
- DoD, 1998, MIL-HDBK-338B Electronic Reliability Design Handbook, October, p.
- Duarte, D., Marado, B., Nogueira, J., Serrano, B., Infante, V. ve Moleiro, F., 2016, An overview on how failure analysis contributes to flight safety in the Portuguese Air Force, *Engineering Failure Analysis*, 65, 86-101.
- Durgabai, R. ve Bhushan, Y. R., 2014, Feature selection using ReliefF algorithm, *International Journal of Advanced Research in Computer and Communication Engineering*, 3 (10), 8215-8218.
- Elerath, J. G. a. P. M., 2012, IEEE 1413: A standard for reliability predictions, *IEEE Transactions on Reliability*, 61 (1), 125--129.
- Elmas, Ç., 2016, Yapay zeka uygulamaları:(yapay sinir ağı, bulanık mantık, sinirsel bulanık mantık, genetik algoritma), Seçkin Yayıncılık, p.
- Fahad, S. A. ve Alam, M. M., 2016, A modified K-means algorithm for big data clustering, *International Journal of Science, Engineering and Computer Technology*, 6 (4), 129.
- Fan, Q. ve Fan, H., 2015, Reliability analysis and failure prediction of construction equipment with time series models, *Journal of Advanced Management Science Vol*, 3 (3).
- Garmabaki, A. H. S. a. A. A. a. B. J. a. P. H. a. K. U., 2016, A reliability decision framework for multiple repairable units, *Reliability Engineering and System Safety*, 150, 78--88.
- Glover, F., Laguna, M. ve Martí, R., 2000, Fundamentals of scatter search and path relinking, *Control and cybernetics*, 29 (3), 653-684.
- Grbz, F. a. z. L. a. Y. H., 2011, Data mining and preprocessing application on component reports of an airline company in Turkey, *Expert Systems with Applications*, 38 (6), 6618--6626.
- Guo, J. a. L. Z. a. W. J., 2016, Reliability centered preventive maintenance optimization for aircraft indicators, 2016-April.
- Gürbüz, F., 2009, Havacılık sektöründe veri madenciliği ile farklı sınıflandırma tekniklerinin karşılaştırmalı olarak uygulanması, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*.
- Gürbüz, H. ve Cömert, E., 2012, Bakım planlama faaliyetlerinde tamsayı doğrusal programlama ve bir uygulama, *Karadeniz Sosyal Bilimler Dergisi*, 4 (7), 101-122.
- Hakli, H. ve Ortacay, Z., 2019, An improved scatter search algorithm for the uncapacitated facility location problem, *Computers & Industrial Engineering*, 135, 855-867.
- Hockley, C. a. L. L., 2017, A Research Study of no Fault Found (NFF) in the Royal Air Force, 59, 263--267.
- Hsu, H.-H. ve Hsieh, C.-W., 2010, Feature Selection via Correlation Coefficient Clustering, *JSW*, 5 (12), 1371-1377.
- Hu, C. a. Z. Z. a. Z. J. a. S. X., 2015, A survey on life prediction of equipment, *Chinese Journal of Aeronautics*.
- Inan, K. C. a. H. U. a. O., 2020, Failure Prediction of Aircraft Equipment using Machine Learning with Hybrid Data Preparation Method, *Hindawi Scientific Programming*, In press.

- Jan, B., Farman, H., Khan, M., Talha, M. ve Din, I. U., 2019, Designing a smart transportation system: An Internet of things and big data approach, *IEEE Wireless Communications*, 26 (4), 73-79.
- Jeon, J. a. S. S. Y., 2015, Product failure pattern analysis from warranty data using association rule and Weibull regression analysis: A case study, *Reliability Engineering and System Safety*, 133, 176--183.
- Jun, L. a. H. X., 2012, Reliability Analysis of Aircraft Equipment Based on FMECA Method, *Physics Procedia*, 25, 1816--1822.
- Keivanpour, S. a., 2015, A sustainable approach to Aircraft Engine Maintenance, 28 (3), 977--982.
- Khan, S., 2015, Maintenance Requirements in Aerospace Systems, 38, 100--105.
- Khan, S. a. F. M. a. E. J., 2017, A novel approach for No Fault Found decision-making, *CIRP Journal of Manufacturing Science and Technology*, 17, 18--31.
- Khan, S. a. G. C. a. F. M., 2018, Evaluating diagnostic failures during system design, *CIRP Journal of Manufacturing Science and Technology*, 21, 97--109.
- Khan, S. a. P. P. a. H. C. a. J. I., 2014a, No Fault Found events in maintenance engineering Part 2: Root causes, technical developments and future research. 123: 196--208.
- Khan, S. a. P. P. a. J. I. a. H. C., 2014b, No Fault Found events in maintenance engineering Part 1: Current trends, implications and organizational practices. 123: 183--195.
- Kira, K. ve Rendell, L. A., 1992, A PRACTICAL APPROACH TO FEATURE-SELECTION, *Machine Learning* /, 249-256.
- Kira, K., Rendell, L. A. ve Amer Assoc Artificial, I., 1992, THE FEATURE-SELECTION PROBLEM - TRADITIONAL METHODS AND A NEW ALGORITHM, *Aaai-92 Proceedings : Tenth National Conference on Artificial Intelligence*, 129-134.
- Kiureghian, A. D., Ditlevsen, O. D. ve Song, J., 2007, Availability, reliability and downtime of systems with repairable components, *Reliability Engineering & System Safety*, 92 (2), 231-242.
- Kononenko, I., 1994, Estimating attributes: analysis and extensions of RELIEF, *European conference on machine learning*, 171-182.
- Kozik, P., 2012, Aircraft engine overhaul demand forecasting using ANN, *Management and Production Engineering Review*, 3 (2), 21--26.
- Kutyowska, M., 2015, Neural network approach for failure rate prediction, *Engineering Failure Analysis*, 47, 41--48.
- Lan, T. S., Chen, P. C., Wang, M. Y., Hsu, K. S., Chen, T. Y. ve Ieee, 2016, A Study of Using Back-Propagation Network to Predict Aircraft Component Life Span, *Proceedings of 2016 International Conference on Applied System Innovation (Icasi)*.
- MacQueen, J., 1967, Some methods for classification and analysis of multivariate observations, *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, 281-297.
- Martí, R., Laguna, M. ve Glover, F., 2006, Principles of scatter search, *European Journal of operational Research*, 169 (2), 359-372.
- Mia, M. M. A., Biswas, S. K., Urmi, M. C. ve Siddique, A., 2015, An algorithm for training multilayer perceptron (MLP) for Image reconstruction using neural network without overfitting, *International Journal of Scientific & Technology Research*, 4 (02), 271-275.
- Morelli, M. L., 2016, From prediction to prevention: The transition away from MTBF, 2016-April.
- Nguyen, D. Q. a. B. M., 2008, Optimization of preventive maintenance scheduling in processing plants, *Computer Aided Chemical Engineering*, 25, 319--324.

- Oladokun and, S., 2010, Predicting mean time between failures of a maintained equipment using artificial neural network, *American Journal of Scientific and Industrial Research*, 1 (3), 500--503.
- Ossmann, D., 2014, Optimization based tuning of fault detection and diagnosis systems for safety critical systems, *IFAC Proceedings Volumes*, 47 (3), 8570-8575.
- Öztemel, E., 2003, Yapay sinir ağları, *PapatyaYayincılık, Istanbul*.
- Papakostas, N. a. P. P. a. X. V. a. M. D. a. C. G., 2010, An approach to operational aircraft maintenance planning, *Decision Support Systems*, 48 (4), 604--612.
- Ramos, P. a. O. J. M. a. S. P., 2014, Predictive maintenance of production equipment based on neural network autoregression and ARIMA, *21st International EurOMA Conference - Operations Management in an Innovation Economy*, 1--10.
- Rosario, S. F. ve Thangadurai, K., 2015, RELIEF: feature selection approach, *International journal of innovative research and development*, 4 (11), 218-224.
- Schuld, M., Sinayskiy, I. ve Petruccione, F., 2016, Prediction by linear regression on a quantum computer, *Physical Review A*, 94 (2), 022342.
- Storn, R. ve Price, K., 1997, Differential evolution--a simple and efficient heuristic for global optimization over continuous spaces, *Journal of global optimization*, 11 (4), 341-359.
- Taşkın, Ç. ve Emel, G. G., 2009, Sayısal yöntemlerde genetik algoritmalar, Alfa Aktüel, p.
- Torell, B. W. a. A. V., 2011, Mean Time Between Failure : Explanation and Standards - White Paper 78, 10.
- Trani, A., Wing-Ho, F., Schilling, G., Baik, H. ve Seshadri, A., 2004, A neural network model to estimate aircraft fuel consumption, *AIAA 4th Aviation Technology, Integration and Operations (ATIO) Forum*, 6401.
- Tuo, S. a. Z. J. a. Y. X. a. Y. L., 2018, A new differential evolution algorithm for solving multimodal optimization problems with high dimensionality, *Soft Computing*, 22 (13), 4361--4388.
- Ungar, L. Y., 2015, Causes and Costs of No Fault Found Events.
- Uzun, A. ve Özdoğan, A., 2011, Güvenirlilik Analizlerine Dayalı Önleyici Bakım Planlanması, *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 20 (1), 303-320.
- Wijk, O. a. A. P. a. B. J. a. R. T., 2017, Phase-out maintenance optimization for an aircraft fleet, *International Journal of Production Economics*, 188, 105--115.
- Yang, Z. ve Yang, G., 2012, Optimization of aircraft maintenance plan based on genetic algorithm, *Physics Procedia*, 33, 580-586.
- Yilmaz, N., Inan, O. ve Uzer, M. S., 2014, A new data preparation method based on clustering algorithms for diagnosis systems of heart and diabetes diseases, *J Med Syst*, 38, 48-59.
- Zhao, Z. a. a. W. X. a. L. W., 2017, Remaining useful life prediction of aircraft engine based on degradation pattern learning, *Reliability Engineering and System Safety*, 164, 74--83.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Kadir ÇELİKMIH
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Konya - 01/01/1977
Telefon : 0533 324 06 34
E-mail : kcelikmih@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	Özel Diltaş Lisesi, Selçuklu, KONYA	1994
Üniversite	İstanbul Teknik Üniversitesi – Kontrol ve Bilgisayar Müh. Maslak, İSTANBUL	1998
Yüksek Lisans	İstanbul Teknik Üniversitesi – Kontrol ve Bilgisayar Müh. Maslak, İSTANBUL	2002

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
Mayıs 1999 – Ekim 2007	Detay Danışmanlık	Sap Abap Danışmanı
Şubat 2007 – Aralık 2009	Serbest Danışman	Sap Abap Danışmanı
Temmuz 2010 – Mayıs 2013	Havelsan A.Ş.	Sap Yazılım Müh.
Mayıs 2013 – Temmuz 2019	Havelsan A.Ş.	Abap Takım Lideri
Temmuz 2019 – Devam	Havelsan A.Ş.	Proje Yöneticisi

BELİRTMEK İSTEDİĞİNİZ DİĞER ÖZELLİKLER

Bu tez çalışması bilimsel araştırma projesi olarak Havelsan ve Kategori-C seviyesinde Savunma Sanayi Başkanlığı -SSB tarafından desteklenmiştir. Proje no: HVL-SÖZ-18/033.

YAYINLAR

1. Celikmih, K., Uguz H., Inan O. Failure Prediction of Aircraft Equipment using Machine Learning with Hybrid Data Preparation Method. *Hindawi Scientific Programming*, 2020, In Press.

BİLDİRİ

1. Celikmih, K., Feature Selection of Maintenance Data and Failure Prediction With Artificial Neural Network, The 4th International Aviation Management Conference (Universiy of Turkish Aeronautical Association) Ankara, October 2019

