



**YAPAY SİNİR AĞLARINA DAYALI UÇAK ALGILAYICI
ARIZASI TESPİTİ VE SİSTEMİN YENİDEN
YAPILANDIRILMASI**

Doktora Tezi

Uğur KILIÇ

Eskişehir 2021

**YAPAY SİNİR AĞLARINA DAYALI UÇAK ALGILAYICI ARIZASI TESPİTİ
VE SİSTEMİN YENİDEN YAPILANDIRILMASI**

Uğur KILIÇ

Doktora Tezi

Havacılık Elektrik ve Elektronik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Gülay ÜNAL

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ağustos 2021

Bu tez çalışması BAP Komisyonu tarafından kabul edilen 20DRP050 no.lu proje kapsamında desteklenmiştir.

ÖZET

YAPAY SİNİR AĞLARINA DAYALI UÇAK ALGILAYICI ARIZASI TESPİTİ VE SİSTEMİN YENİDEN YAPILANDIRILMASI

Uğur KILIÇ

Havacılık Elektrik ve Elektronik Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ağustos 2021

Danışman: Dr. Öğr. Üyesi Gülay ÜNAL

Bu çalışmanın amacını, uçaklar için önem arz eden hava veri sisteminin bileşenleri olan hücum açısı, hız ve irtifa algılayıcılarında oluşabilecek bir arızanın yanlış alarm durumu olmayacak şekilde ve herhangi ek bir algılayıcı ölçümüne gerek kalmadan zamanında tespiti ve yeniden yapılandırılması oluşturmaktadır. Literatürde modern uçaklar için kullanılan arıza tespit ve yeniden yapılandırma sistemleri uçaklar üzerindeki asıl/yedekli algılayıcıların çoğunluğunun doğruluğuna dayanan çoğunluk oylama yöntemi ve ağırlıklı ortalama gibi yöntemleri kullanmaktadır. Donanım fazlalığına dayanan bu yöntemlerin kullanımı yerine tasarlanan analitik fazlalığa dayalı sistem ile ağırlık ve yakılan yakıttan tasarruf sağlanabilirken, hava aracı daha uzun mesafe yol alabilir ve bu sayede CO₂ emisyonu ve gürültünün azaltılmasıyla hava aracı daha çevre dostu uçuşlar gerçekleştirebilir. Ayrıca yedekli algılayıcıların çıkartılmasıyla hava aracının hava yolu şirketine ürettiği satın alma maliyeti ve ilgili parçaların daha az olmasıyla bakım maliyetleri de azaltılabilir. İlgili sistemin tasarımı için yerel bir havayolundan alınan gerçek uçuş verileri kullanılmıştır. Hücum açısı, hız ve irtifa algılayıcılarıyla alakalı verilerin seçimi için korelasyon analizi kullanılmıştır. Arızanın tespiti ve yeniden yapılandırılmasında makine öğrenmesine dayalı yöntemler kullanılmıştır. İlgili işlemler için MATLAB programı kullanılmıştır. Hücum açısı, hız ve irtifa algılayıcılarında oluşabilecek arıza durumları modellenmiştir ve tüm uçuş fazlarında karşılaşılabilecek farklı arıza senaryoları incelenmiştir. Arıza tespiti 0-2 sn aralığında yanlış alarm olmadan gerçekleştirilmiştir. Arıza yeniden yapılandırılırken sistem çıktısının tahmin edilen algılayıcı verilerine göre seyretmesi sağlanmıştır.

Anahtar Sözcükler: Hava aracı algılayıcısı, Arıza tespiti, Yeniden yapılandırma, Makine öğrenmesi.

ABSTRACT

AIRCRAFT SENSOR FAULT DETECTION AND SYSTEM RECONSTRUCTION BASED ON ARTIFICIAL NEURAL NETWORKS

Uğur KILIÇ

Department of Avionics

Eskişehir Technical University, Institute of Graduate Programs, August 2021

Supervisor: Asst. Prof. Dr. Gülay ÜNAL

The purpose of this study is to detect and reconstruct a fault that may occur in the angle of attack, airspeed and altitude sensors, which are important components of the air data system for aircrafts, in a timely intervention without the need for any additional sensor measurement and without a false alarm. Fault detection and reconstruction systems used for modern aircrafts in the literature are methods such as majority voting and weighted mean based on the majority accuracy of the primary/redundant sensors on the aircrafts. Instead of using these methods based on hardware redundancy, by the designed analytical redundant system, while saving weight and fuel burned, the aircraft can travel longer distances and thereby reducing CO₂ emissions and noise, the aircraft can perform more environmentally friendly flights. In addition, with the removal of the redundant sensors, the purchase cost of the aircraft to the airline company and the maintenance costs of the related parts can be reduced. The real flight data of a commercial aircraft collected from a local airline were used for the system design. Correlation analysis was used to select data related to the angle of attack, airspeed and altitude sensors. Machine learning-based methods were used to detect and reconstruct the fault. MATLAB program was used for the related operations. The fault situations that may occur in the angle of attack, airspeed and altitude sensors were modeled and different fault scenarios that can be encountered in all flight phases were examined. Fault detection was performed in the range of 0-2 s without false alarms. While reconstructing the fault, it is ensured that the system output follows the estimated sensor data.

Keywords: Aircraft sensor, Fault detection, Reconstruction, Machine learning.

TEŞEKKÜR

Doktora tez çalışmam boyunca benden desteklerini esirgemeyen ve yol gösteren Sayın Dr. Öğretim Üyesi Gülay ÜNAL'a çok teşekkür ediyorum. Umarım bilime az da olsa katkı sağlayabilmişizdir. Ayrıca Tez İzleme Komitesi'nde bulunan ve benden yardımlarını esirgemeyen Sayın Doç. Dr. Emre KIYAK ve Sayın Dr. Öğretim Üyesi Hasan Serhan YAVUZ'a çok teşekkür ediyorum.

Her zaman yanımda olan canım eşime ve aileme de çok teşekkür ediyorum ve tezimi canım eşime ithaf ediyorum.

Uğur KILIÇ



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Uğur KILIÇ

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vi
İÇİNDEKİLER	vii
TABLOLAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xiv
1. GİRİŞ.....	1
1.1. Literatür Taraması	4
1.2. Bazı Hava Araçları Kazaları ve Sisteme Olan İhtiyaç	10
2. ARIZA TESPİTİ VE KORELASYON ANALİZİ	12
2.1. Arıza Tespit Sisteminin Genel Yapısı.....	12
2.2. Özellik Çıkarımı ve Korelasyon Analizi	14
2.3. Korelasyon Katsayılarının Elde Edilmesi.....	17
3. YAPAY SİNİR AĞLARI YÖNTEMLERİ İLE SİSTEM EĞİTİMİ	19
3.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ile Eğitim	20
3.2. Yapay Sinir Ağları ile Eğitim.....	24
3.2.1. Hücum açısı için yapay sinir ağları ile eğitim	26
3.2.2. Hız için yapay sinir ağları ile eğitim	32
3.2.3. İrtifa için yapay sinir ağları ile eğitim	39

4. YAPAY SİNİR AĞLARI KULLANARAK GERÇEK UÇUŞ VERİLERİNE DAYALI ARIZA TESPİTİ VE SİSTEMİN YENİDEN YAPILANDIRILMASI ..	47
5. TARTIŞMALAR	62
6. SONUÇLAR.....	64
KAYNAKÇA.....	65
ÖZGEÇMİŞ	



TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1. Uçuşa ait bazı bilgiler	15
Tablo 2.2. Hücüm açısı için korelasyon katsayıları	17
Tablo 2.3. Hız için korelasyon katsayıları	18
Tablo 2.4. İrtifa için korelasyon katsayıları	18
Tablo 3.1. Hücüm açısı algılayıcısı için üyelik fonksiyonları tahmin hatası değerleri .	23
Tablo 3.2. Hız algılayıcısı için üyelik fonksiyonları tahmin hatası değerleri	23
Tablo 3.3. İrtifa algılayıcısı için üyelik fonksiyonları tahmin hatası değerleri	24
Tablo 3.4. Alakalı verilere göre hücüm açısı verisinin tahmini için RMSE ve ağ eğitim süreleri	30
Tablo 3.5. Hücüm açısı algılayıcısı için analiz yöntemlerinin karşılaştırılması	30
Tablo 3.6. Alakalı verilere göre hız verisinin tahmini için RMSE ve ağ eğitim süreleri	37
Tablo 3.7. Hız algılayıcısı için analiz yöntemlerinin karşılaştırılması	37
Tablo 3.8. Alakalı verilere göre irtifa verisinin tahmini için RMSE ve ağ eğitim süreleri	44
Tablo 3.9. İrtifa algılayıcısı için analiz yöntemlerinin karşılaştırılması	44
Tablo 4.1. Hücüm açısı algılayıcısı için modellenen arızalar	48
Tablo 4.2. Hız algılayıcısı için modellenen arızalar	52
Tablo 4.3. İrtifa algılayıcısı için modellenen arızalar	57

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Sisteme ait blok diyagram	13
Şekil 3.1. ANFIS yapısı	21
Şekil 3.2. Yapay sinir ağı yapısı	25
Şekil 3.3. En alakalı verilere göre hücum açısı için yapay sinir ağı yapısı	26
Şekil 3.4. En alakalı verilere göre hücum açısı gizli katman 4 nöron için regresyon eğrileri	27
Şekil 3.5. En alakalı verilere göre hücum açısı gizli katman 8 nöron için regresyon eğrileri	27
Şekil 3.6. Alakalı verilere göre hücum açısı için yapay sinir ağı yapısı	28
Şekil 3.7. Alakalı verilere göre hücum açısı gizli katman 3 nöron için regresyon eğrileri	29
Şekil 3.8. Alakalı verilere göre hücum açısı gizli katman 9 nöron için regresyon eğrileri	29
Şekil 3.9. Alakalı verilere göre hücum açısı gizli katman 18 nöron için regresyon eğrileri	30
Şekil 3.10. Hücum açısı için box ve whisker çizimleri	31
Şekil 3.11. Gerçek ve tahmin edilen hücum açısı değerleri ile aralarındaki farkın mutlak değeri	32
Şekil 3.12. En alakalı verilere göre hava hızı için yapay sinir ağı yapısı	33
Şekil 3.13. En alakalı verilere göre hava hızı gizli katman 4 nöron için regresyon eğrileri	33
Şekil 3.14. En alakalı verilere göre hava hızı gizli katman 8 nöron için regresyon eğrileri	34

Şekil 3.15. Alakalı verilere göre hava hızı için yapay sinir ağı yapısı	35
Şekil 3.16. Alakalı verilere göre hava hızı gizli katman 3 nöron için regresyon eğrileri	36
Şekil 3.17. Alakalı verilere göre hava hızı gizli katman 7 nöron için regresyon eğrileri	36
Şekil 3.18. Alakalı verilere göre hava hızı gizli katman 14 nöron için regresyon eğrileri	37
Şekil 3.19. Hız için box ve whisker çizimleri	38
Şekil 3.20. Gerçek ve tahmin edilen hız değerleri ile aralarındaki farkın mutlak değeri	39
Şekil 3.21. En alakalı verilere göre irtifa için yapay sinir ağı yapısı	40
Şekil 3.22. En alakalı verilere göre irtifa gizli katman 3 nöron için regresyon eğrileri .	40
Şekil 3.23. En alakalı verilere göre irtifa gizli katman 6 nöron için regresyon eğrileri .	41
Şekil 3.24. Alakalı verilere göre irtifa için yapay sinir ağı yapısı	42
Şekil 3.25. Alakalı verilere göre irtifa gizli katman 3 nöron için regresyon eğrileri	43
Şekil 3.26. Alakalı verilere göre irtifa gizli katman 9 nöron için regresyon eğrileri	43
Şekil 3.27. Alakalı verilere göre irtifa gizli katman 18 nöron için regresyon eğrileri ...	44
Şekil 3.28. İrtifa için box ve whisker çizimleri	45
Şekil 3.29. Gerçek ve tahmin edilen irtifa değerleri ile aralarındaki farkın mutlak değeri	46
Şekil 4.1. Hücüm açısı algılayıcısı için bias tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması.....	50
Şekil 4.2. Hücüm açısı algılayıcısı için osilasyon tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması.....	50

Şekil 4.3. Hücüm açısı algılayıcısı için NRZ tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması.....	51
Şekil 4.4. Hücüm açısı algılayıcısı için sürüklenme tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	51
Şekil 4.5. Hücüm açısı algılayıcısı için gürültü tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması.....	52
Şekil 4.6. Hız algılayıcısı için bias tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	54
Şekil 4.7. Hız algılayıcısı için osilasyon tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	54
Şekil 4.8. Hız algılayıcısı için son değerde takılma tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	55
Şekil 4.9. Hız algılayıcısı için sıfırda takılma tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması.....	55
Şekil 4.10. Hız algılayıcısı için NRZ tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	56
Şekil 4.11. Hız algılayıcısı için gürültü tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	56
Şekil 4.12. İrtifa algılayıcısı için son değerde takılma tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	58
Şekil 4.13. İrtifa algılayıcısı için osilasyon tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	59
Şekil 4.14. İrtifa algılayıcısı için NRZ tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	59

Şekil 4.15. İrtifa algılayıcısı için bias tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	60
Şekil 4.16. İrtifa algılayıcısı için sürüklenme tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması.....	60
Şekil 4.17. İrtifa algılayıcısı için gürültü tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması	61



SİMGELER VE KISALTMALAR DİZİNİ

ADC	: Air Data Computer
ADIRU	: Air Data Inertial Reference Unit
ADM	: Air Data Module
ANFIS	: Adaptive-Network Based Fuzzy Inference Systems
ANN	: Artificial Neural Network
ASE	: Altimetry System Error
BUSS	: Backup Speed Scale
CAS	: Calibrated Air Speed
E	: Beklenen Değer
EAS	: Equivalent Air Speed
EFCS	: Electronic Flight Control System
$f(k)$	: Arıza Modeli
FAA	: Federal Aviation Administration
g	: Yerçekimi İvmesi (m/sn^2)
GPS	: Global Positioning System
h	: İrtifa (ft)
IAS	: Indicated Air Speed
IDG	: Integrated Drive Generator
i	: Boole Değişkeni
j	: Alt İndis
k	: İndis
MLP	: Multi Layer Perceptron
n	: Toplam Veri Sayısı
N11	: Motor N1 Şaftı Devri
N12	: Motor N2 Şaftı Devri
NRZ	: Non-Return to Zero
p	: Korelasyon Katsayısı
PCA	: Principal Component Analysis
PLI	: Pitch Limit Indicator
$r(k)$	: Rezidü Değeri
R	: Gaz Sabiti (J/kgK)

RMSE	: Root Mean Square Error
RVSM	: Reduced Vertical Separation Minimum
SAS	: Synthetic Air Speed
SAT	: Static Air Temperature
SSE	: Static Source Error
SVM	: Support Vector Machine
t	: Zaman (sn)
T_0	: Deniz Seviyesi Sıcaklık Değeri (K)
TAS	: True Air Speed
TAT	: Total Air Temperature
w	: Ağırlık Değerleri
y_j	: İncelenen Değişkenin j . Gerçek Değeri
$\hat{y}_j$	: İncelenen Değişkenin j . Tahmin Değeri
$Y(k)$	: Arızalı Sistem Verileri
$\hat{y}(k)$	: Tahmin Edilen Sistem Verileri
$y(k)$	: Arızasız Sistem Verileri
α_c	: Birleştirilmiş Hücüm Açısı Bilgisi (deg)
$\bar{\alpha}$	: Sol, Sağ ve Yedekli Hücüm Açısı Ölçüm Sinyalini İçeren Vektör (deg)
α_k	: İlgili Hücüm Açısı Verisi (deg)
$\mathcal{E}_1$	: Filtrelenmemiş Rezidü Sinyali için Kullanılan Eşik Değeri
$\mathcal{E}_2$	: Filtrelenmiş Rezidü Sinyali için Kullanılan Eşik Değeri
μ	: Ortalama Değeri
ρ_0	: Deniz Seviyesindeki Yoğunluk Değeri (kg/m^3)
ρ	: İlgili İrtifadaki Yoğunluk Değeri (kg/m^3)
σ	: Standart Sapma Değeri
φ	: Bağlı Yoğunluk Değeri

1. GİRİŞ

Sistemlerde oluşan arızalar zamanında tespit ve teşhis edilip gerekli önlemler alınmazsa, bu arızalar ilgili sistemlerde büyük sorunlara yol açabilmektedir. Uçuş kontrol sistemlerinde de uçak algılayıcı, eyleyici ve kontrol yüzeylerinde oluşabilecek bir arıza durumu için gerekli önlemler alınmazsa, bu sistemlerde de istenmeyen sonuçlar doğabilmektedir. Arıza tespiti, izlenen sistemdeki arızanın oluşumunu belirler ve farklı ölçülebilir sinyaller arasındaki bağlantıların kullanılarak süreçlerdeki arızaların tespit edilmesinden oluşur. Ayrıca arıza ayırımı ve arıza tanımlama süreçleri de bu süreçle ilişkilidir. Arıza ayırımı, arızanın yerini ve türünü belirlerken, arıza tanımlama ise arızanın büyüklüğünü belirlemektedir. Arıza ayırımı ve arıza tanımlaması birlikte arıza teşhisi olarak adlandırılır. Arıza teşhisi, arızanın türünün belirlenmesi, arıza büyüklüğü, yeri ve tespit süresi gibi mümkün olduğunca fazla ayrıntıya sahip bir süreçtir. Arıza tespiti çeşitli yollar ve yöntemlerle gerçekleştirilebilmektedir. Bu yöntemler sadece bir süreç değişkeni değil, aynı zamanda süreç durumu, parametreler ve karakteristik büyüklükler gibi ölçülebilir olmayan değişkenleri de kapsamaktadır. Bazı yöntemler doğru süreç modelleri gerektirirken, diğerleri öncelikli olarak mevcut tarihsel süreç verilerine dayanır (Isermann, 2005; 2006; Castillo and Edgar, 2008).

Hava araçlarında önleyici ve düzeltici bakım dediğimiz bakım programları bulunmaktadır. Önleyici bakım, arıza durumu oluşmadan önce hava aracının düzenli olarak bakıma alınmasını sağlayan bir programlı bakımdır. Ömürlü elemanlar varsa bunların değiştirilmesi ve düzenli olarak çalışma aralıklarının kontrol edilip uçuşa elverişliliğin sağlanması önleyici bakım kapsamındadır. Düzeltici bakım hava aracında beklenmeyen bir arıza meydana geldiğinde bu arızaların düzeltilmesi amacıyla yapılan programsız bakımlardır. Yıldırım çarpması, sert iniş, kuş çarpması veya hava aracı elemanlarında oluşabilecek herhangi bir arıza, düzeltici bakım kapsamındadır (Carbaugh, Forsythe and McIntyre, 1999). Literatürde modern uçaklar için kullanılan arıza tespit ve teşhis sistemleri, uçaklar üzerindeki asıl/yedekli algılayıcıların çoğunluğunun doğruluğuna dayanan çoğunluk oylama yöntemi ve ağırlıklı ortalama gibi yöntemleri kullanmaktadır. Ancak bu yöntemlerin kullanımı nedeniyle uçuş ekibine hatalı algılayıcı bilgisi verilebilmektedir. Hava araçları için genel olarak bir arıza tespit ve yeniden yapılandırma sisteminin olmadığı ve uçuş ekibinin bu arızalara karşı zamanında uyarılmadığı ve uçuş ekibinin arızanın etkisini azaltacak gerekli işlemleri zamanında yapamadığı görüldüğünden dolayı, bütün bu işlemleri sağlayabilecek genel

bir arıza tespit ve yeniden yapılandırma sisteminin tasarımı ile ilgili hava araçlarının algılayıcı arızasından dolayı düşmesinin önüne geçilmeye çalışılması bu çalışmanın çıkış noktasını oluşturmuştur. Bu çalışmada uçaklar için önem arz eden ve hava veri sisteminin bileşenleri olan hücum açısı algılayıcısı, hız algılayıcısı ve irtifa algılayıcısının arızalanması durumunda bu arızaların tespiti ve zamanında müdahalesi konuları ele alınmıştır.

Hücum açısı verisi uçağın stall (uçağın havada tutunamaması durumu) durumuna karşı kontrolünü sağlamaktadır. Ayrıca, ticari uçaklarda kullanılan hücum açısı algılayıcıları “Stall Warning, Stall Margin Information on Airspeed Indicators ve Pitch Limit Indicator (PLI)” gibi sistemleri sürmektedir. Hız verisi, kontrol parametrelerini etkilediğinden dolayı uçağın kararlılığının kontrolünü sağlamaktadır. İrtifa verisi ile uçağın yerden yüksekliği ölçülürken aynı zamanda tırmanma ve alçalma oranını belirleyen dikey hız göstergesine de veri sağlanmaktadır. İrtifa bilgisi hava trafik kontrol birimine de gönderildiğinden radar ekranı için önem arz eden bir parametredir. İlgili algılayıcılarda oluşabilecek arızalar otomatik gaz kolu parametresini, hava hızı ve irtifa bilgisine dayanan diğer ekipmanları da etkilemektedir. Uçak üreticileri genel olarak uçaklarda hücum açısı için en az bir algılayıcı, hız için en az iki algılayıcıyı ve irtifa için de en az dört algılayıcıyı yedek olarak uçaklara eklemektedir. Bazı pitot tüplerinde (hava hızını ölçen algılayıcı) statik delikler (yüksekliği ölçen algılayıcı) bulunur. Bu delikler tüpün çevresinde bulunan küçük deliklerdir ve statik sisteme bağlanmaktadır. Tüm bu algılayıcı sistemine “Pitot Statik Prob” adı verilir ve aynı zamanda “Prandtl Tüp” adını da alır. Ölçülen statik basınç uçuş süresince gerçek basınç ile daima aynı değildir. Aradaki fark statik kaynak hatası (Static Source Error-SSE) adını alır. Statik portlarda ikişer adet kullanımının nedeni, statik kaynak hatasını en aza indirmek için yapılan bir düzeltme yöntemidir. Hava veri bilgisayarı (Air Data Computer-ADC) düzeltme faktörünü otomatik olarak hesaplar. Ayrıca ilgili uçaklarda portlardan alınan hava veri bilgilerini nümerik değerlere dönüştürüp hava verisi atalet referans ünitesi (Air Data Inertial Reference Unit-ADIRU) birimine gönderen 4 adet hava veri modülü (Air Data Module-ADM) bulunmaktadır (Collinson, 2003; Mako vd., 2020). Ancak, uçaklarda her bir algılayıcı için kaç yedekli eleman kullanılırsa kullanılsın herhangi bir buzlanma durumunda algılayıcıların hepsi hatalı değer gösterecektir. Kullanılan donanım fazlalığına rağmen uçaklarda algılayıcı kaynaklı kazalar ve arızalar fazlasıyla yaşanmıştır. Uçak üreticileri halihazırda sadece

uçak üzerindeki algılayıcıların ve yedeklerinin değerlerinin anlık olarak karşılaştırılması yoluyla algılayıcılar arasındaki uyumsuzluğu uçuş ekibine bildirmektedir. Uçuş ekibi böyle durumlarda belli prosedürlere bağlı kalarak veya diğer göstergeler ve veriler ile karşılaştırma yoluna giderek sorunun kaynağını bulmaya çalışmaktadır (Carbaugh, Forsythe and McIntyre, 1999). Uçaklarda arızasız durumda denklem 1.1’de görüldüğü üzere ağırlıklı ortalama tekniği ile çıkış tayin edilmektedir. Arıza durumunda ise bir algılayıcı bilgisi diğer ikisinden daha fazla değişiyorsa diğer iki algılayıcının ortalaması çıkışa verilmektedir. İlgili durum denklem 1.2’de görülmektedir. Ancak burada iki algılayıcı verisi hatalıysa bu durumda da hatalı durumlar çıkışa verilmektedir (Ossmann and Joos, 2016). Burada en iyi örneği 1 Haziran 2009 tarihindeki Air France 447 kazası vermektedir. Üç yedekli pitot prob sisteminde iki prob buzlanmıştır, bundan dolayı hatalı verilerin ortalaması çıkışa verilmiştir.

$$\alpha_c = \frac{1}{2} \text{median}(\bar{\alpha}) + \frac{1}{4} (\min(\bar{\alpha}) + \max(\bar{\alpha})) \quad (1.1)$$

$$\alpha_c = \frac{1}{2} \sum_{k=1}^3 \alpha_k i_k \quad (1.2)$$

Sonuç olarak yeni bir algılayıcı eklemek yerine, olan arızanın tespit edilmesi ve arızalı değerlerin olması gereken algılayıcı verilerine göre yeniden yapılandırılması daha avantajlı olacaktır. Bu sayede, uçuş ekibinin arızalı veriye göre uçmasının önüne geçilmiş olacaktır. Burada dikkat edilmesi gereken nokta, arızalı değerlerin yeniden yapılandırılması için kullanılan verilerin hiçbir yedekli elemandan gelmemesi ve diğer verilerden tahmin edilerek bulunmasıdır. İlk olarak korelasyon analizi ile hücum açısı, hız ve irtifa verileriyle alakalı olan veriler seçilmiştir. İlgili verilerden hareketle hücum açısı, hız ve irtifa verilerinin olması gereken değerleri tahmin edilmiştir. Tahmin kısmında makine öğrenmesine dayalı yöntemler olan uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağları (YSA) kullanılmıştır. Tasarlanan sistem ile donanım fazlalığı azaltılarak ağırlık ve üretim/bakım maliyetlerinden tasarruf sağlanabilir. Yakılan yakıtın daha az olması ile hava aracı daha uzun mesafe yol alabilir. Ayrıca yakıt tüketimi önemli bir sera gazı olan CO₂ emisyonunun doğrudan bir göstergesidir. Bu çalışmada tasarlanan sistem ile CO₂ emisyonu ve gürültünün azaltılmasıyla hava aracı daha çevre dostu uçuşlar gerçekleştirebilir. Ayrıca analitik

fazlalık olarak tasarlanacak sistemde yedekli algılayıcıların çıkartılmasıyla hava aracının hava yolu şirketine ürettiği satın alma maliyeti ve ilgili parçaların daha az olmasıyla bakım maliyetleri de azaltılabilir. Analitik yedekli sistem tasarımı ile yedekli donanımların kullanımına gerek kalmadan gerçek uçuş verilerine dayanarak hazırlanan bir arıza tespit ve yeniden yapılandırma sistemi oluşturulmuştur. Donanım fazlalığı yerine analitik olarak yapılacak hesaplamalar dahilinde, algılayıcı arızaları zamanında tespit edilebilecek ve uçuş ekibine arızalı bileşene alternatif olarak bir bilgi kaynağı sağlanacaktır. Bu şekilde uçuş ekibinin arızalı veriye göre uçmasının önüne geçilmiş olacaktır. Bu kapsamda bu çalışmada, hava araçları için bahsedilen eksiklikleri giderecek şekilde arızanın tespiti ve arızanın yeniden yapılandırılmasını hızlı, güvenilir, kararlı, birden fazla arıza karşısında doğru bir şekilde çalışabilen, zamanında müdahaleye ortam sağlayan ve bu işlemleri yüksek tespit oranı ve düşük yanlış alarm oranı ile gerçekleştirebilen bir sistemin hava araçları için gerçek zamanlı olarak tasarlanması amaçlanmıştır. Yapılan çalışmada problemin çözümü için yapay sinir ağları yöntemleri kullanılmıştır. Sistem tasarımı için yerel bir havayolundan alınan ticari uçaklara ait gerçek uçuş verileri kullanılmıştır. Toplam 36.550 adet giriş çıkış verisinin 25.585'i eğitim, 10.965'i test verisi olmak üzere rastgele olarak seçilmiştir. Hücum açısı, hız ve irtifa algılayıcılarında oluşabilecek arıza durumları modellenmiştir ve tüm uçuş fazlarında karşılaşılabilecek farklı arıza senaryoları incelenmiştir. İlk olarak korelasyon analizi yardımıyla ilgili algılayıcılarla ilişkili olan veriler seçilmiştir ve ilgili algılayıcılardan herhangi bir veri gelişi olmadan ve sadece ilişkili verilerden ilgili algılayıcıların olması gereken değerleri tahmin edilmiştir. Arıza bindirilmiş gerçek uçuş değerleri ile yapay sinir ağları yöntemleriyle tahmin edilen olması gereken uçuş değerleri arasındaki fark değerini oluşturan rezidü sinyalleri ise belirli bir eşik değerine göre değerlendirilerek arıza tespiti yapılmıştır. Arıza tespit edildikten sonra arızanın yeniden yapılandırılması kısmında arızalı algılayıcı değerlerinin tahmin edilen algılayıcı değerlerine göre seyretmesi sağlanmıştır. Bu şekilde analitik olarak görsel bir algılayıcı yapısı oluşturulmuştur.

1.1. Literatür Taraması

1990'ların başlarına kadar, arıza tespiti ile ilgili araştırma ve geliştirme çalışmaları, nükleer santraller, hava araçları, süreç tesisleri, otomobil endüstrisi ve savunma sanayi ile ilgiliydi. Ancak günümüzde arıza tespiti birçok sektörde

kullanılmaktadır. Başlıca uygulamaları: makineler ve motorlar, elektrik motorları, pompalar, buhar türbinleri, üretim, rulmanlar ve makinalar, hava araçları, otomotiv sistemleri, ısıtma, havalandırma, iklimlendirme ve kimyasal süreçlerdir (Miljković, 2011). Burada tezin konusunu oluşturan ve hava araçları ile ilgili çalışmalar incelenerek yapılmış olan bazı çalışmalar aşağıda verilmiştir:

Simani vd., (2006) arızalı verilerden elde edilen sinyallerin kullanılması amacıyla modellenen uçak için giriş algılayıcı arızalarının tespiti ve ayrımını gerçekleştirmişlerdir. Ayrıca farklı rezidü üretici tasarımlarını, ek arızaların olduğu durumlarda arıza teşhisi için çalışıp karşılaştırmışlardır.

Jaradat ve Langari (2009) çoklu arızaların olduğu durumlarda, çoklu algılayıcı füzyonu ve arıza tespiti için geleneksel bulanık kümelenme ve yapay bağışıklık sistemleri tabanlı olan verimli yeni hibrit bir yaklaşım önermişlerdir.

Hansen, Blanke ve Adrian (2010) küçük bir insansız hava aracının pitot tüpünde oluşabilecek arızaların, tespit olasılıklarını analiz etmişlerdir. Bir yerleşik GPS alıcısından ölçülen hız, motor gaz kolundan tahmin edilen hava hızı ve pitot tüpü tabanlı hava hızı gibi ek bilgilerin kullanımı ile elde edilen rezidü değerlerinin analizini gerçekleştirmişlerdir.

Freeman, Seiler ve Balas (2011) algılayıcılarda oluşan bir arıza durumunda arızayı bertaraf edebilmek için yedekli sistem yapısının kullanılmasından doğan ağırlık ve maliyet artımı durumlarına alternatif bir yöntem olarak, yedeksiz bir hava veri sisteminde oluşan arızaları tespit edebilmek için model tabanlı bir yaklaşım sunmuşlardır. Önerilen yaklaşım Goodrich Corporation tarafından sağlanan üretici verilerine dayanılarak modellenen bir hava veri sistemi ile NASA'nın Generic Transport Model uçağına uygulanmıştır.

Jing vd., (2011) uçak entegre sürücü jeneratörleri (IDG) için benzetim ve arıza tespitini gerçekleştirmişlerdir. Uçak entegre sürücü jeneratörünün çalışma prensibi analiz edilmiş ve benzetim sistemi Matlab programında hazırlanmıştır. Kısa zamanlı fourier dönüşümü (STFT) yöntemi kullanılarak arıza tespiti gerçekleştirilmiştir.

Shi vd., (2011) farklı arıza türlerinin arıza dalga formlarını içeren arıza karakteristiği veri tabanını, uçak motor ateşleme sisteminde oluşan arızaları teşhis etmek için birçok deneyle elde etmişlerdir.

Zhang vd., (2011) arızaların ve arıza nedenlerinin ilişkisini sezgisel olarak ifade edebilmek için B737NG uçak uçuş kontrol sistemi arıza verileri ve uzman

deneyimlerinin kullanımı ile birlikte bir bulanık sinir ağı (FNN) tabanlı arıza teşhis modeli sunmuşlardır.

Eykeren, Chu ve Mulder (2012a) hava aracı algılayıcıları için bir arıza tespit ve teşhis yöntemi önermişlerdir. Analitik yedeklik mantığına göre tasarlanan sistem, genişletilmiş kalman filtresinin (EKF) uyarlamalı bir formu kullanılarak tanıtılmıştır. Kullanılan EKF, hava aracının kinematik ilişkilerini kullanmaktadır ve mümkün olan mevcut ölçümlerden bir durum yeniden yapılandırmasını içermektedir.

Eykeren, Chu ve Mulder (2012b) kontrol yüzey eyleyicilerindeki arızaların tespit edilmesi için bir arıza tespit ve teşhis yöntemi önermişlerdir. Burada tanıtılan yöntem, arıza tespiti ve ayırımı sağlamak için uçağın dinamikleri bilgisini kullanmaktadır. Modelin parametreleri çevrimiçi olarak tanımlanmıştır ve bir arıza durumunda bu parametrelerde bir değişiklik gözlenmesi beklenmiştir. Yöntemin avantajı, farklı arıza türlerine karşı da uygulanabilmesidir.

Gao vd., (2012) uzay araçları için temel bileşen analizi (PCA) ve destek vektör makineleri (SVM) temelli olan yeni bir arıza tespit ve teşhis yaklaşımı sunmuşlardır.

Zhao vd., (2013) hava aracı navigasyon sistemi arıza tespiti için analitik olmayan modele dayalı çevrimiçi bir yöntem önermişlerdir. Sistemde rezidü ölçümü ve değişim oranı kural tabanlı sistemin girişleri iken, arıza tespit fonksiyonu da kural tabanlı sistemin çıkışı olarak alınmıştır.

Varga, Ossmann ve Joos (2014) hücum açısı ve / veya kalibre edilmiş hava hızı algılayıcılarının kısmi veya toplam kayıplarını barındırabilen sivil bir hava aracı için bir entegre arıza teşhisi tabanlı arıza toleranslı kontrol sistem mimarisi yaklaşımı önermişlerdir.

Azzawi vd., (2015) biyolojik dendritik hücrelerin işlevselliği ve bunların bağışıklık sisteminin çeşitli bileşenleri ile etkileşimlerine dayanan hava aracı alt sistemlerinde oluşan arızanın tespiti, tanımlanması ve değerlendirilmesi için entegre yeni bir yöntem sunmuşlardır. Önerilen yaklaşım süpersonik bir savaş uçağı modelinde başarıyla denenmiştir.

Jiang vd., (2015) uçak motorunun yağlama sistemindeki anormal durumları tanımlamak için temel bileşen analizi (PCA) ve destek vektör makinesine (SVM) dayalı bir yöntem sunmuşlardır. Öncelikle sadece uçak motorunun çalışma durumunu izlemek için değil aynı zamanda arıza özelliklerini ayıklamak amacıyla motor normal

örneklerine dayalı olarak PCA kullanımı ile birlikte bir arıza izleme modeli oluşturulmuştur. Ardından SVM kullanılarak bir sınıflandırıcı oluşturulmuştur.

Yuan vd., (2015) farklı uçuş koşullarındaki kanatçık eyleyicilerindeki arızaları tespit etmek için bir yöntem önermişlerdir. Yaklaşımında, arıza tespit ve ön arıza lokalizasyonu için üç sinir ağı kullanılmıştır. Bir gözleyici olarak kullanılan ilk sinir ağı, kanatçık eyleyicilerinin izlenmesi ve sistem çıkışının tahmin edilmesi için kurulmuştur. İkinci sinir ağı, eş zamanlı olarak uyarlanabilir eşik değeri üretmek için kullanılmıştır. Son sinir ağı ise, bir kuvvet motoru akımı gözleyicisi olarak kullanılmıştır ve tahmini kuvvet motoru akımını çıkarmıştır. Arızalar, rezidü hatası ile eşik değerinin karşılaştırılması veya kuvvet motoru akımı ile tahmini kuvvet motoru akımının karşılaştırılması ile tespit edilmiştir.

Zhao vd., (2015) bir uçak motoru algılayıcı arızasını teşhis etmek için temel bileşen analizi (PCA) yöntemini kullanmışlardır. Online teşhis aşamasında ofset algılayıcısı arızası, sapma algılayıcısı arızası ve darbe algılayıcısı arızasını teşhis etmek için offline bir modelden yararlanılmıştır. Benzetim sonuçlarına göre, PCA tabanlı algılayıcı arıza teşhis yöntemi uçak motorları için uygun ve etkilidir.

Zolghadri vd., (2015) uçak elektrik uçuş kontrol sistemi (EFCS) için model ve sinyal tabanlı arıza tespit yöntemlerini incelemişlerdir. İncelenen yöntemler gerçeğe yakın uçak modelinde veya Airbus A380 uçağından alınan gerçek uçuş verileriyle denenmiştir. Sunulan model tabanlı bir çözüm, Airbus A350 uçağı için sertifikalandırılmıştır ve ilgili uçak tasarlanan sistemli ilk ticari uçuşunu 15 Ocak 2015'te gerçekleştirmiştir.

Bauer vd., (2018) iki kanatçık ve bir elektrik motoru bulunduran küçük bir insansız bir hava aracının uçuşta arıza tespiti ve küçük bir yeniden yapılandırılmasını incelemişlerdir. Arıza senaryosu olarak, kontrol yüzeylerinden birinin düz uçuşta iken verilen pozisyonda takılı kalmasıdır. Arıza tespiti, çoklu model uyarlamalı tahmin algoritmasıyla yapılmıştır. Arıza tespiti ve sistemin yeniden yapılandırılması için elde edilen sonuçlar, döngüsel benzetim sonucunda elde edilmiştir.

Eroglu vd., (2018) eyleyici veya motor arızaları altında uçak dinamiği için adaptasyon parametrelerini tahmin etmeye yönelik bir hibrid tekrarlayan/konvolüsyonel sinir ağı modeli sunmuşlardır. Model, farklı arıza senaryoları veri tabanından çevrimdışı olarak eğitilmiştir. Oluşturulan model, bir eyleyici veya motor arızası durumunda adaptasyon parametrelerini tanımlamakta ve bu bilgiyi adaptif kontrol sistemine

vermektedir. Sonuçta olarak kontrolör katsayılarının daha hızlı bir şekilde yakınsaması sağlanmaktadır.

Guo vd., (2018) insansız hava araçları için pitot tüp, cayro, ivme ölçer ve rüzgar açısı algılayıcı gibi hava aracı üstündeki algılayıcıları kullanarak, arıza tespiti yapan bir metod önermişlerdir. Metodu uygulamak için beş arıza tespit senaryosu incelenmiştir: arızalı pitot tüp, hücum açısı algılayıcısı, yana kayış algılayıcısı, ivme ölçer ve cayro. Ardından, orantılı ve çoklu bütünleyici (PMI) arıza tespit filtresi durumların ve girişin tahmini için önerilmiştir.

Sercekman ve Kutay (2018) arıza tespit ve teşhisi için, gözleyici tabanlı bir arıza tespit yöntemine yönelik yenilikçi bir yaklaşım önermişlerdir. Tasarlanan arıza tespit modeli, Boeing 747'nin doğrusal olmayan bir sivil hava aracı modeline parametrelerin doğru bir şekilde ayarlanmasıyla entegre edilmiştir. Arıza tespiti, bir gözleyici olarak standart bir kalman filtresi kullanılarak tahmin edilen hatasız davranışa göre uçağın davranışındaki önemli herhangi bir değişikliği değerlendirmek suretiyle gerçekleştirilmiştir.

Yan ve Zhou (2018) uçak algılayıcıları geçmiş verilerini inceleyerek uçak elemanları arızalarını tespit etmek için sınıflandırma tabanlı bir anomali tespit modeli sunmuşlardır. Öncelikle, arıza ile ilgili birkaç algılayıcı istatistiksel analiz kullanılarak seçilmiştir. İkinci olarak, seçilen algılayıcılar kullanılarak uçuş fazı tabanlı istatistiksel özellikler çıkarılmıştır. Üçüncü olarak, uçuş etiketiyle korelasyon analizi kullanılarak birkaç önemli özellik seçilmiştir. Son olarak, seçilen özelliklere dayanarak arıza sınıflandırma modelini oluşturmak için random forest algoritması uygulanmıştır.

Lijia, Yu ve Guo (2019) gözleyici ve radyal temelli işlevsel ağ yapısını beraber kullanarak insansız hava aracı konum sistemi için arıza tespit sistemi tasarlamışlardır.

Taimoor ve Aijun (2019) uçak gibi doğrusal olmayan sistemler için bilinmeyen hataların ve bozuklukların tahmini ve yeniden inşası için uyarlanabilir sinirsel kayan mod tabanlı bir gözleyici yapısı önermişlerdir. Arıza toleranslı kontrol sistemi stratejisi, Boeing 747 100/200 uçağında doğrulanan sistemin kararlılığını sağlamak için bilinmeyen hatalar ve arızaların varlığında her gözlemci için ayrı ayrı sunulmuştur.

He vd., (2020) hava araçlarında ataletsel ölçüm birimi için gözleyici ve kalman filtresi yapısının ayrı ayrı kullanılmasıyla model tabanlı bir arıza tespit ve teşhis sistemi oluşturmuşlardır. Gözleyici yapısı arıza tespitinde daha hızlı sonuç verirken, kalman filtreli yapıda arıza tespiti daha hassas yapılabilmektedir.

Nimmagadda vd., (2020) veri madenciliği tekniklerini kullanarak havayolu kazasının kuş çarpması sonucu olup olmadığını tahmin etmek için bir yöntem önermişlerdir. İlgili çalışmada karar ağaçları ve bayes sınıflandırmaları gibi makine öğrenme teknikleri kullanılarak bir tahmin modeli oluşturulmaya çalışılmıştır.

Baptista, Henriques ve Prendinger (2021) geleneksel olarak kestirimci bakıma yönelik prognostik yaklaşımlar, ekipmanın kalan faydalı ömrünü tahmin etmeye odaklanmıştır. Bununla birlikte endüstriyel bir bakış açısından amaç, genellikle kalan ömrü tahmin etmek değil, belirli bir zaman aralığında bir bakım eylemi ihtiyacını belirlemektir. Yapılan çalışmada havacılık ile ilgili sorunu ele almak için rastgele ormanlar, destek vektör makineleri, en yakın komşular ve derin öğrenme teknikleri gibi bir dizi sınıflandırıcı yaklaşımının göreceli güçlerini ve sınırlamalarını incelemişlerdir.

Kıyak ve Ünal (2021) yaptıkları çalışma ile derin öğrenmeye dayalı izleme algoritmasını ve geliştirilen dört derin öğrenme izleme modelini ele almışlardır. İlgili yöntemler otonom uçaklarda çarpışmayı önlemek ve hedef takibi yapabilmek için birbirleriyle karşılaştırılmıştır. İlgili çalışmada transfer öğrenme ile hassas ayar derin evrişimli sinir ağı (FNDCNNTL) yapısı ile elde edilen sonuçların diğer yöntemlere göre daha doğru çıktı verdiği vurgulanmıştır.

Taimoor vd., (2021) çok sayıda arıza, belirsizlik ve bozulmayı göz önünde bulundurarak, algılayıcı arıza tespiti ve doğrusal olmayan sistemin teşhisi için çeşitli sinir ağı (NN) gözlemci yapısı tekniklerini araştırmışlardır. İlgili çalışmada NN'lerin ağırlık parametrelerini uyarlamalı olarak ayarlamak için Lyapunov fonksiyon teorisi ve kayan mod yüzey konsepti gibi iki strateji bir arada kullanılmıştır. Bu stratejilerin temel amacı, bilinmeyen hataların büyüklüğünün yanı sıra şekil açısından da yüksek doğrulukla arıza teşhisi ve yeniden yapılandırılmasıdır. Önerilen strateji sonuçlarının literatürde kullanılan tekniklerle karşılaştırıldığında daha etkili olduğu vurgulanmıştır.

Görüldüğü gibi literatüre bakıldığında uçak modellemesine göre yapılan çalışmalara sıkça rastlanmaktadır. Ancak, uçak modeline göre yapılan çalışmalar çoğunlukla düz uçuş için belirli algılayıcılar ve belirli arıza durumları için yapılmıştır. Ayrıca bu çalışmalar model belirsizlikleri ve ölçüm hataları içermektedir. Yapılan çalışmalarda arıza tespitinin yapılmadığı ancak uçaklar için yapay sinir ağıları kullanarak gerçek uçuş verilerine dayalı alternatif veri sağlanmasına yönelik olan çalışmalar mevcuttur (Turkmen, 2018; Dalkiran and Toraman, 2020). İlk çalışmada hava hızı bilgisi pitot statik sistem ölçümleri olmadan tahmin edilmeye çalışılmıştır.

İlgili sistemde, hava hızı verilerini hesaplamak için giriş olarak 10 parametre seçilmiştir. İkinci çalışmada ise gaz kolu parametresi hava hızı, irtifa ve sıcaklık bilgileri kullanılarak hesaplanmaya çalışılmıştır. Yapılan çalışmalar arasında uçaklar için gerçek uçuş verilerine dayalı arıza tespit ve sistemin yeniden yapılandırılmasında tüm uçuş durumlarının alındığı (kalkış, düz uçuş, iniş) çalışmalar mevcuttur (Fravolini vd., 2018; Lu vd., 2020). Ancak bu çalışmalar belirli algılayıcılar ve belirli arıza durumlarının (sert veya yumuşak bias arızası) incelendiği çalışmalardır. Ayrıca ilgili çalışmalarda arıza tespit zamanı gecikmesi ve yanlış alarm durumu görülmektedir. Bazı pratik uygulamalardan bahsedecek olursak; Airbus A320, A330 ve A340 uçakları bir yedek hız ölçeği (BUSS) ile donatılmıştır. Teorik bir hava hızının sadece yunuslama ve gaz kolu parametrelerinden tahmin edildiği ilgili sistem Air France 447 uçuşunda başarısız olmuştur. Boeing firması ise bu sorunu Boeing 787 uçağını görsel hava hızı algılayıcısı ile donatarak çözmeye çalışmıştır. Hücum açısı ve atalet sistemlerinden gelen bilgiler ile hesaplanan veri sentetik hava hızı (SAS) olarak adlandırılmıştır, ancak bu sistem Jetstar'ın JQ 07 uçuşunda başarısız olmuştur (Alvarez vd., 2019).

Her ne kadar birçok önemli teorik ve pratik çalışmalar olsa da, uçaklar için arıza tespiti ve yeniden yapılandırılmasına yönelik genel olarak kullanılan bir sistem bulunmamaktadır. İlgili çalışmalar belirli algılayıcılar ve belirli arıza durumlarının incelendiği çalışmalar olmasından dolayı bu çalışmada hücum açısı, hız ve irtifa algılayıcısı için tek bir arıza tipi yerine, tüm uçuş fazlarında karşılaşılabilecek farklı arıza senaryoları incelenmiştir. Ayrıca ilgili çalışmalarda oluşan arıza tespit zamanı gecikmesi ve yanlış alarm durumu da giderilerek daha güvenilir bir arıza tespit ve yeniden yapılandırma sistemi oluşturulurken uçaklar için hücum açısı, hava hızı ve irtifa bilgisi için alternatif bir veri sağlama kısmı elde edilebilmiştir. Ayrıca, BUSS ve SAS gibi sistemler yerine tasarlanan sistem veri tahmini için daha fazla parametre içermektedir. Bu çalışmada, bazı çalışmaların daha ileriki aşamalarında belirtildiği gibi ilişkili girdi parametrelerinin daha fazla sayıda olmasının daha iyi veri tahmini sağladığı belirtilmektedir (Dalkiran and Toraman, 2020).

1.2. Bazı Hava Araçları Kazaları ve Sisteme Olan İhtiyaç

Hava yolunda oluşan kazalar uçuş ekibine verilecek eğitimlerle birlikte azaltılabilirken, uçakta oluşan arızaların giderilmesi belirli bir mühendislik çalışması gerektirmektedir. Bundan dolayı bu arızaların giderilmesi için neler yapılabilir sorusu

bu çalışmanın çıkış noktasını oluşturmuştur. Uçaklarda hücum açısı algılayıcısı kaynaklı çeşitli kazalar meydana gelmiştir. 29 Ekim 2018 tarihinde, Lion havayolları'na ait bir Boeing 737 Max uçağı dijital uçuş veri kaydedicisine göre hücum açısı algılayıcısı kaynaklı bir arızadan dolayı düşmüştür. Diğer bir kaza ise; 10 Mart 2019 tarihinde, Etiyopya Havayolları'na ait bir Boeing 737 Max uçağının düşmesi yine bir hücum açısı algılayıcı arızası sonucu oluşmuştur (Yüksel, 2019). Uçaklarda hava veri sisteminin bileşenlerinden olan hız ve irtifa algılayıcıları kaynaklı çeşitli kazalar meydana gelmiştir. 6 Şubat 1996 tarihinde Birgen Havayolları'na ait bir Boeing 757 uçağı, hava hızını ölçen pitot problemlerin üzerindeki koruyucu kılıfların uzun süre alınmaması nedeniyle oluşan tıkanmadan dolayı Atlantik Okyanusu'na düşmüştür. 2 Ekim 1996 tarihinde Aeroperu Havayolları'na ait bir Boeing 757 uçağı, irtifayı ölçen statik portların üzerlerindeki kılıfların uçuştan önce alınmaması nedeniyle Peru'da düşmüştür. 7 Nisan 1999 tarihinde Türk Havayolları'na ait bir Boeing 737 uçağı, pitot problemlerin buzlanması nedeniyle Adana'da düşmüştür. 1 Haziran 2009 tarihinde Air France Havayolları'na ait bir Airbus A330 uçağı, pitot problemlerin buzlanması nedeniyle Atlantik Okyanusu'na düşmüştür. 13 Kasım 2013 tarihinde Etihad Havayolları'na ait bir Airbus A330 uçağı, pitot problemlerin kirden tıkanmasından dolayı Avusturalya'da düşmüştür. 11 Şubat 2018 tarihinde Saratov Havayolları'na ait bir Antonov An-148 uçağı, pitot problemlerin buzlanması sonucu Moskova'da düşmüştür (Alvarez vd., 2019).

2. ARIZA TESPİTİ VE KORELASYON ANALİZİ

2.1. Arıza Tespit Sisteminin Genel Yapısı

Arıza; sistemin en az bir karakteristik özelliğinin kabul edilebilir, olağan, standart durumundan izin verilmeyecek şekilde sapmasıdır. Arıza tespiti aşaması, arıza toleranslı kontrol sistemlerinin temel aşamasıdır. Genel prosedür aşağıdaki üç adımı içermektedir: Rezidü üretimi (arıza bindirilmiş gerçek uçuş değerleri ile tahmin edilen olması gereken uçuş değerleri arası fark), rezidü değerlendirme (belirli eşik değerine göre değerlendirme) ve karar verme aşamasıdır. Genellikle, bir arıza tespit ve ayırım sisteminin temel istenen özellikleri; erken tespit ve ayırım, gürültü ve belirsizliklere karşı dayanıklılık ve güvenilirliktir (Fekih, 2014). İlgili çalışmada aynı anda birden fazla arıza olma durumu incelenmemiştir ve ilgili algılayıcılar ayrı ayrı incelenmiştir.

“ $Y(k)$ ” arızalı sistem verileri olmak üzere denklem 2.1’de görüldüğü şekilde arızasız sistem verileri “ $y(k)$ ”nın üzerine “ $t_1 \leq t \leq t_2$ ” zaman aralığında arıza modeli “ $f(k)$ ”nın bindirilmesiyle oluşturulmuştur. Ancak tahmin edilen sistem verileri “ $\hat{y}(k)$ ” arızadan bağımsızdır.

$$Y(k) = y(k) + f(k) \quad (2.1)$$

Rezidü değeri “ $r(k)$ ” ise denklem 2.2’de görüldüğü şekilde arızalı sistem verileri “ $Y(k)$ ” ile tahmin edilen olması gereken değerler “ $\hat{y}(k)$ ” arası farka eşittir.


$$r(k) = Y(k) - \hat{y}(k) \quad (2.2)$$

Eşik değeri “ $\mathcal{E}$ ” olmak üzere denklem 2.3’te görüldüğü şekilde rezidü değerinin mutlak değerinin belirlenen eşik değeri geçmesi durumunda sistem arıza tespiti yapacaktır.

$$|r(k)| > \mathcal{E} \quad (2.3)$$

Arıza tespiti ve yeniden yapılandırılması için tasarlanan sisteme ait blok diyagramı Şekil 2.1’de gösterilmiştir. Herhangi bir arıza tespit sisteminin doğruluğu tespit zamanı, yanlış alarm oranı veya arızayı tespit edip edememesiyle ölçülür. Genel olarak çalışmada dikkat edilmesi gereken nokta eşik değerini doğru tayin etmektir. Çünkü

düşük eşik değeri yanlış alarm oranını artırabilirken, yüksek eşik değeri de arızanın tespit edilememesine neden olabilir ve arıza tespit zamanını artırabilir (Samy, Postlethwaite and Gu, 2011).



Şekil 2.1. Sisteme ait blok diyagram

Bu çalışmada, arıza tipleri otoritelerce izin verilen arıza limitleri dahilince modellenmiştir. Hücum açısı algılayıcısı için kaptan ve yardımcı pilot göstergeleri arası farkın mutlak değeri federal havacılık idaresi (FAA)’nin belirlediği değer olan 10 derece değerini geçmemesi, hız algılayıcısı için bu değer 4 knot değerini geçmemesi ve irtifa algılayıcısı için bu değer tam “Reduced Vertical Separation Minimum-RVSM” durumunda aradaki farkın mutlak değeri “Altimetry System Error-ASE”nin 245 ft değerini geçmemesi gerekmektedir. Bu değerlere kadar arıza durumu olmadığı ve bu değerlerin kabul edilebilir olduğu belirtilmektedir. Hücum açısı algılayıcısı çıkış sinyali aerodinamik titreşimlerden etkilenir ve bu durum algılayıcı verisini osilasyona sokabilir. Ayrıca ilgili algılayıcılar manyetik çevre durumlarından dolayı bias arızaları içerebilir (Popowski and Dabrowski 2015; Castaldi, Mimmo and Simani, 2017). Bu sistemlerin arızalanmasının ana sebeplerinden biri pitot statik sistemin buz veya yabancı cisimler tarafından tıkanmasıdır. Pitot statik sistemde toplam basınç giriş deliği, statik hava basıncının alındığı statik basınç giriş deliği veya sistemdeki nemi dışarı atan pitot tüp tahliye deliği tıkanabilir. Pitot tüp tahliye deliği tılandıktan sonra toplam basınç giriş deliği tıkalı (iki durum art arda) ve ardından pitot tüp üzerindeki statik basınç giriş deliğinin tıkanması durumunda hız verisi son değerinde takılı kalacaktır. Ancak önce toplam basınç giriş deliği tıkanırsa bu durumda hava hızı göstergesi sıfıra gidecek ve donacaktır. Statik portun tıkanması durumunda irtifa verisi en son değerinde kalacaktır. Örnekler arasında donabilecek su, uçak park halindeyken yuva yapan böcekler,

deliklere giren diğer döküntüler veya pitot tüpü ve/veya statik delik koruyucularının uçuştan önce alınmamış olması sayılabilir. Pitot statik hatlarda aynı zamanda düzenli olarak suyun olup olmadığı kontrol edilmelidir. Pitot statik sistem hatlarında biriken su, ivmelenme kuvvetinin etkisiyle borular içinde hareket eder ve hapsolmuş havanın basıncını değiştirir. Sudan etkilenen göstergeler üzerinde yükselen alçalan indikasyonlar görülür. Borulardaki su donarsa, tıkanmış portlardaki gibi aynı etkiyi gösterir (Oliveira, 2013).

2.2. Özellik Çıkarımı ve Korelasyon Analizi

Elimizdeki verilere ait birçok özellikten verinin kümesini, sınıfını veya değerini belirleyen özelliklerin hangileri olduğu bilinemeyebilir. Bu tarz durumlarda tüm özellik kümesinin bir alt kümesi seçilir (Özellik seçimi) veya bu özelliklerin birleşiminden yeni veriler elde edilir (Özellik çıkarımı). Bunun yapılmasının amacı, hesaplama yükü azaltılırken başarı oranını yükseltmektir. Özellik kavramı yerine bazı kaynaklarda nitelik bazı kaynaklarda ise değişken terimi kullanılmaktadır. Özellik seçimi makine öğrenmesi yöntemlerinde sıklıkla kullanılır. Yapılan işlem aslında verilerin ön işlenmesidir. Seçilen özellikler ayrık, sürekli veya nominal değerlerde olabilmektedir. En uygun özellik alt kümesinin seçildiğinden emin olmak için bütün olası alt kümeler seçilip sistem tarafından denenmeli ve elde edilen sonuçlara göre uygun alt küme seçilmelidir. Özellikleri ifade etmek için aşağıda verilen terimler kullanılmaktadır.

-Alakalı (Relevant): Çıkış parametresi üzerinde doğrudan etkili olan parametrelerdir.

-Alakasız (Irrelevant): Çıkış parametresi üzerinde doğrudan etkisi olmayan ve her bir örneklem alt kümesinde rasgele üretilen özelliklerdir.

-Gereksiz (Redundant): Seçilen bir özellik yerine eğer başka bir özellik getirilebiliyorsa bu özellik için gereksiz ifadesi kullanılabilir.

Özellik seçiminin avantajları:

1. Çıkış parametresi üzerinde bir etkisi olmayan bileşenlerin silinmesini sağlar.
2. Özellik sayısı azaltıldığından dolayı ilgili algoritmanın eğitim aşaması kısa sürer.
3. Eğitim verisi gereksiz özelliklerden arındırıldığı için sonuçta oluşan doğruluk değeri artırılmış olur.

4. Çalışma uzayının boyutu düşürüldüğü ve depolama ile işlem karmaşıklığı azaltıldığı için bellek biriminden tasarruf sağlanır (Bilgin, 2018).

İlk olarak korelasyon analizinin kullanılması ile hücum açısı, hız ve irtifa ile alakalı olan veriler seçilmiştir. Yani sistemde kullanılacak özellikler korelasyon analizi ile seçilerek veriler ayıklanmıştır. İlgili alakalı verilerden hareketle hücum açısı, hız ve irtifa verilerinin olması gereken değerleri tahmin edilmiştir. Kullanılan bazı uçuş verileri ve değer aralıkları Tablo 2.1’de verilmiştir.

Tablo 2.1. Uçuşa ait bazı bilgiler

	İrtifa (ft)	Hava hızı (CAS) (knot)	Hücum açısı (derece)	Dikey hız (ft/min)	Yunuslama açısı (deg)	Toplam hava sıcaklığı (degC)	N12 (rpm)
Ortalama değeri	2.6474e+04	224,45	-1,2164	-4,1752	2,3991	-15,265	74,6664
Medyan değeri	36994	251	-0,88	0	2,8000	-19,500	89,6000
Standart sapma değeri	1.4768e+04	76	2,1543	875,3582	1,9648	12,314	26,2614
Minimum değer	0	45	-18,46	-3344	-3	-38	19,1000
Maksimum değer	37048	327	9,14	4272	17,4000	9,750	99,5000

Analiz için kullanılan uçuş verileri; statik basınç (hPa), irtifa verisi (ft), barometrik altimetreden okunan irtifa verisi (ft), kalibre edilmiş hava hızı (CAS, knot), gerçek hava hızı (TAS, knot), hücum açısı (deg), dikey hız (ft/min), dönüş oranı (deg/s), yunuslama oranı (deg/s), yalpa oranı (deg/s), dönüş açısı (deg), yunuslama açısı (deg), baş açısı (deg), statik hava sıcaklığı (SAT, degC), toplam hava sıcaklığı (TAT, degC), motor N1 shaftı devri (N11, rpm), motor N2 shaftı devri (N12, rpm)’dir. Statik basınç, cisme bulunduğu ortamın her yönde etki ettiği basınçtır. İrtifa verisi, statik basınca göre ölçülen değerdir. Barometrik altimetreden okunan irtifa verisi, barometrik altimetre referans değerine göre ölçülen değerdir. Kalibre edilmiş hava hızı (CAS), işari hava hızı (IAS)’nın enstrüman ve pitot pozisyon hatalarından arındırılmış halidir. Gerçek hava hızı (TAS), sıkıştırılabilirlik düzeltmesi yapılmış CAS değeri olan eşdeğer hava hızı (EAS)’nın yoğunluğa göre düzeltilmiş halidir. Hücum açısı, bağlı rüzgar doğrultusu ile veter doğrusu arasındaki açıdır. Dikey hız verisi, uçağın dakikada feet olarak yükselme veya alçalma hızı verisidir. Dönüş oranı, yunuslama oranı ve yalpa oranı verileri hava

aracına verilen kontrol sonucunda uçağın saniyedeki hareket oranlarıdır. Dönüş açısı, yunuslama açısı ve baş açısı uçağa verilen kontrol sonucunda uçağın eksenlere göre yaptığı açılardır. Statik hava sıcaklığı, uçağın çevresinde bozulmayan havanın sıcaklığıdır. Toplam hava sıcaklığı, uçuşta statik hava sıcaklığından daha yüksektir, çünkü çarpan havadan dolayı yükselir. Motor N1 şaftı devri (fan hızı) ve motor N2 şaftı devri ise ilgili şaftların dakikadaki devir sayılarını vermektedir. N1 hızı, fanın dönüş hızıdır ve motor itkisini ölçmede kullanılmaktadır. Hızlı dalgalanan N1 değeri motorun teklemesine neden olabilir. N2/N3 hızları ise kompresörün yüksek veya orta basınçtaki dönme değerleridir (Kurt, 2018). Denklem 2.4'ten görüldüğü üzere TAS değeri yoğunluk değerine bağlıdır (ρ_0 deniz seviyesindeki ve ρ ilgili irtifadaki havanın yoğunluk değerleri, kg/m^3).

$$TAS = \frac{EAS}{\sqrt{\varphi}} \quad \left(\varphi = \frac{\rho}{\rho_0} \right) \quad (2.4)$$

Yoğunluk (ρ , kg/m^3) ile irtifa (h , m) verisi arasında denklem 2.5'e göre bir bağlantı olmasından dolayı, TAS verisi bir nevi irtifa bilgisine göre değişmektedir (Freeman, Seiler and Balas, 2013). Bundan dolayı hesaplamalarda CAS verisinin kullanılması daha doğru olacaktır. $T_o=288 \text{ K}$, $g=9,81 \text{ m/s}^2$ ve $R=287 \text{ J/kgK}$ olmak üzere;

$$\frac{\rho}{\rho_0} = \left(1 - \frac{h}{44308} \right)^{4.259} \quad (2.5)$$

Korelasyon katsayısı, bazı değişkenler arasındaki ilişkinin yönü ve büyüklüğünü belirlemektedir. İlgili katsayı, -1 ile +1 arasında bir değer almaktadır ve -1'e veya +1'e ne kadar yakınsa ilişkinin doğrusallığı o kadar fazla olmaktadır. Bu katsayı incelenen iki değişkenin kovaryansı " $Cov(X,Y)$ "nin (değerlerin birlikte nasıl değiştiğini gösteren parametre), değişkenlerin standart sapmaları σ_x ve σ_y 'nin çarpımına bölünmesiyle elde edilir. Denklem 2.6'da verildiği şekilde hesaplanır ve tüm pratik uygulamalarda $|p| < 0,05$ olduğu durumda değişkenler korelasyonsuz alınır (Duda, Hart and Stork, 2000).

$$p_{x,y} = \frac{Cov(X,Y)}{\sigma_x \sigma_y} = \frac{E(X-\mu_x)(Y-\mu_y)}{\sigma_x \sigma_y} \quad (2.6)$$

2.3. Korelasyon Katsayılarının Elde Edilmesi

Bu çalışmada hücum açısı, hız ve irtifa algılayıcısı verilerinin diğer verilerle nasıl değiştiğinin bulunması için MATLAB programında korelasyon analizi yapılmıştır ve korelasyon matrisleri ile korelasyon katsayıları bulunmuştur. İlk olarak hücum açısı verisi ile diğer veriler arası korelasyon analizi yapılmıştır ve korelasyon katsayılarının mutlak değerleri elde edilmiştir. Tüm pratik uygulamalarda $|p| < 0,05$ olduğu durumda değişkenler korelasyonsuz alınmıştır. Buna göre korelasyon analizi sonucu hücum açısı ile ilişkili veriler toplam 12 adet olmaktadır ($|p| < 0,05$ olmasından dolayı dikey hız, dönüş oranı, yalpa oranı ve dönüş açısı verileri elenmiştir). İrtifa değeri statik basınca göre belirlenmektedir ve statik basınç, irtifa verisi ve barometrik altimetreden okunan irtifa verisi aynı kaynaktan beslenmektedir. Bundan dolayı aralarında en yüksek korelasyona sahip olan statik basınç ($p=0,3128$) çalışmaya dahil edilmiştir. Ayrıca, yukarıda bahsedildiği üzere TAS verisi irtifayla değiştiğinden dolayı çalışmaya CAS verisi dahil edilmiştir. Hücum açısı ile ilişkili olan veriler Tablo 2.2’de verildiği üzere 9 adettir.

Tablo 2.2. Hücum açısı için korelasyon katsayıları

Hücum açısı ile ilişkili veriler	Statik basınç (hPa)	CAS (knot)	Yunuslama oranı (deg/s)	Yunuslama açısı (deg)	Baş açısı (deg)	SAT (degC)	TAT (degC)	N11 (rpm)	N12 (rpm)
Kore. Kats. (p)	0,3128	0,5067	0,2252	0,5249	0,1956	0,2540	0,2241	0,3734	0,3723

Hız verisi ile diğer veriler arası korelasyon analizi yapılarak korelasyon katsayılarının mutlak değerleri elde edilmiştir. Buna göre korelasyon analizi sonucu hız ile ilişkili veriler toplam 10 adet olmaktadır ($|p| < 0,05$ olmasından dolayı dikey hız, dönüş oranı, yunuslama oranı, yalpa oranı ve dönüş açısı verileri elenmiştir). Hücum açısı korelasyon analizinde olduğu gibi ilgili irtifa verileri arasında en yüksek korelasyona sahip olan statik basınç ($p=0,8342$) çalışmaya dahil edilmiştir. Hücum açısı verisinin kalibrasyonu bir hız verisi göstergesi olan mach sayısına göre yapılmaktadır. Yani hız verisinin ve dolayısıyla hesaplanan mach sayısının yanlış olması kalibre edilmiş hücum açısı verisini etkilemektedir (Cashman, Kelly and Nield, 2000). Bundan dolayı hız algılayıcısının arızalanması durumunda hücum açısı verisi de hatalı olarak kalibre edileceğinden bu iki veri arasındaki korelasyon katsayısının değeri ($p=0,5067$) olmasına rağmen hücum açısı

verisi hız algılayıcısı arıza incelemesine dahil edilmemiştir. Hız ile ilişkili olan veriler Tablo 2.3'te verildiği üzere 7 adettir.

Tablo 2.3. Hız için korelasyon katsayıları

Hız ile ilişkili veriler	Statik basınç (hPa)	Yunuslama açısı (deg)	Baş açısı (deg)	SAT (degC)	TAT (degC)	N11 (rpm)	N12 (rpm)
Kore. Kats. (p)	0,8342	0,4652	0,3731	0,8075	0,7455	0,7674	0,7656

Son olarak irtifa verisi ile diğer veriler arası korelasyon analizi yapılmıştır ve korelasyon katsayılarının mutlak değerleri elde edilmiştir. Buna göre korelasyon analizi sonucu irtifa ile ilişkili veriler toplam 10 adet olmaktadır ($|p| < 0.05$ olmasından dolayı dikey hız, dönüş oranı, yalpa oranı ve dönüş açısı verileri elenmiştir). Yukarıda bahsedildiği üzere TAS verisi irtifayla değiştiğinden dolayı çalışmaya CAS verisi dahil edilmiştir. İrtifa ile ilişkili olan veriler Tablo 2.4'te verildiği üzere 9 adettir.

Tablo 2.4. İrtifa için korelasyon katsayıları

İrtifa ile ilişkili veriler	CAS (knot)	Hücum açısı (deg)	Yunuslama oranı (deg/s)	Yunuslama açısı (deg)	Baş açısı (deg)	SAT (degC)	TAT (degC)	N11 (rpm)	N12 (rpm)
Kore. Kats. (p)	0,7693	0,2829	0,1691	0,2864	0,2810	0,9708	0,9226	0,8433	0,8434

3. YAPAY SİNİR AĞLARI YÖNTEMLERİ İLE SİSTEM EĞİTİMİ

Teknik tesislerin güvenilirliği ve güvenliği konusunda artan talepler, proses hatalarının erken tespit edilmesini gerektirmektedir. Tek süreç değişkenine dayalı klasik limit ve trend kontrollü sistemlere göre proses hatalarının daha erken tespit edilebilmesini sağlayan metotlar geliştirilmiştir. Bu metotlar sadece bir süreç değişkeni değil, aynı zamanda süreç durumu, parametreler ve karakteristik büyüklükler gibi ölçülebilir olmayan değişkenleri de kapsamaktadır. Bazı yöntemler doğru süreç modelleri gerektirirken, diğerleri öncelikli olarak mevcut tarihsel süreç verilerine dayanır. Belirli arıza tespit yöntemini seçerken arızaların türü, işlem yapısının tanımı, işlem dinamiği, mevcut işlem sinyalleri, işlem karmaşıklığı, işlem giriş-çıkış verilerinin kullanılabilir miktarı ve işlem uygunluğu gibi durumlar dikkate alınmalıdır. Literatürdeki yaklaşımların bazıları kontrol mühendisliği yaklaşımına yönelmişken bazıları da matematiksel, istatistiksel ve yapay zeka yaklaşımlarına yönelmiştir. Kullanılan arıza tespit metotları aşağıda verilmiştir (Isermann, 2005; 2006; Castillo and Edgar, 2008).

Veri Tabanlı Yöntemler ve Sinyal Modelleri

- Limit ve trend kontrolü
- Veri analizi (PCA)
- Spektrum analizi ve parametrik modeller
- Örüntü tanıma (Yapay sinir ağları)

Proses Model Tabanlı Yöntemler

- Parite denklemleri
- Durum gözleyicileri
- Parametre tahmin sistemleri
- Doğrusal olmayan modeller (Yapay sinir ağları)

Bilgi Tabanlı Yöntemler

- Uzman Sistemler
- Bulanık Mantık


Makine öğrenmesi yöntemleri modelleme ve tahmin algoritması olarak havacılık alanında son zamanlardaki çalışmalarda sıklıkla kullanılmaktadır. (Yazar vd., 2018;

Gupta, Emran and Najjaran, 2019; Taimoor and Aijun, 2019; Verma and Peyada, 2019; Bagherzadeh, 2020; Chen vd., 2020; Dalkiran and Toraman, 2020; Huo vd., 2020; Işık, Ekici and Şahin, 2020; Meel vd., 2020; Puranik, Rodriguez and Mavris, 2020; Verma and Peyada, 2020; Basturk and Cetek, 2021; Dalmau vd., 2021; Garcia, Camana and Koo, 2021; Kayaalp and Metlek, 2021; Khan vd., 2021; Verma and Peyada, 2021). Bu çalışmanın tahmin kısmında makine öğrenmesine dayalı yöntemler olan uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağları (YSA) kullanılmıştır. İlgili yöntemlerin eğitim aşamasında geriye yayılım algoritması ile algoritma ağırlıklarının güncellenmesi sonucunda sistem eğitimi gerçekleştirilir. Modelin aşırı öğrenmediğinin kontrolü doğrulama veri kümesi üzerinden yapılır. Eğitim aşaması belirli bir hata değeri veya çevrim sayısına ulaşıldığında durdurulur. Eğitilmiş sistem üzerinden istenilen test verisinin kullanılması ile de sistem testi gerçekleştirilir. Bu yöntemlerin kalman filtresi veya luenberger gözleyicisi gibi model tabanlı sistemlere göre avantajları; model belirsizlikleri ve ölçüm hataları içermemesi, belli bir modele bağlı olmaması ve hata toleranslı olmasıdır. İlgili yöntemlerin hata toleransı olmasından dolayı giriş sistemlerinde oluşabilecek bir arıza, tahmin hatasını fazla artırmayacağından dolayı yine yaklaşık bir çözüm üretilebilecektir. Bu sayede ilgili yöntemler belirli kabuller altında kalmadan uçak gibi doğrusal olmayan sistemlerde kullanılabilir (Singh and Vasudeviah, 2012). Ayrıca ilgili yöntemler sistem karmaşıklığı, hesaplaması ve maliyetini fazla artırmadan doğru ve hızlı bir arıza tespiti ve yeniden yapılandırmayı gerçek zamanlı sistemler için gerçekleştirebilir kılmaktadır (Turkmen, 2018; Taimoor and Aijun, 2019). Bu çalışmada uyarlamalı ağ tabanlı bulanık çıkarım sistemi ve yapay sinir ağlarının kullanılmasıyla elde edilen veri tahmini başarımı her iki yöntem için karşılaştırılmıştır.

3.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ile Eğitim

ANFIS metodunun temeli Takagi-Sugeno bulanık çıkarım sistemine dayanmaktadır. Sugeno tipi çıkarım sistemi çıkışa lineer bir fonksiyon veya sabit vermektedir. Sugeno sistemi hesaplama açısından daha kolaydır ve durulaştırma işlemi gerekmemektedir. Mamdani-tipi çıkarım sistemi ise üyelik fonksiyonlarıyla ifade edilen bir çıkış vermektedir. Jang (1993), uyarlamalı ağ tabanlı bulanık çıkarım sistemini geliştirmiştir ve bu sayede doğrusal olmayan fonksiyonlar modellenebilmiştir. Bu yöntemin uygulanabilmesi için giriş-çıkışa dayanan bir veri kümesine ihtiyaç vardır. Bu

yöntemde, bulanık sistemin üyelik fonksiyonları ve kuralları yapay sinir ağları yardımı ile bulunur. ANFIS, giriş-çıkış değerleri bilinen sistemlerin ilgili yöntem ile modellenebilmesi için kural tabanı ve üyelik değerlerinin optimizasyonunu sağlamaktadır. Optimizasyon işlemi yapay sinir ağlarının öğrenme algoritmaları ile yapılır. ANFIS yönteminde iki tip optimizasyon algoritması kullanılmaktadır. Bunlar; hibrit metodu ve geriye yayılım algoritmasıdır. Hibrit metodu daha hızlı bir yapı göstermektedir. Hibrit öğrenme metodunda geriye yayılım ve en küçük kareler yöntemi beraber kullanılır. Sonucun ilk değerini alması için en küçük kareler yöntemi başlangıçta bir kez uygulanır ve daha sonra geriye yayılım algoritması ile parametreler güncelleştirilir. Bir ANFIS denetleyici beş katmandan meydana gelmektedir. Şekil 3.1’de ANFIS yapısı gösterilmiştir (Rençber, 2018).



Şekil 3.1. ANFIS yapısı (Rençber, 2018)

Birinci katmanda, bulanıklaştırma işlemi gerçekleştirilerek üyelik dereceleri hesaplanmaktadır. İkinci katmanda ise girdiler çarpılmaktadır. Üçüncü katmanda, ateşleme gücü değerleri toplam değere bölünerek normalizasyon işlemine tabi tutulur. Dördüncü katmanda, Takagi-Sugeno sistemi kullanılır. Burada normalleştirilmiş kuralların ateşleme güçleri sabit sayı veya lineer fonksiyon ile çarpılarak durulaştırma işlemi yapılır. Beşinci katman sonucunda toplam sonuç değeri elde edilmektedir. Burada uyarlamalı ağ tabanlı bulanık çıkarım sistemi tarafından yapay sinir ağı öğrenme yöntemleri kullanılarak ‘w’ ağırlık değerleri öğrenilmektedir ve sistem modellenmektedir. ANFIS’de her katmanda kural sayısı kadar nöron bulunmaktadır. Burada yuvarlak düğüm noktaları statik iken kare düğüm noktaları uyarlanabilir. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi tek çıkış üretmekte ve ağırlıklı ortalama

durulaştırma yöntemini kullanmaktadır. Çıkış üyelik fonksiyonları ise hepsi aynı tip sabit sayı veya lineer fonksiyondur. Uygulamayı kullanmak için belirlenmesi gereken parametreler dilsel değişken sayısı, üyelik fonksiyonu tipi, bulanık çıkarım derecesi, optimizasyon metodu, hata toleransı ve eğitim çevrim sayısıdır (Rençber, 2018). İşlemler için MATLAB kullanılmıştır. Dilsel değişken sayısı üç olarak alınmıştır, yani her bir giriş için üç adet üyelik fonksiyonu tanımlanmıştır. Her bir üyelik fonksiyonu tipi ayrı ayrı denenmiştir (üçgen, yamuk, çan şekilli, gauss, π , sigmoidal). Bulanık çıkarım kısmında çıkış üyelik fonksiyonu sabit olarak alınmıştır. Optimizasyon metodu hibrit olarak seçilmiştir. Hata toleransı sıfır alınmıştır. Eğitim çevrim sayısı ise 3 olarak alınmıştır (genelde 2. çevrimde optimal sonucu vermektedir). Eğitim ve test verisi rasgele olarak ayrılmıştır. Çok fazla kural oluşabileceğinden dolayı **en alakalı veriler** seçilmiştir. Her bir üyelik fonksiyonu gerçek değerler ile tahmin edilen değerler arasındaki farkın ölçütü olarak kullanılan ve denklem 3.1’de verilen ortalama hata kareleri toplamı (RMSE) değeri kullanılarak karşılaştırılmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (3.1)$$

Hücum açısı için korelasyon katsayılarına göre **en alakalı veriler** seçildiğinde; statik basınç, kalibre edilmiş hava hızı, yunuslama açısı, motor N1 şaftı devri şeklinde 4 adet giriş değeri bulunmaktadır. Bu şekilde hücum açısı için 81 adet kural oluşmaktadır. İlgili 4 değer uyarlamalı ağ tabanlı bulanık çıkarım sisteminin girişini oluştururken hücum açısı değeri de çıkış verisini oluşturmaktadır. Eğitim sonucunda; Bağlantı sayısı: 193, Lineer parametre sayısı: 81, Veri çifti sayısı: 10960, Kural sayısı: 81 olarak sonuç vermiştir. Her bir üyelik fonksiyonu için hücum açısı tahmin hatası RMSE değeri hesaplanmıştır ve en düşük RMSE değeri Tablo 3.1’de görüldüğü üzere üçgen üyelik fonksiyonu için elde edilmiştir (RMSE=0,914030).

Tablo 3.1. *Hücum açısı algılayıcısı için üyelik fonksiyonları tahmin hatası değerleri*

Üyelik Fonksiyonu	Matlab Kodu	Hata Değeri (RMSE)
Üçgen Üyelik Fonksiyonu	trimf	0,914030
Yamuk Üyelik Fonksiyonu	trapmf	1,018367
Çan Şekilli Üyelik Fonksiyonu	gbellmf	0,920340
Gauss Üyelik Fonksiyonu (tam simetrik)	gaussmf	0,915959
Gauss Üyelik Fonksiyonu	gauss2mf	0,984558
II Üyelik Fonksiyonu	pimf	1,030640
Sigmoidal Üyelik Fonksiyonu (tam simetrik) (iki sigmoid üyelik fonksiyonu arası fark)	dsigmf	0,964751
Sigmoidal Üyelik Fonksiyonu (iki sigmoid üyelik fonksiyonunun çarpımı)	psigmf	0,964786

Hız için korelasyon katsayılarına göre **en alakalı veriler** seçildiğinde; statik basınç, yunuslama açısı, statik hava sıcaklığı, motor N1 şaftı devri şeklinde 4 adet giriş değeri bulunmaktadır. Bu şekilde hız algılayıcısı için 81 adet kural oluşmaktadır. İlgili 4 değer uyarlamalı ağ tabanlı bulanık çıkarım sisteminin girişini oluştururken hız değeri de çıkış verisini oluşturmaktadır. Eğitim sonucunda; Bağlantı sayısı: 193, Lineer parametre sayısı: 81, Veri çifti sayısı: 10960, Kural sayısı: 81 olarak sonuç vermiştir. Her bir üyelik fonksiyonu için hız tahmin hatası RMSE değeri hesaplanmıştır ve en düşük RMSE değeri Tablo 3.2’de görüldüğü üzere üçgen üyelik fonksiyonu için elde edilmiştir (RMSE=4,832116).

Tablo 3.2. *Hız algılayıcısı için üyelik fonksiyonları tahmin hatası değerleri*

Üyelik Fonksiyonu	Matlab Kodu	Hata Değeri (RMSE)
Üçgen Üyelik Fonksiyonu	trimf	4,832116
Yamuk Üyelik Fonksiyonu	trapmf	13,344170
Çan Şekilli Üyelik Fonksiyonu	gbellmf	5,799824
Gauss Üyelik Fonksiyonu (tam simetrik)	gaussmf	5,131293
Gauss Üyelik Fonksiyonu	gauss2mf	9,831108
II Üyelik Fonksiyonu	pimf	15,063976
Sigmoidal Üyelik Fonksiyonu (tam simetrik) (iki sigmoid üyelik fonksiyonu arası fark)	dsigmf	7,154231
Sigmoidal Üyelik Fonksiyonu (iki sigmoid üyelik fonksiyonunun çarpımı)	psigmf	7,153258

İrtifa için korelasyon katsayılarına göre **en alakalı veriler** seçildiğinde; kalibre edilmiş hava hızı, statik hava sıcaklığı, motor N2 şaftı devri şeklinde 3 adet giriş değeri bulunmaktadır. Bu şekilde irtifa algılayıcısı için 27 adet kural oluşmaktadır. İlgili 3 değer uyarlamalı ağ tabanlı bulanık çıkarım sisteminin girişini oluştururken irtifa değeri


de çıkış verisini oluşturmaktadır. Eğitim sonucunda; Bağlantı sayısı: 78, Lineer parametre sayısı: 27, Veri çifti sayısı: 10960, Kural sayısı: 27 olarak sonuç vermiştir. Her bir üyelik fonksiyonu için irtifa tahmin hatası RMSE değeri hesaplanmıştır ve en düşük RMSE değeri Tablo 3.3'te görüldüğü üzere gauss üyelik fonksiyonu (tam simetrik) için elde edilmiştir (RMSE=728,889948).

Tablo 3.3. İrtifa algılayıcısı için üyelik fonksiyonları tahmin hatası değerleri

Üyelik Fonksiyonu	Matlab Kodu	Hata Değeri (RMSE)
Üçgen Üyelik Fonksiyonu	trimf	808,826846
Yamuk Üyelik Fonksiyonu	trapmf	1198,149077
Çan Şekilli Üyelik Fonksiyonu	gbellmf	817,687829
Gauss Üyelik Fonksiyonu (tam simetrik)	gaussmf	728,889948
Gauss Üyelik Fonksiyonu	gauss2mf	1067,079089
Π Üyelik Fonksiyonu	pimf	1309,246356
Sigmoidal Üyelik Fonksiyonu (tam simetrik) (iki sigmoid üyelik fonksiyonu arası fark)	dsigmf	1050,823097
Sigmoidal Üyelik Fonksiyonu (iki sigmoid üyelik fonksiyonunun çarpımı)	psigmf	1050,823136

3.2. Yapay Sinir Ağları ile Eğitim

Bu sistemler, örüntü tanıma için başarıyla kullanılmaktadır ve bu nedenle arıza tespiti için uygundur. Yapay sinir ağları hiç görmediği örnekler ile karşılaştırılınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilen bir sistem yapısıdır. Yapay sinir ağlarında kullanılan öğrenme algoritmaları, verilen üniteler arasındaki bağlantı ağırlıklarını hesaplar. Bir sinir ağı, bir adet giriş katmanı, bir ya da daha fazla gizli katman ve bir adet çıkış katmanından oluşur. Bu çalışmada algoritmanın hızlı çalışması için gizli katman sayısı bir olarak alınmıştır. Şekil 3.2'de yapay sinir ağı yapısı verilmiştir (Rençber, 2018).



Şekil 3.2. *Yapay sinir ağı yapısı* (Rençber, 2018)

Çeşitli sinir ağı algoritmaları arasındaki yöntemlere bakılacak olursa ileri beslemeli eğitimler için geri yayılım yöntemi literatürde yaygın olarak kullanılmaktadır. İleri besleme ağı, aynı zamanda çok katmanlı algılayıcı (MLP) olarak adlandırılır. Bu çalışmada ileri beslemeli çok katmanlı algılayıcı kullanılmıştır. İşlemler için “Matlab Neural Network Toolbox” kullanılmıştır. Eğitim algoritması için “Levenberg Marquardt-trainlm” tercih edilmiştir. Öğrenme algoritması olarak geriye yayılım algoritması (learngdm) kullanılırken, aktivasyon fonksiyonu olarak tan-sigmoid transfer fonksiyonu (tansig) kullanılmıştır. Tan-sigmoid transfer fonksiyonunu kullanmak için giriş değerleri (-1, 1) arasında normalize edildikten sonra sonuç değerleri (-1, 1) arasında elde edilmektedir. Tan-sigmoid transfer fonksiyonu denklem 3.2’de verildiği gibi gösterilmektedir.

$$Tansig(n) = \frac{2}{(1+e^{-2n})} - 1 \quad (3.2)$$


Bir yapay sinir ağı eğitiminde en önemli parametrelerden birisi gizli katmanlarda kaç adet nöron olacağıdır. Bu durumu belirlemede kesin kurallar olmamasından dolayı genellikle belirli sayılardan başlanarak aşamalı artırma ile uygun sayı belirlenir. Az nöron kötü sonuçlar verebileceği gibi fazla nöron da ezberlemeye sebep olabilir. Yapılan bazı çalışmalarda gizli katman nöron sayısı girdi katmanı nöron sayısına eşit olarak alınabileceği gibi iki katına eşit olarak da alınabilmektedir. Başka bir çalışmada

ise girdi ve çıktı katmanı nöron sayılarının çarpımının karekökü gizli katman nöron sayısını verebilmektedir (Rençber, 2018). Gizli katmandaki nöron sayısına yapılan deneysel çalışmalar sonucunda karar verilmiştir. YSA da modelin aşırı öğrenmesinden kaçınmak amacıyla bütün veri kümesi eğitim, doğrulama ve test veri kümesi olmak üzere üç parçaya ayrılır. Modelin aşırı öğrenmediğinin kontrolü doğrulama veri kümesi üzerinden yapılır. Eğitim ve doğrulama veri kümeleri kullanılarak tamamlanan eğitim sürecinden sonra modelin gerçek performansı test veri kümesiyle ölçülür. Yapılan uygulamalarda toplam veri kümesi eğitim, doğrulama ve test kümesine rastgele olarak ayrılmıştır (%70-%15-%15). Yapay sinir ağının net çıktısı ise denklem 3.3 kullanılarak hesaplanır.

$$F(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}} \quad (3.3)$$


3.2.1. Hücum açısı için yapay sinir ağları ile eğitim

ANFIS ve YSA yöntemlerini karşılaştırabilmek için ilk olarak hücum açısı için uyarlamalı ağ tabanlı bulanık çıkarım sisteminde kullanılan **en alakalı veriler** (statik basınç, kalibre edilmiş hava hızı, yunuslama açısı, motor N1 şaftı devri) için yapay sinir ağı eğitilmiş ve test edilmiştir. Yapay sinir ağı eğitiminde giriş olarak ilgili 4 veri alınırken çıkış olarak hücum açısı verisinin kendisi alınmıştır. Şekil 3.3'te hücum açısı algılayıcısı **en alakalı veriler** için yapay sinir ağı yapısı görülmektedir.




Şekil 3.3. En alakalı verilere göre hücum açısı için yapay sinir ağı yapısı

Hücum açısı algılayıcısının 4 **en alakalı verisi** için nöron sayılarına göre ağın eğitim, doğrulama ve testi için regresyon değerleri Şekil 3.4 ve Şekil 3.5'te gösterilmiştir.




Şekil 3.4. En alakalı verilere göre hücum açısı gizli katman 4 nöron için regresyon eğrileri




Şekil 3.5. En alakalı verilere göre hücum açısı gizli katman 8 nöron için regresyon eğrileri

Hücum açısı algılayıcısı için nöron sayılarına göre test verisinin tahmininde gerçek değer ile tahmin edilen değer arası fark ölçütü ortalama RMSE değerleri gizli katman 4 nöron için 0,8780 iken 8 nöron için 0,8170 olarak bulunmuştur. ANFIS üçgen üyelik fonksiyonu için bu değer 0,914030 olarak bulunmuştur. Bundan sonra hücum açısı için **alakalı verilere** göre analiz yapılacaktır. Hücum açısı verisi ile **alakalı** 9 giriş verisi korelasyon analizi sonucu bulunmuştur. Yapay sinir ağı eğitiminde giriş olarak ilgili 9 veri alınırken çıkış olarak hücum açısı verisinin kendisi alınmıştır. Şekil 3.6'da hücum açısının 9 **alakalı** verisi için oluşturulan yapay sinir ağı modeli verilmiştir.




Şekil 3.6. Alakalı verilere göre hücum açısı için yapay sinir ağı yapısı


Hücum açısı değerinin **alakalı verileri** için 3, 9 ve 18 gizli katman nöron sayısı ayrı ayrı incelenmiştir. Hücum açısı değerinin 9 alakalı verisi için nöron sayılarına göre ağın eğitim, doğrulama ve testi için regresyon değerleri Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da gösterilmiştir. İlgili yapay sinir ağları eğitilip arızasız hücum açısı verilerine göre test edilmiştir. Hücum açısı değerinin **alakalı verileri** için gizli katman nöron sayılarına göre test verisinin tahmininde gerçek değer ile tahmin edilen değer arası fark ölçütü RMSE oranları ve ağ eğitim süreleri Tablo 3.4'te verilmiştir.



Şekil 3.7. Alakalı verilere göre hücum açısı gizli katman 3 nöron için regresyon eğrileri



Şekil 3.8. Alakalı verilere göre hücum açısı gizli katman 9 nöron için regresyon eğrileri



Şekil 3.9. Alakalı verilere göre hücum açısı gizli katman 18 nöron için regresyon eğrileri

Tablo 3.4. Alakalı verilere göre hücum açısı verisinin tahmini için RMSE ve ağ eğitim süreleri

Gizli katman nöron sayısı	RMSE değeri	Eğitim süresi (sn)
3	0,7702	1
9	0,5832	3
18	0,5127	3


Tablo 3.5’te hücum açısı için incelenen yöntemlerin içinde en düşük ortalama tahmin hata oranları verilmiştir. Buradan hücum açısı için YSA yapısının ANFIS yapısından daha doğru sonuç verdiği görülmektedir.

Tablo 3.5. Hücum açısı algılayıcısı için analiz yöntemlerinin karşılaştırılması

Analiz Yöntemi	Ortalama Tahmin Hatası Değeri (RMSE)
ANFIS üçgen üyelik fonksiyonu	0,914030
YSA 4 girişli gizli katman 8 nöronlu yapı	0,8170
YSA 9 girişli gizli katman 18 nöronlu yapı	0,5127


Tablo 3.5’ten de görüldüğü üzere hücum açısı için yapay sinir ağları tahmin işleminde daha doğru sonuçlar vermektedir. Burada giriş sayısı arttığında yapay sinir ağı daha doğru sonuç vermiştir ve hava aracı arıza tespit ve yeniden yapılandırılmasında hücum

açısı algılayıcısı için YSA 9 girişli gizli katman 18 nöronlu yapı kullanılacaktır. Ayrıca her bir yöntem için box ve whisker grafiği çizdirilmiştir. İlgili grafikler özet istatistiklerin görselleştirilmesini sağlar. Tahmin edilen algılayıcı medyan değerleri ile kutuların alt ve üst uçları baz alınarak yapılan karşılaştırmada yapay sinir ağlarının olması gereken algılayıcı değerlerine daha yakın seyrettiği görülmüştür. Hücum açısı için box ve whisker çizimleri Şekil 3.10’da verilmiştir. Bundan dolayı yeni bir algılayıcı eklemek yerine, olan arızanın tespit edilmesi ve arızalı değerlerin olması gereken algılayıcı verilerine göre yeniden yapılandırılmasında kullanılacak olan tahmin edilen değerler yapay sinir ağlarından sağlanacaktır.



Şekil 3.10. Hücum açısı için box ve whisker çizimleri

Şekil 3.11’in üst kısmında 18 nöronlu gizli katman yapısı için gerçek ve tahmin edilen hücum açısı değerleri verilmiştir. Görüldüğü gibi turuncu renk ile gösterilen tahmin edilen hücum açısı değerleri, mavi renk ile gösterilen gerçek hücum açısı değerleriyle uçuşun çoğu boyunca örtüşmektedir. Şekil 3.11’in alt kısmında ise hücum açısı verisi 18 nöronlu gizli katman yapısı için arızasız gerçek değerler “ $y(k)$ ” ile tahmin edilen değerler “ $\hat{y}(k)$ ” arası farkın mutlak değeri “ $|r(k)|$ ” verilmiştir.




Şekil 3.11. Gerçek ve tahmin edilen hücum açısı değerleri ile aralarındaki farkın mutlak değeri

Doğruluğun düz uçuş boyunca daha yüksek olduğu görülmekle beraber hücum açısı için ortalama tahmin hatası 18 nöronlu gizli katman yapısı için 0,5127’dir. Uçağın kalkışı ve inişinde çoğu ölçüm sistemi doğru sonuç vermediğinden dolayı bu kısımlarda tahmin hatası fazla olmaktadır. Bölüm 2.1’de bahsedildiği üzere hücum açısı algılayıcısı için FAA’in belirlediği değer olan $\mathcal{E}_I=10$ derece eşik değerine kadar arıza durumu olmadığı ve bu değer kabul edilebilir olduğu belirtilmektedir. Bu çalışma için de ilk olarak eşik değerin $\mathcal{E}_I=10$ derece alındığı şekilde bir değerlendirme yapılmıştır. Şekil 3.11’e göre elde edilen farkın mutlak değeri “ $|r(k)|$ ” ilgili eşik değerine göre bir değerlendirmeye tabi tutulmuştur ve sistem arızasız verilere göre test edilmesine rağmen 10621.sn de tahmin hatasından dolayı bir yanlış alarm oluştuğu görülmüştür (İlgili değer 10,1933’tür). Çalışmanın bundan sonraki kısmında ilk olarak her bir arıza senaryosu modellenecektir ve buradan elde edilen rezidü sinyallerinin mutlak değerleri “ $|r(k)|$ ” “gaussian” filtreden geçirilmek suretiyle yanlış alarm durumu giderilip arıza tespit edilmeye çalışılacaktır.

3.2.2. Hız için yapay sinir ağları ile eğitim


ANFIS ve YSA yöntemlerini karşılaştırmak için ilk olarak hız için uyarlamalı ağ tabanlı bulanık çıkarım sisteminde kullanılan **en alakalı veriler** (statik basınç, yunuslama açısı, statik hava sıcaklığı, motor N1 şaftı devri) için yapay sinir ağı

eđitilmiř ve test edilmiřtir. Yapay sinir ađı eđitiminde giriř olarak ilgili 4 veri alınırken ıkıř olarak hız verisinin kendisi alınmıřtır. řekil 3.12’de hız algılayıcısı **en alakalı veriler** için yapay sinir ađı yapısı görlmektedir.




řekil 3.12. En alakalı verilere gre hava hızı için yapay sinir ađı yapısı

Hız algılayıcısının 4 **en alakalı verisi** için nron sayılarına gre ađın eđitim, dođrulama ve testi için regresyon deđerleri řekil 3.13 ve řekil 3.14’te gsterilmiřtir.




řekil 3.13. En alakalı verilere gre hava hızı gizli katman 4 nron için regresyon eđrileri




Şekil 3.14. En alakalı verilere göre hava hızı gizli katman 8 nöron için regresyon eğrileri

Hız algılayıcısı için nöron sayılarına göre test verisinin tahmininde gerçek değer ile tahmin edilen değer arası fark ölçütü ortalama RMSE değerleri gizli katman 4 nöron için 5,3644 iken 8 nöron için 4,0871 olarak bulunmuştur. ANFIS üçgen üyelik fonksiyonu için bu değer 4,832116 olarak bulunmuştur. Bundan sonra hava hızı için **alakalı verilere** göre analiz yapılacaktır. Hız verisi ile **alakalı** 7 giriş verisi korelasyon analizi sonucu bulunmuştur. Yapay sinir ağı eğitiminde giriş olarak ilgili 7 veri alınırken çıkış olarak hız verisinin kendisi alınmıştır. Şekil 3.15'te hava hızının 7 **alakalı** verisi için oluşturulan yapay sinir ağı modeli verilmiştir.




Şekil 3.15. Alakalı verilere göre hava hızı için yapay sinir ağı yapısı


Hız değerinin **alakalı verileri** için 3, 7 ve 14 gizli katman nöron sayısı ayrı ayrı incelenmiştir. Hız değerinin 7 alakalı verisi için nöron sayılarına göre ağın eğitim, doğrulama ve testi için regresyon değerleri Şekil 3.16, Şekil 3.17 ve Şekil 3.18’de gösterilmiştir. İlgili yapay sinir ağları eğitilip arızasız hız verilerine göre test edilmiştir. Hız değerinin **alakalı verileri** için gizli katman nöron sayılarına göre test verisinin tahmininde gerçek değer ile tahmin edilen değer arası fark ölçütü RMSE oranları ve ağ eğitim süreleri Tablo 3.6’da verilmiştir.



Şekil 3.16. Alakalı verilere göre hava hızı gizli katman 3 nöron için regresyon eğrileri



Şekil 3.17. Alakalı verilere göre hava hızı gizli katman 7 nöron için regresyon eğrileri



Şekil 3.18. Alakalı verilere göre hava hızı gizli katman 14 nöron için regresyon eğrileri

Tablo 3.6. Alakalı verilere göre hız verisinin tahmini için RMSE ve ağ eğitim süreleri

Gizli katman nöron sayısı	RMSE değeri	Eğitim süresi (sn)
3	3,6107	2
7	1,8208	3
14	1,1944	3


Tablo 3.7’de hız için incelenen yöntemlerin içinde en düşük ortalama tahmin hata oranları verilmiştir. Buradan hız için YSA yapısının ANFIS yapısından daha doğru sonuç verdiği görülmektedir.

Tablo 3.7. Hız algılayıcısı için analiz yöntemlerinin karşılaştırılması

Analiz Yöntemi	Ortalama Tahmin Hatası Değeri (RMSE)
ANFIS üçgen üyelik fonksiyonu	4,832116
YSA 4 girişli gizli katman 8 nöronlu yapı	4,0871
YSA 7 girişli gizli katman 14 nöronlu yapı	1,1944


Tablo 3.7’den de görüldüğü üzere hız için yapay sinir ağları tahmin işleminde daha doğru sonuçlar vermektedir. Burada giriş sayısı arttığında yapay sinir ağı daha doğru sonuç vermiştir ve hava aracı arıza tespit ve yeniden yapılandırılmasında hız algılayıcısı için YSA 7 girişli gizli katman 14 nöronlu yapı kullanılacaktır. Ayrıca her bir yöntem

için box ve whisker grafiği çizdirilmiştir. İlgili grafikler, özet istatistiklerin görselleştirilmesini sağlar. Tahmin edilen algılayıcı medyan değerleri ile kutuların alt ve üst uçları baz alınarak yapılan karşılaştırmada yapay sinir ağlarının olması gereken algılayıcı değerlerine daha yakın seyrettiği görülmüştür. Hız için box ve whisker çizimleri Şekil 3.19’da verilmiştir. Bundan dolayı yeni bir algılayıcı eklemek yerine, olan arızanın tespit edilmesi ve arızalı değerlerin olması gereken algılayıcı verilerine göre yeniden yapılandırılmasında kullanılacak olan tahmin edilen değerler yapay sinir ağlarından sağlanacaktır.



Şekil 3.19. Hız için box ve whisker çizimleri

Şekil 3.20’nin üst kısmında 14 nöronlu gizli katman yapısı için gerçek ve tahmin edilen hız değerleri verilmiştir. Görüldüğü gibi turuncu renk ile gösterilen tahmin edilen hız değerleri, mavi renk ile gösterilen gerçek hız değerleriyle uçuşun çoğu boyunca örtüşmektedir. Şekil 3.20’nin alt kısmında ise hız verisi 14 nöronlu gizli katman yapısı için arızasız gerçek değerler “ $y(k)$ ” ile tahmin edilen değerler “ $\hat{y}(k)$ ” arası farkın mutlak değeri “ $|r(k)|$ ” verilmiştir.




Şekil 3.20. Gerçek ve tahmin edilen hız değerleri ile aralarındaki farkın mutlak değeri

Doğruluğun düz uçuş boyunca daha yüksek olduğu görülmekle beraber hız için ortalama tahmin hatası 14 nöronlu gizli katman yapısı için 1,1944'tir. Uçağın kalkışı ve inişinde çoğu ölçüm sistemi doğru sonuç vermediğinden dolayı bu kısımlarda tahmin hatası fazla olmaktadır. Bölüm 2.1'de bahsedildiği üzere hız algılayıcısı için FAA'in belirlediği değer olan $\mathcal{E}_I=4$ knot eşik değerine kadar arıza durumu olmadığı ve bu değer kabul edilebilir olduğu belirtilmektedir. Bu çalışma için de ilk olarak eşik değerin $\mathcal{E}_I=4$ knot alındığı şekilde bir değerlendirme yapılmıştır. Şekil 3.20'ye göre elde edilen farkın mutlak değeri " $|r(k)|$ " ilgili eşik değerine göre bir değerlendirmeye tabi tutulmuştur ve sistem arızasız verilere göre test edilmesine rağmen 93 noktada tahmin hatasından dolayı yanlış alarm olduğu görülmüştür. Çalışmanın bundan sonraki kısmında ilk olarak her bir arıza senaryosu modelleneyecektir ve buradan elde edilen rezidü sinyallerinin mutlak değerleri " $|r(k)|$ " "movmean" filtreden geçirilmek suretiyle yanlış alarm durumu giderilip arıza tespit edilmeye çalışılacaktır.

3.2.3. İrtifa için yapay sinir ağları ile eğitim


ANFIS ve YSA yöntemlerini karşılaştırabilmek için ilk olarak irtifa için uyarlamalı ağ tabanlı bulanık çıkarım sisteminde kullanılan **en alakalı veriler** (kalibre edilmiş hava hızı, statik hava sıcaklığı, motor N2 shaftı devri) için yapay sinir ağı eğitilmiş ve test edilmiştir. Yapay sinir ağı eğitiminde giriş olarak ilgili 3 veri alınırken

çıkış olarak irtifa verisinin kendisi alınmıştır. Şekil 3.21’de irtifa algılayıcısı **en alakalı veriler** için yapay sinir ağı yapısı görülmektedir.




Şekil 3.21. En alakalı verilere göre irtifa için yapay sinir ağı yapısı

İrtifa algılayıcısının 3 **en alakalı verisi** için nöron sayılarına göre ağı eğitimi, doğrulama ve testi için regresyon değerleri Şekil 3.22 ve Şekil 3.23’te gösterilmiştir.




Şekil 3.22. En alakalı verilere göre irtifa gizli katman 3 nöron için regresyon eğrileri




Şekil 3.23. En alakalı verilere göre irtifa gizli katman 6 nöron için regresyon eğrileri

İrtifa algılayıcısı için nöron sayılarına göre test verisinin tahmininde gerçek değer ile tahmin edilen değer arası fark ölçütü ortalama RMSE değerleri gizli katman 3 nöron için 695,4485 iken 6 nöron için 318,5639 olarak bulunmuştur. ANFIS gauss üyelik fonksiyonu (tam simetrik) için bu değer 728,889948 olarak bulunmuştur. Bundan sonra irtifa için **alakalı verilere** göre analiz yapılacaktır. İrtifa verisi ile **alakalı** 9 giriş verisi korelasyon analizi sonucu bulunmuştur. Yapay sinir ağı eğitiminde giriş olarak ilgili 9 veri alınırken çıkış olarak irtifa verisinin kendisi alınmıştır. Şekil 3.24'te irtifa verisinin 9 **alakalı** verisi için oluşturulan yapay sinir ağı modeli verilmiştir.




Şekil 3.24. Alakalı verilere göre irtifa için yapay sinir ağı yapısı


İrtifa değerinin **alakalı verileri** için 3, 9 ve 18 gizli katman nöron sayısı ayrı ayrı incelenmiştir. İrtifa değerinin 9 alakalı verisi için nöron sayılarına göre ağın eğitim, doğrulama ve testi için regresyon değerleri Şekil 3.25, Şekil 3.26 ve Şekil 3.27’de gösterilmiştir. İlgili yapay sinir ağları eğitilip arızasız irtifa verilerine göre test edilmiştir. İrtifa değerinin **alakalı verileri** için gizli katman nöron sayılarına göre test verisinin tahmininde gerçek değer ile tahmin edilen değer arası fark ölçütü RMSE oranları ve ağ eğitim süreleri Tablo 3.8’de verilmiştir.



Şekil 3.25. Alakalı verilere göre irtifa gizli katman 3 nöron için regresyon eğrileri



Şekil 3.26. Alakalı verilere göre irtifa gizli katman 9 nöron için regresyon eğrileri



Şekil 3.27. Alakalı verilere göre irtifa gizli katman 18 nöron için regresyon eğrileri

Tablo 3.8. Alakalı verilere göre irtifa verisinin tahmini için RMSE ve ağ eğitim süreleri

Gizli katman nöron sayısı	RMSE değeri	Eğitim süresi (sn)
3	188,0903	3
9	71,4425	3
18	44,9414	10


Tablo 3.9’da irtifa için incelenen yöntemlerin içinde en düşük ortalama tahmin hata oranları verilmiştir. Buradan irtifa için YSA yapısının ANFIS yapısından daha doğru sonuç verdiği görülmektedir.

Tablo 3.9. İrtifa algılayıcısı için analiz yöntemlerinin karşılaştırılması

Analiz Yöntemi	Ortalama Tahmin Hatası Değeri (RMSE)
ANFIS gauss üyelik fonksiyonu (tam simetrik)	728,889948
YSA 3 girişli gizli katman 6 nöronlu yapı	318,5639
YSA 9 girişli gizli katman 18 nöronlu yapı	44,9414


Tablo 3.9’dan da görüldüğü üzere irtifa için yapay sinir ağları tahmin işleminde daha doğru sonuçlar vermektedir. Burada giriş sayısı arttığında yapay sinir ağı daha doğru sonuç vermiştir ve hava aracı arıza tespit ve yeniden yapılandırılmasında irtifa algılayıcısı için YSA 9 girişli gizli katman 18 nöronlu yapı kullanılacaktır. Ayrıca her

bir yöntem için box ve whisker grafiği çizdirilmiştir. İlgili grafikler, özet istatistiklerin görselleştirilmesini sağlar. Tahmin edilen algılayıcı medyan değerleri ile kutuların alt ve üst uçları baz alınarak yapılan karşılaştırmada yapay sinir ağlarının olması gereken algılayıcı değerlerine daha yakın seyrettiği görülmüştür. İrtifa için box ve whisker çizimleri Şekil 3.28’de verilmiştir. Bundan dolayı yeni bir algılayıcı eklemek yerine, olan arızanın tespit edilmesi ve arızalı değerlerin olması gereken algılayıcı verilerine göre yeniden yapılandırılmasında kullanılacak olan tahmin edilen değerler yapay sinir ağlarından sağlanacaktır.



Şekil 3.28. İrtifa için box ve whisker çizimleri

Şekil 3.29’un üst kısmında 18 nöronlu gizli katman yapısı için gerçek ve tahmin edilen irtifa değerleri verilmiştir. Görüldüğü gibi turuncu renk ile gösterilen tahmin edilen irtifa değerleri, mavi renk ile gösterilen gerçek irtifa değerleriyle uçuşun çoğu boyunca örtüşmektedir. Şekil 3.29’un alt kısmında ise irtifa verisi 18 nöronlu gizli katman yapısı için arızasız gerçek değerler “ $y(k)$ ” ile tahmin edilen değerler “ $\hat{y}(k)$ ” arası farkın mutlak değeri “ $|r(k)|$ ” verilmiştir.



Şekil 3.29. Gerçek ve tahmin edilen irtifa değerleri ile aralarındaki farkın mutlak değeri

Doğruluğun düz uçuş boyunca daha yüksek olduğu görülmekle beraber irtifa için ortalama tahmin hatası 18 nöronlu gizli katman yapısı için 44,9414'tir. Uçağın kalkışı ve inişinde çoğu ölçüm sistemi doğru sonuç vermediğinden dolayı bu kısımlarda tahmin hatası fazla olmaktadır. Bölüm 2.1'de bahsedildiği üzere irtifa algılayıcısı için FAA'in belirlediği değer olan $\mathcal{E}_I=245$ ft eşik değerine kadar arıza durumu olmadığı ve bu değer kabul edilebilir olduğu belirtilmektedir. Bu çalışma için de ilk olarak eşik değerin $\mathcal{E}_I=245$ ft alındığı şekilde bir değerlendirme yapılmıştır. Şekil 3.29'a göre elde edilen farkın mutlak değeri " $|r(k)|$ " ilgili eşik değerine göre bir değerlendirmeye tabi tutulmuştur ve sistem arızasız verilere göre test edilmesine rağmen 16 noktada tahmin hatasından dolayı yanlış alarm olduğu görülmüştür. Çalışmanın bundan sonraki kısmında ilk olarak her bir arıza senaryosu modelleneyecektir ve buradan elde edilen rezidü sinyallerinin mutlak değerleri " $|r(k)|$ " "movmean" filtreden geçirilmek suretiyle yanlış alarm durumu giderilip arıza tespit edilmeye çalışılacaktır.

4. YAPAY SİNİR AĞLARI KULLANARAK GERÇEK UÇUŞ VERİLERİNE DAYALI ARIZA TESPİTİ VE SİSTEMİN YENİDEN YAPILANDIRILMASI

Elde bulunan uçuş verilerine göre her bir algılayıcı için tasarlanan yapay sinir ağları seçilen **alakalı** arızasız uçuş verilerine göre eğitilmiştir. Sonraki aşamada, uçaklar için önem arz eden hücum açısı, hız ve irtifa algılayıcılarında oluşabilecek arıza durumları ve senaryoları incelendikten sonra rasgele bir zaman aralığında meydana getirilen arıza durumları, gerçek ve yapay sinir ağı çıktısı olan beklenen algılayıcı değerleri arasındaki fark incelemesi olan rezidü sinyallerinin incelenmesine göre tespit edilmiştir. Ardından arızanın yeniden yapılandırılması ise beklenen değer olan yapay sinir ağı çıktısının çıkışa verilmesi ile yapılmıştır. Yapılan çalışmada hücum açısı, hız ve irtifa algılayıcılarında oluşabilecek bir arıza durumunda arıza tespit zamanı, yanlış alarm durumu gibi parametreler de incelenecektir. Ayrıca yanlış alarm oranının önüne geçmek için rezidü sinyali filtreden geçirilerek tekrardan sistemin başarımı ölçülecektir. Giriş olarak kullanılan verilerde ise herhangi bir arıza olmadığı varsayılmıştır ve arıza tespiti için çıkış arıza tipleri modellenmiştir. Bu çalışmada ticari uçaklar için gerçek uçuş verilerine göre hücum açısı algılayıcısında oluşabilecek osilasyon, bias (pozitif veya negatif offset, step error, üzerine sabit veri binmesi durumu), sürüklenme (drift), NRZ (Non-Return to Zero) ve gürültü tipi (white noise, random noise) arızalar incelenirken, hız algılayıcısında sürüklenme tipi arıza algılayıcıyı ölçülebilen limiti dışına çıkarttığından dolayı incelenmezken, ilgili arızalara ek olarak algılayıcı verisinin son değerinde takılma arızası (stuck error, jamming error) ve sıfırda takılma arızası incelenmiştir ve irtifa algılayıcısı için ise ilgili arızalara ek olarak sürüklenme tipi arıza incelenmiştir. İlgili algılayıcılar aerodinamik titreşimlerden etkilenir ve bu durum algılayıcı verisini osilasyona sokabilir. Ayrıca ilgili algılayıcılar manyetik çevre durumlarından dolayı bias arızaları da içerebilir. Bu sistemlerin arızalanmasının ana sebeplerinden biri pitot statik sistemin buz veya yabancı cisimler tarafından tıkanmasıdır. Pitot statik sistemde toplam basınç giriş deliği, statik hava basıncının alındığı statik basınç giriş deliği veya sistemdeki nemi dışarı atan pitot tüp tahliye deliği tıkanabilir. Örnekler arasında donabilecek su, uçak park halindeyken yuva yapan böcekler, deliklere giren diğer döküntüler veya pitot tüpü ve/veya statik delik koruyucularının uçuştan önce alınmamış olması sayılabilir. Model tabanlı yöntemler ile ilgili yapılan bazı çalışmalarda model belirsizlikleri ve ölçüm hataları olmasından

dolayı ek olarak white gaussian gürültü tüm verilerin üzerine arıza olup olmadığına bakılmaksızın giriş kısmında eklenmiştir (Freeman, Seiler and Balas, 2013; Ossmann and Joos, 2016; Guo vd., 2018; Keliris, Polycarpou and Parisini, 2018). Ancak bu çalışmada gerçek uçuş verileri ile çalışılmasından dolayı ek bir başka giriş hatası kullanılmamaktadır.


MATLAB programında hücum açısı, hız ve irtifa algılayıcıları için arıza tipleri modellenmiş ve arıza tipinin, frekansının ve genliğinin ne olacağının ve arızanın hangi saniyeler arası oluşacağını seçimine yazılım dahilinde izin verilmiştir. Arızaların oluştuğu uçuş fazları ise uçuşun yaklaşık 900.sn sonrası kalkış, yaklaşık 2500.sn sonrası düz uçuş ve yaklaşık 8500.sn sonrası iniş şekline göre modellenmiştir. Hücum açısı algılayıcısı için modellenen arızalara ait bilgiler Tablo 4.1’de verilmiştir.

Tablo 4.1. Hücum açısı algılayıcısı için modellenen arızalar


Arıza tipi $\{f(k)\}$	Arızanın oluştuğu uçuş fazı	Arıza genliği (derece)	Arıza zaman aralığı (sn) $\{t_1 \leq t \leq t_2\}$	Arıza tespit zamanı (sn)
Bias	Kalkış	10 derece	$1000 \leq t \leq 2000$	Anlık
Osilasyon	Kalkış	10 hertz frekanslı 10 derece genlikli cos dalgası	$2000 \leq t \leq 2500$	1
NRZ	Düz uçuş	10 hertz frekanslı 10 derece genlikli kare dalga	$2500 \leq t \leq 3500$	1
Sürüklenme	Düz uçuş	3 t	$7500 \leq t \leq 7505$	1
Gürültü	İniş	Rasgele gürültü	$9000 \leq t \leq 9500$	1

Arıza bindirilmiş gerçek uçuş değerleri “ $Y(k)$ ” ile yapay sinir ağından tahmin edilen olması gereken uçuş değerleri “ $\hat{y}(k)$ ” arası fark değeri olan rezidü sinyali “ $r(k)$ ”nın mutlak değeri alındıktan sonra MATLAB programında yumuşatma yöntemi “gaussian” seçilerek bu sinyalin filtrelenmesi sağlanmıştır. Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5’in üst kısımlarında Tablo 4.1’e göre modellenen bias, osilasyon, NRZ, sürüklenme ve gürültü arızaları için rezidü sinyallerinin mutlak değerlerinin filtrelenmemiş ve filtrelenmiş hali görülürken, alt kısımlarında ise analitik fazlalığa dayalı sistem ile arızalı değerlerin yeniden yapılandırılması görülmektedir. Arızalı değerlerin yeniden yapılandırılması, arıza bindirilmiş gerçek uçuş değerleri “ $Y(k)$ ”dan rezidü sinyali “ $r(k)$ ”nın çıkarılması şeklinde sağlanmaktadır ($Y(k)-r(k)$). Bu sayede arıza bindirilmiş gerçek uçuş değerleri “ $Y(k)$ ” yerine yapay sinir ağlarının kullanılmasıyla elde edilen tahmin edilen uçuş değerleri “ $\hat{y}(k)$ ”nın çıkışa aktarılması


ile anlık olarak arızaya müdahale edilebilmiştir. Burada sinyal filtrelendikten sonra $\mathcal{E}_1=10$ derece eşik değeri yerine yeni bir eşik değeri belirlenmiştir ($\mathcal{E}_2=6$ derece). Şekillerin üst kısımlarında görüldüğü üzere turuncu renk ile gösterilen filtrelenmiş sinyal ile tahmin hatası azaltılmıştır ve yanlış alarm durumunun önüne geçilmiştir (Turuncu renk ile gösterilen rezidü sinyalinin mutlak değerinin filtrelenmiş hali modellenen arıza zamanları haricinde $\mathcal{E}_2=6$ derece eşik değerini geçmemektedir). Bias tipi arıza $t=1000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=6$ derece eşik değerini aştığı kısım 1000.sn dir ve bu değer 6,0766'dır). Osilasyon tipi arıza $t=2000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=6$ derece eşik değerini aştığı kısım 2001.sn dir ve bu değer 7,6545'tir). NRZ tipi arıza $t=2500$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=6$ derece eşik değerini aştığı kısım 2501.sn dir ve bu değer 7,7283'tür). Sürüklenme tipi arıza $t=7500$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=6$ derece eşik değerini aştığı kısım 7501.sn dir ve bu değer 6,2414'tür). Gürültü tipi arıza $t=9000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=6$ derece eşik değerini aştığı kısım 9001.sn dir ve bu değer 6,7055'tir). Şekillerin alt kısımlarında tespit edilen arızanın yeniden yapılandırılması gösterilmiştir. Görüldüğü üzere yeşil renk ile gösterilen arızanın yeniden yapılandırma değerleri arıza tespit edilene kadar devrede değildir. Arıza tespit edildiği anda turuncu renk ile gösterilen arızalı " $Y(k)$ " değerlerinin, olması gereken arızasız değerler " $y(k)$ " yönünde seyretmesi sağlanmıştır. Bu şekilde yeni değerlerin çıkışa atanması ile anlık olarak arızaya müdahale edilebilmiştir. İkinci olarak hız algılayıcısı için arıza analizi yapılacaktır. Hız algılayıcısı için modellenen arızalara ait bilgiler Tablo 4.2'de verilmiştir.




Şekil 4.1. Hücum açısı algılayıcısı için bias tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.2. Hücum açısı algılayıcısı için osilasyon tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.3. Hücum açısı algılayıcısı için NRZ tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.4. Hücum açısı algılayıcısı için sürüklenme tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.5. Hücum açısı algılayıcısı için gürültü tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması

Tablo 4.2. Hız algılayıcısı için modellenen arızalar


Arıza tipi $\{f(k)\}$	Arızanın olduğu uçuş fazı	Arıza genliği (knot)	Arıza zaman aralığı (sn) $\{t_1 \leq t \leq t_2\}$	Arıza tespit zamanı (sn)
Bias	Kalkış	4 knot	$1000 \leq t \leq 1500$	Anlık
Osilasyon	Kalkış	10 hertz frekanslı 4 knot genlikli cos dalgası	$1000 \leq t \leq 2000$	Anlık
Son değerde takılma	Kalkış	286 knot	2000.sn	Anlık
Sıfırda takılma	Düz uçuş	Sıfır	8000.sn	Anlık
NRZ	İniş	10 hertz frekanslı 4 knot genlikli kare dalga	$8500 \leq t \leq 9000$	Anlık
Gürültü	İniş	Rasgele gürültü	$9000 \leq t \leq 9500$	Anlık

Arıza bindirilmiş gerçek uçuş değerleri “ $Y(k)$ ” ile yapay sinir ağından tahmin edilen olması gereken uçuş değerleri “ $\hat{y}(k)$ ” arası fark değeri olan rezidu sinyali “ $r(k)$ ”nın mutlak değeri alındıktan sonra MATLAB programında yumuşatma yöntemi “movmean” seçilerek bu sinyalin filtrelenmesi sağlanmıştır. Şekil 4.6, Şekil 4.7, Şekil 4.8, Şekil 4.9, Şekil 4.10 ve Şekil 4.11’in üst kısımlarında Tablo 4.2’ye göre modellenen bias, osilasyon, son değerde takılma, sıfırda takılma, NRZ ve gürültü arızaları için rezidu sinyallerinin mutlak değerlerinin filtrelenmemiş ve filtrelenmiş hali görülürken, alt kısımlarında ise analitik fazlalığa dayalı sistem ile arızalı değerlerin yeniden yapılandırılması görülmektedir. Burada sinyal filtrelendikten sonra $\mathcal{E}_I=4$ knot


eşik değeri yerine yeni bir eşik değeri belirlenmiştir ($\mathcal{E}_2=3$ knot). Şekillerin üst kısımlarında görüldüğü üzere turuncu renk ile gösterilen filtrelenmiş sinyal ile tahmin hatası azaltılmıştır ve yanlış alarm durumunun önüne geçilmiştir (Turuncu renk ile gösterilen rezidü sinyalinin mutlak değerinin filtrelenmiş hali, modellenen arıza zamanları haricinde $\mathcal{E}_2=3$ knot eşik değerini geçmemektedir). Bias tipi arıza $t=1000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=3$ knot eşik değerini aştığı kısım 1000.sn dir ve bu değer 3,0042'dir). Osilasyon tipi arıza $t=1000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=3$ knot eşik değerini aştığı kısım 1000.sn dir ve bu değer 3,0006'dir). Son değerde takılma tipi arıza $t=2000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=3$ knot eşik değerini aştığı kısım 2000.sn dir ve bu değer 3,1199'dur). Sıfırda takılma tipi arıza $t=8000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=3$ knot eşik değerini aştığı kısım 8000.sn dir ve bu değer 125,7958'dir). NRZ tipi arıza $t=8500$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=3$ knot eşik değerini aştığı kısım 8500.sn dir ve bu değer 3,2303'tür). Gürültü tipi arıza $t=9000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=3$ knot eşik değerini aştığı kısım 9000.sn dir ve bu değer 3,0192'dir). Şekillerin alt kısımlarında tespit edilen arızanın yeniden yapılandırılması gösterilmiştir. Görüldüğü üzere yeşil renk ile gösterilen arızanın yeniden yapılandırma değerleri arıza tespit edilene kadar devrede değildir. Arıza tespit edildiği anda turuncu renk ile gösterilen arızalı " $Y(k)$ " değerlerinin, olması gereken arızasız değerler " $y(k)$ " yönünde seyretmesi sağlanmıştır. Bu şekilde yeni değerlerin çıkışa atanması ile anlık olarak arızaya müdahale edilebilmiştir. Son olarak irtifa algılayıcısı için arıza analizi yapılacaktır. İrtifa algılayıcısı için modellenen arızalara ait bilgiler Tablo 4.3'te verilmiştir.




Şekil 4.6. Hız algılayıcısı için bias tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.7. Hız algılayıcısı için osilasyon tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.8. Hız algılayıcısı için son değerde takılma tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.9. Hız algılayıcısı için sıfırda takılma tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.10. Hız algılayıcısı için NRZ tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.11. Hız algılayıcısı için gürültü tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması

Tablo 4.3. İrtifa algılayıcısı için modellenen arızalar


Arıza tipi $\{f(k)\}$	Arızanın oluştuğu uçuş fazı	Arıza genliği (ft)	Arıza zaman aralığı (sn) $\{t_1 \leq t \leq t_2\}$	Arıza tespit zamanı (sn)
Son değerde takılma	Kalkış	3433 ft	1000.sn	1
Osilasyon	Kalkış	10 hertz frekanslı 245 ft genlikli cos dalgası	$2000 \leq t \leq 2500$	1
NRZ	Düz uçuş	10 hertz frekanslı 245 ft genlikli kare dalga	$2500 \leq t \leq 3500$	1
Bias	Düz uçuş	245 ft	$6000 \leq t \leq 7000$	1
Sürüklenme	İniş	100 t	$8500 \leq t \leq 8505$	2
Gürültü	İniş	Rasgele gürültü	$9000 \leq t \leq 9500$	2

Arıza bindirilmiş gerçek uçuş değerleri “ $Y(k)$ ” ile yapay sinir ağından tahmin edilen olması gereken uçuş değerleri “ $\hat{y}(k)$ ” arası fark değeri olan rezidü sinyali “ $r(k)$ ”nın mutlak değeri alındıktan sonra MATLAB programında yumuşatma yöntemi “movmean” seçilerek bu sinyalin filtrelenmesi sağlanmıştır. Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.15, Şekil 4.16 ve Şekil 4.17’nin üst kısımlarında Tablo 4.3’e göre modellenen son değerde takılma, osilasyon, NRZ, bias, sürüklenme ve gürültü arızaları için rezidü sinyallerinin mutlak değerlerinin filtrelenmemiş ve filtrelenmiş hali görülürken, alt kısımlarında ise analitik fazlalığa dayalı sistem ile arızalı değerlerin yeniden yapılandırılması görülmektedir. Burada sinyal filtrelendikten sonra $\mathcal{E}_1=245$ ft eşik değeri yerine yeni bir eşik değeri belirlenmiştir ($\mathcal{E}_2=200$ ft). Şekillerin üst kısımlarından da görüldüğü üzere turuncu renk ile gösterilen filtrelenmiş sinyal ile tahmin hatası azaltılmıştır ve yanlış alarm durumunun önüne geçilmiştir (Turuncu renk ile gösterilen rezidü sinyalinin mutlak değerinin filtrelenmiş hali, modellenen arıza zamanları haricinde $\mathcal{E}_2=200$ ft eşik değerini geçmemektedir). Son değerde takılma tipi arıza $t=1000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=200$ ft eşik değerini aştığı kısım 1001.sn dir ve bu değer 217,3155’tir). Osilasyon tipi arıza $t=2000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=200$ ft eşik değerini aştığı kısım 2001.sn dir ve bu değer 205,4546’dır). NRZ tipi arıza $t=2500$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=200$ ft eşik değerini aştığı kısım 2501.sn dir ve bu değer 214,9188’dır). Bias tipi arıza $t=6000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=200$ ft eşik değerini aştığı kısım 6001.sn dir ve bu değer 215,3199’dur). Sürüklenme tipi arıza $t=8500$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=200$ ft eşik değerini aştığı kısım 8502.sn dir ve bu değer 207,8470’tir). Gürültü tipi


arıza $t=9000$.sn de oluşturulmuştur (Turuncu renk ile gösterilen filtrelenmiş sinyalin $\mathcal{E}_2=200$ ft eşik değerini aştığı kısım 9002.sn dir ve bu değer 200,6567’dir). Şekillerin alt kısımlarında tespit edilen arızanın yeniden yapılandırılması gösterilmiştir. Görüldüğü üzere yeşil renk ile gösterilen arızanın yeniden yapılandırma değerleri arıza tespit edilene kadar devrede değildir. Arıza tespit edildiği anda turuncu renk ile gösterilen arızalı “ $Y(k)$ ” değerlerinin, olması gereken arızasız değerler “ $y(k)$ ” yönünde seyretmesi sağlanmıştır. Bu şekilde yeni değerlerin çıkışa atanması ile anlık olarak arızaya müdahale edilebilmiştir. İrtifa algılayıcısı arızası, hız algılayıcısına göre 1-2 sn süreyle tespit edilebilmiştir. Çünkü kalkış ve inişte bağımsız bir kaynak olan radyo altimetre sistemi kullanıldığından dolayı sonuçlar ilgili şekilde elde edilmektedir.




Şekil 4.12. İrtifa algılayıcısı için son değerde takılma tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.13. İrtifa algılayıcısı için osilasyon tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması




Şekil 4.14. İrtifa algılayıcısı için NRZ tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.15. İrtifa algılayıcısı için bias tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.16. İrtifa algılayıcısı için sürüklenme tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması



Şekil 4.17. İrtifa algılayıcısı için gürültü tipi arıza tespiti ve arızalı değerlerin yeniden yapılandırılması

5. TARTIŞMALAR

Bu çalışmanın giriş kısmında bahsedilen literatürdeki model tabanlı ve gerçek uçuş verilerine göre yapılan çalışmalara göre farkları şu şekildedir: Model tabanlı çalışmalarda model belirsizlikleri ve ölçüm hataları olmasından dolayı bu çalışmada ticari uçaklara ait gerçek uçuş verilerinin kullanılmasıyla uçaklardaki hücum açısı, hız ve irtifa algılayıcıları için arıza tespit ve yeniden yapılandırma sistemi oluşturulmaya çalışılmıştır. Bahsedilen çalışmalar çoğunlukla düz uçuş için belirli algılayıcılar ve belirli arıza durumları için yapılmıştır. Ayrıca ilgili çalışmalarda arıza tespit zamanı gecikmesi ve yanlış alarm durumu da görülmektedir. Ancak bu çalışmada hücum açısı, hız ve irtifa algılayıcılarında tek bir arıza tipi yerine tüm uçuş fazlarında karşılaşılabilecek farklı arıza senaryoları (osilasyon, bias, takılma, sıfırda takılma, sürüklenme, NRZ ve gürültü tipi arızalar) incelenmiştir. Ayrıca, otoritelerce izin verilen arıza limitleri hesaba alınmıştır ve arıza durumları modellenmiştir. Yapılan çalışmada yanlış alarm durumunu gidermek için kullanılan sinyaller filtrelenerek 0-2 sn aralığında bir arıza tespiti gerçekleştirilmiştir. Yapılan çalışmada uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağlarının (YSA) kullanılmasıyla elde edilen test verisi beklenen değerinin tahmini kısımları, RMSE değerlerine bakılarak her iki yöntem için karşılaştırılmıştır. Yapay sinir ağlarının daha doğru sonuç verdiği gözlemlenmiştir (En iyi sonuç hücum açısı algılayıcısı için 0,5127'lik RMSE değeriyle 18 nöronlu gizli katman yapısı iken, hız algılayıcısı için 1,1944'lük RMSE değeriyle 14 nöronlu gizli katman yapısı ve irtifa algılayıcısı için 44.9414'lük RMSE değeriyle 18 nöronlu gizli katman yapısıdır). Yapay sinir ağları ile tahmin yönteminin kalman filtresi veya luenberger gözleyicisi gibi literatürde kullanılan model tabanlı yöntemlere göre avantajı, yapay sinir ağları yönteminin belli bir modele bağlı olmaması ve hata toleranslı olmasıdır. Yapay sinir ağlarının hata toleransı olmasından dolayı giriş sistemlerinde oluşabilecek bir arıza tahmin hatasını fazla artırmayacağından dolayı yine yaklaşık bir çözüm üretilebilecektir. Bu sayede belirli kabuller altında kalmadan uçak gibi doğrusal olmayan sistemler için rahatlıkla kullanılabilir. Yapay sinir ağı eğitiminde hücum açısı için korelasyon analizi ile bulunan ilgili 9 veri giriş olarak alınırken, hücum açısı verisinin kendisi de çıkış olarak alınmıştır. Aynı şekilde hız için korelasyon analizi ile bulunan ilgili 7 veri giriş olarak alınırken, hız verisinin kendisi de çıkış olarak alınmıştır. Son olarak irtifa için korelasyon analizi ile bulunan ilgili 9 veri giriş olarak alınırken, irtifa verisinin kendisi de çıkış olarak alınmıştır (Giriş olarak

kullanılan verilerde herhangi bir arıza bulunmamaktadır). Gizli katmanlardaki nöron sayısına yapılan deneysel çalışmalar sonucunda karar verilmiştir. Yapılan tüm uygulamalarda toplam veri kümesi eğitim, doğrulama ve test kümesine rastgele olarak ayrılmıştır. Hücüm açısı, hız ve irtifa algılayıcıları için arızasız uçuş durumlarına göre eğitilen yapay sinir ağlarının oluşturulan arıza senaryolarını, elde edilen rezidü sinyallerinin (arıza bindirilmiş gerçek uçuş değerleri ile tahmin edilen olması gereken uçuş değerleri arası fark sinyalleri) mutlak değerine göre tespit etmesi beklenmiştir. Yapay sinir ağları kullanarak yapılan çalışmada tahmin hatası giderilmeden arıza tespiti yapılmıştır ve yanlış alarm durumu oluşturduğu görülmüştür (Hücüm açısı algılayıcısı için 10621.sn de arıza olmamasına rağmen yanlış alarm oluşurken, hız algılayıcısı için tam 93 noktada yanlış alarm oluşmuştur ve irtifa algılayıcısı için tam 16 noktada yanlış alarm görülmüştür). İkinci kısımda ise tahmin hatasının giderilmesi için bir filtrenin kullanılmasıyla (Rezidü sinyalinin mutlak değeri hücüm açısı algılayıcısı için “gaussian” filtre ile yumuşatılırken, hız ve irtifa algılayıcıları için “movmean” filtre ile yumuşatılmıştır) yanlış alarm durumu giderilmiştir. Arıza modellemeleri sonucu elde edilen arızalı test verileri ile de arıza analizi yapılmıştır. Buna göre elde edilen rezidü sinyallerinin mutlak değerleri belirli bir eşik değerine göre değerlendirilmiştir. Arıza tespit edildikten sonra arızalı veriler yapay sinir ağlarından tahmin edilen olması gereken algılayıcı verilerine göre yeniden yapılandırılmıştır. Burada dikkat edilmesi gereken nokta arızanın yeniden yapılandırılması için kullanılan verilerin hiçbir yedekli elemandan gelmemesi ve diğer verilerden tahmin edilerek bulunmasıdır. Bu sayede analitik fazlalığa dayalı bir arıza tespit ve yeniden yapılandırma sistemi elde edilebilmiştir.

6. SONUÇLAR

Yapılan çalışma uçaklar için genel olarak kullanılmakta olan bir arıza tespit ve yeniden yapılandırma sisteminin olmamasından yola çıkılarak hazırlanmıştır. Uçaklarda genel olarak iki algılayıcı arasında belli bir tutarsızlık varsa bu durum göstergelere sunulmaktadır. Uçuş ekibi böyle durumlarda belli prosedürlere bağlı kalarak veya diğer göstergeler ve veriler ile karşılaştırma yoluna giderek sorunun kaynağını bulmaya çalışmaktadır. Arızanın yeniden yapılandırılması ise yedek olarak kullanılan üçüncü algılayıcı verisinin göstergeye atanmasıyla yapılmaktadır. Ancak örneğin yedek algılayıcılarda buzlanma gibi olumsuz bir durum olması durumunda, arıza tespiti gerçekleştirilemeyecektir. Yedekli donanım sisteminin dezavantajları arasında tam güvenli bir sistem olmaması, maliyeti artırması, ağırlığı artırması, ağırlığın artması ile yakılan yakıtı artırması ve gidilen menzili azaltması sayılabilir. Donanım fazlalığına dayanan bu yöntemlerin kullanımı yerine bilgisayarlı hesaplama yöntemleri ile tasarlanan analitik fazlalığa dayalı sistem sayesinde uçuş ekibi için zaman kaybı önlenirken, donanım fazlalığı azaltılarak ağırlık ve üretim/bakım maliyetlerinden tasarruf edilebilecektir. Ağırlığın azaltılmasıyla birlikte yakılan yakıt daha az olacaktır ve hava aracının daha uzun mesafe gidebilmesi sağlanabilecektir. Ayrıca CO₂ emisyonu ve gürültü azaltılarak hava aracının daha çevre dostu uçuşlar gerçekleştirmesi sağlanabilecektir. Böylece önerilen sistem yapısı hava veri bilgisayarı tarafından gerçekleştirilen geleneksel hesaplama yöntemine göre hücum açısı, hava hızı ve irtifa değerlerini hesaplamak için daha basit olan alternatif bir yöntem sağlamaktadır. Kullanılan yöntemler olarak makine öğrenmesi yöntemleri sistem karmaşıklığı, hesaplaması ve maliyetini fazla artırmadan doğru ve hızlı bir arıza tespiti ve arızanın yeniden yapılandırmasını gerçek zamanlı sistemler için gerçekleştirebilir kılmaktadır. Ayrıca, ticari uçaklarda kullanılan yedek hız ölçeği (BUSS) ve sentetik hava hızı (SAS) gibi sistemlere alternatif olacak şekilde tasarlanan sistem yapısı veri tahmini için daha fazla parametre içermektedir. Bu çalışmada incelenen değişken ile ilişkili girdi parametrelerinin ve gizli katman nöron sayılarının fazla sayıda olmasının daha iyi veri tahmini sağladığı bulunmuştur. Tasarlanan sistem ile uçuş ekibini arıza durumunda erkenden uyarmak ve hava araçlarında yaşanabilecek kazaları önlemek için ilgili hava araçlarına gerçek zamanlı bir sistem kurulabilir ve bu sayede ilgili hava araçlarının operasyonlarını yüksek arıza tespit oranıyla gerçekleştirirken daha doğru ve daha güvenli bir sistem yapısı sunulmaktadır.

KAYNAKÇA

- Alvarez, O. H., Zea, L. B. G., Bil, C., Napolitano, M. and Fravolini, M. L. (2019). Review of methodologies for aircraft sensors fault detection and correction. *International Symposium on Space Flight Dynamics*, Melbourne, Australia, 259-264.
- Azzawi, D. A., Perhinschi, M. G., Moncayo, H. and Perez, A. (2015). A dendritic cell mechanism for detection, identification, and evaluation of aircraft failures. *Control Eng. Pract.*, 41, 134-148.
- Bagherzadeh, S. A. (2020). Nonlinear aeroelastic modeling of aircraft using support vector machine method. *Aircraft Engineering and Aerospace Technology*, 92 (3), 502-518.
- Baptista, M. L., Henriques, E. M. P. and Prendinger, H. (2021). Classification prognostics approaches in aviation. *Measurement*, 182 (109756).
- Basturk, O. and Cetek, C. (2021). Prediction of aircraft estimated time of arrival using machine learning methods. *The Aeronautical Journal*, 125 (1289), 1245-1259.
- Bauer, P., Venkataraman, R., Vanek, B., Seiler, P. J. and Bokor, J. (2018). Fault detection and basic in-flight reconfiguration of a small UAV equipped with elevons. *10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes*, Warsaw, Poland, 600-607.
- Bilgin, M. (2018). *Makine öğrenmesi*. İstanbul: Papatya.
- Carbaugh, D., Forsythe, D. and McIntyre, M. (1999). Erroneous flight instruments. *Aero8*.
- Cashman, J. E., Kelly, B. D. and Nield, B. N. (2000). Operational use of angle of attack on modern commercial jet airplanes. *Aero12*, 12-21.
- Castaldi, P., Mimmo, N. and Simani, S. (2017). Avionic air data sensors fault detection and isolation by means of singular perturbation and geometric approach. *Sensors*, 17 (2202), 1-19.
- Castillo, I. and Edgar, T. (2008). Model-based fault detection and diagnosis. *TWCCC Conference, Austin, Texas*.
- Chen, H., Shang, J., Zhao, X., Li, X., Zheng, L. and Chen, F. (2020). A Deep learning Method for Landing Pitch Prediction based on Flight Data. *IEEE 2nd International Conference on Civil Aviation Safety and Information Technology*, Weihai, China, 199-204.
- Collinson, R.P.G. (2003). *Introduction to avionics systems*. New York: Springer.
- Dalkiran, F. Y. and Toraman, M. (2020). Predicting thrust of aircraft using artificial neural networks. *Aircraft Engineering and Aerospace Technology*, 92 (2), 237-255.

- Dalmau, R., Ballerini, F., Naessens, H., Belkoura, S. and Wangnick, S. (2021). An explainable machine learning approach to improve take-off time predictions. *Journal of Air Transport Management*, 95 (102090).
- Duda, R. O., Hart, P. E. and Stork, D. G. (2000). *Pattern classification*. New York: John Wiley & Sons.
- Eroglu, B., Sahin, C., Yuksek, B., Ure, N. K. and Inalhan, G. (2018). Deep recurrent and convolutional networks for accelerated fault tolerant adaptive flight control under severe failures. *Proc. Am. Control Conf.*, Milwaukee, Wisconsin, USA, 6569-6565.
- Eykeren, L.V., Chu, Q. P. and Mulder, J. A. (2012). Sensor fault detection and isolation using adaptive extended Kalman Filter. *8th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, Mexico City, Mexico, 1155-1160.
- Eykeren, L.V., Chu, Q. P. and Mulder, J. A. (2012). Actuator fault detection by aerodynamic model identification. *8th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, Mexico City, Mexico, 1353-1357.
- Fekih, A. (2014). Fault diagnosis and fault tolerant control design for aerospace systems: A bibliographical review. *American Control Conference*, Portland, Oregon, USA, 1286-1291.
- Fravolini, M. L., Napolitano, M. R., Core, G. and Papa, U. (2018). Experimental interval models for the robust fault detection of aircraft air data sensors. *Control Eng. Pract.*, 78, 196-212.
- Freeman, P., Seiler, P. and Balas, G. J. (2011). Robust fault detection for commercial transport air data probes. *18th IFAC World Congress*, Milan, Italy, 1373-13728.
- Freeman, P., Seiler, P. and Balas, G. J. (2013). Air data system fault modeling and detection. *Control Eng. Pract.*, 21 (10), 1290-1301.
- Gao Y., Yang, T., Xing, N. and Xu, M. (2012). Fault detection and diagnosis for spacecraft using principal component analysis and support vector machines. *7th IEEE Conf. Ind. Electron. Appl.*, Singapore, 1984-1988.
- Garcia, C. E., Camana, M. R. and Koo, I. (2021). Machine learning-based scheme for multi-class fault detection in turbine engine disks. *ICT Express*, 7 (1), 15-22.
- Guo, D., Wang, Y., Zhong, M. and Zhao, Y. (2018). Fault detection and isolation for Unmanned Aerial Vehicle sensors by using extended PMI filter. *10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes*, Warsaw, Poland, 818-823.
- Gupta, K., Emran, B. J. and Najjaran, H. (2019), Vision-based pose estimation of a multi-rotor unmanned aerial vehicle. *International Journal of Intelligent Unmanned Systems*, 7 (3), 120-132.

- Hansen, S., Blanke, M. and Adrian, J. (2010). Diagnosis of UAV pitot tube defects using statistical change detection. *7th IFAC Symposium on Intelligent Autonomous Vehicles*, Lecce, Italy, 485-490.
- He, Q., Zhang, W., Lu, P. and Liu, J. (2020). Performance comparison of representative model-based fault reconstruction algorithms for aircraft sensor fault detection and diagnosis. *Aerosp. Sci. Technol.*, 98 (105649).
- Huo, J., Keung, K. L., Lee, C. K. M., Ng, K. K. H. and Lee, K. C. (2020). The prediction of flight delay: Big data-driven machine-learning approach. *IEEE International Conference on Industrial Engineering and Engineering Management*, Singapore, 190-194.
- Isermann, R. (2005). Model-based fault detection and diagnosis status and applications. *Annu. Rev. Control*, 29 (1), 71-85.
- Isermann, R. (2006). *Fault-diagnosis systems*. Berlin: Springer.
- Işık, G., Ekici, S. and Şahin, G. (2020). A neural network model for UAV propulsion system. *Aircraft Engineering and Aerospace Technology*, 92 (8), 1177-1184.
- Jaradat, M. A. K. and Langari, R. (2009). A hybrid intelligent system for fault detection and sensor fusion. *Appl. Soft Comput. J.*, 9 (1), 415-422.
- Jiang, L., Xue, C., Cui, J., Yu, M., Pu, X. and Shi, J. (2015). Research recognition of aircraft engine abnormal state. *27th Chinese Control Decis. Conf.*, Qingdao, China, 4625-4630.
- Jing, T., Yang, C., Yang, Y. and Shi, X. (2011). Simulation and fault detection for aircraft IDG system. *Procedia Eng.*, 15, 2533-2537.
- Kayaalp, K. and Metlek, S. (2021). Prediction of burning performance and emissions indexes of a turboprop motor with artificial neural network. *Aircraft Engineering and Aerospace Technology*, 93 (3), 394-409.
- Keliris, C., Polycarpou, M. M. and Parisini, T. (2018). An adaptive approach to sensor bias fault diagnosis and accommodation for a class of input-output nonlinear systems. *IEEE Conference on Decision and Control*, Miami, Florida, USA.
- Khan, W. A., Ma, H. L., Chung, S. H. and Wen, X. (2021). Hierarchical integrated machine learning model for predicting flight departure delays and duration in series. *Transportation Research Part C: Emerging Technologies*, 129 (103225).
- Kıyak, E. and Ünal, G. (2021). Small aircraft detection using deep learning. *Aircraft Engineering and Aerospace Technology*, 93 (4), 671-681.
- Kurt, B., (2018). *Tahmin yöntemleri ile uçak verilerinin işlenmesi*. Yayımlanmış Doktora Tezi. Kayseri: Erciyes Üniversitesi, Fen Bilimleri Enstitüsü.
- Lijia, C., Yu, T. and Guo, Z. (2019). Adaptive observer-based fault detection and active tolerant control for unmanned aerial vehicles attitude system. *5. IFAC*

Symposium on Telematics Applications, Chengdu, China, 47-52.

- Lu, P., Kampen, E. J. V., Visser, C. and Chu, Q. (2020). Air data sensor fault detection and diagnosis in the presence of atmospheric turbulence: theory and experimental validation with real flight data. *IEEE Trans. Control Syst. Technol.*, 1-9.
- Mako, S., Pilat, M., Svab, P., Kozuba, J. and Cicvakova, M. (2020). Evaluation of MCAS system. *Acta Avionica Journal*, 40 (1), 21-28.
- Meel, P., Singhal, M., Tanwar, M. and Saini, N. (2020). Predicting Flight Delays with Error Calculation using Machine Learned Classifiers. *7th International Conference on Signal Processing and Integrated Networks*, Noida, India, 71-76.
- Miljković, D. (2011). Fault detection methods: A literature survey. *MIPRO, 2011 Proceedings of the 34th International Convention*, Opatija, Croatia, 110-115.
- Nimmagadda, S., Sivakumar, S., Kumar, N. and Haritha, D. (2020). Predicting Airline Crash due to Birds Strike Using Machine Learning. *7th International Conference on Smart Structures and Systems*, Chennai, India, 1-4.
- Oliveira, L. R. M. (2013). The dramatic effects of pitot static system blockages and failures. *Luizmonteiro*, 1-51.
http://www.luizmonteiro.com/DocumentsPDF/The_Dramatic_Effects_of_Pitot_Static_Blockages.pdf. (Erişim tarihi: 01.06.2021).
- Ossmann, D. and Joos, H. D. (2016). Enhanced detection and isolation of angle of attack sensor faults. *AIAA Guidance, Navigation and Control Conference*, San Diego, California, USA, 1-16.
- Popowski, S. and Dabrowski, W. (2015). Measurement and estimation of the angle of attack and the angle of sideslip. *Vilnius Gedim. Tech. Univ. Press*, 19 (1), 19-24.
- Puranik, T. G., Rodriguez, N. and Mavris, D. N. (2020). Towards online prediction of safety-critical landing metrics in aviation using supervised machine learning. *Transportation Research Part C: Emerging Technologies*, 120 (102819).
- Rençber, Ö. F. (2018). *Sınıflandırma problemlerinde çoklu lojistik Regresyon, yapay sinir ağı ve ANFIS yöntemlerinin karşılaştırılması: İnsani gelişmişlik endeksi üzerine uygulama*. Ankara: Gazi kitabevi.
- Samy, I., Postlethwaite, I. and Gu, D. (2011). Survey and application of sensor fault detection and isolation schemes. *Control Eng. Pract.*, 19 (7), 658-674.
- Sercekman, O. and Kutay, A. T. (2018). A model based approach for sensor fault detection in civil aircraft control surface. *IEEE/ION Position, Location and Navigation Symposium*, Monterey, California, USA, 715-729.
- Shi, X., Ren, G., Li, J. and Zhang, S. (2011). Fault diagnosis method research of aircraft ignition system based on waveform image matching. *Procedia Eng.*, 15, 2527-2532.

- Simani, S., Bonfè, M., Castaldi, P. and Geri, W. (2006). Application of fault diagnosis methodologies to a general aviation aircraft. *6th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, Beijing, China, 180-185.
- Singh, S. and Vasudeviah, R. M. T. (2012). Neural network based sensor fault detection for flight control systems. *International Journal of Computer Applications*, 59 (13), 1-8.
- Taimoor, M. and Aijun, L. (2019). Neural-sliding mode approach-based adaptive estimation, isolation and tolerance of aircraft sensor fault. *Aircraft Engineering and Aerospace Technology*, 92 (2), 237-255.
- Taimoor, M., Lu, X., Maqsood, H. and Sheng, C. (2021). Adaptive rapid neural observer-based sensors fault diagnosis and reconstruction of quadrotor unmanned aerial vehicle. *Aircraft Engineering and Aerospace Technology*, 93 (5), 847-861.
- Turkmen, I. (2018). An alternative neural airspeed computation method for aircrafts. *Aircraft Engineering and Aerospace Technology*, 90 (2), 368-378.
- Varga, A., Ossmann, D. and Joos, H. D. (2014). A fault diagnosis based reconfigurable longitudinal control system for managing loss of air data sensors for a civil aircraft. *19th IFAC World Congress*, Cape Town, South Africa, 3489-3496.
- Verma, H. O. and Peyada, N. K. (2019). Parameter estimation of aircraft using extreme learning machine and Gauss-Newton algorithm. *The Aeronautical Journal*, 124 (1272), 271-295.
- Verma, H. O. and Peyada, N. K. (2020). Aircraft parameter estimation using ELM network. *Aircraft Engineering and Aerospace Technology*, 92 (6), 895-907.
- Verma, H. O. and Peyada, N. K. (2021). Estimation of aerodynamic parameters near stall using maximum likelihood and extreme learning machine-based methods. *Aeronautical Journal*, 125 (1285), 489-509.
- Yan, W. and Zhou, J. (2018). Early fault detection of aircraft components using flight sensor data. *IEEE 23rd International Conference on Emerging Technologies and Factory Automation*, Turin, Italy, 337-342.
- Yazar, I., Kiyak, E., Caliskan, F. and Karakoc, T.H. (2018). Simulation-based dynamic model and speed controller design of a small-scale turbojet engine. *Aircraft Engineering and Aerospace Technology*, 90 (2), 351-358.
- Yuan, H., Lu, C., Ma, J. and Chen, Z. H. (2015). Neural network-based fault detection method for aileron actuator. *Appl. Math. Model.*, 39 (19), 5803-5815.
- Yüksel E., (2019). Lion air ve etiopya havayolları kazalarının ardından B737 max mcas. *UTED*, Nisan (368), 48-49.
- Zhang, P., Zhang, R. and Ran, X. X. (2011). Research of fault diagnosis in flight control system based on fuzzy neural network. *Procedia Eng.*, 15, 70-74.

- Zhao, X., Wang, S., Zhang, J., Fan, Z. and Min, H. (2013). Real-time fault detection method based on belief rule base for aircraft navigation system. *Chinese J. Aeronaut.*, 26 (3), 717-729.
- Zhao, Z., Sun, Y. and Zhang, J. (2015). PCA-based sensor fault diagnosis for aero-engine. *27th Chinese Control Decis. Conf.*, Qingdao, China, 2679-2683.
- Zolghadri, A., Cieslak, J., Efimov, D., Henry, D., Philippe, G., Dayre, R., Gheorghe, A. and Berre, H. L. (2015). Signal and model-based fault detection for aircraft systems. *9. IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes*, Paris, France, 1096-1101.



ÖZGEÇMİŞ

Adı Soyadı: Uğur KILIÇ

Yabancı Dil: İngilizce

Eğitim Geçmişi:

Yüksek Lisans, Mezuniyet Yılı: 2016, Fırat Üniversitesi, Fen Bilimleri Enstitüsü,
Elektrik Elektronik Mühendisliği Bölümü, Elektrik Elektronik Mühendisliği
Anabilim Dalı

Lisans, Mezuniyet Yılı: 2013, Fırat Üniversitesi, Mühendislik Fakültesi, Elektrik
Elektronik Mühendisliği Bölümü

Mesleki Geçmişi:

2016-Halen, Araştırma Görevlisi, Eskişehir Teknik Üniversitesi, Havacılık ve Uzay
Bilimleri Fakültesi, Havacılık Elektrik ve Elektronik Bölümü

2013-2016, Araştırma Görevlisi, Harran Üniversitesi, Mühendislik Fakültesi, Elektrik
Elektronik Mühendisliği Bölümü

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

Makaleler:

1. Kilic, U. and Unal, G. (2021). Aircraft air data system fault detection and reconstruction scheme design. *Aircraft Engineering and Aerospace Technology*, <https://doi.org/10.1108/AEAT-01-2021-0018>
2. Guler, H. and Kilic, U. (2017). The development of a novel knowledge-based weaning algorithm using pulmonary parameters: a simulation study. *Med Biol Eng Comput.*, 56, 373-384.
3. Guler, H., Kilic, U. and Kaya, T. (2016). The design of fuzzy based weaning protocol in LabVIEW environment. *International Journal of Artificial*

Kitap Bölümü:

1. Kilic, U., Gulluoglu, M.T., Guler, H. and Kaya, T. (2016). Analysis of pulmonary and hemodynamic parameters for the weaning process by using fuzzy logic based technology. *Communications in Computer and Information Science* içinde (s. 119-131). Switzerland: Springer International Publishing.

Bildiriler:

1. Kilic, U. and Unal, G. (2021). Model-based fault detection and reconfiguration system for commercial aircrafts. *3rd International Applied Mathematics, Modelling and Simulation Conference*, Paris, France.
2. Kilic, U and Unal, G. (2019). Sensor fault detection and fault isolation scheme for unmanned aerial vehicle. *2nd International Conference on Innovative Research in Science Engineering and Technology*, Roma, Italy.
3. Kilic, U., Unal, G., Kiyak, E. and Ayturan, K. (2017). Using full-order observer in the form of generalized observer scheme to detect and isolate aircraft sensor faults in automatic flight control systems. *8th International Advanced Technologies Symposium*, Elazig, Turkey.
4. Ayturan, K., Kilic, U. and Gulluoglu, M.T. (2017). Pre-diagnosis of diseases using genetic algorithms. *8th International Advanced Technologies Symposium*, Elazig, Turkey.

Projeler:

1. Hava Aracı Sistemi ve Uçuş Durumlarının Matlab – Simulink Aerospace Toolbox’da Modellenmesi

Proje Türü: Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi- 102-Araştırma Destek Projesi

Başlangıç – Bitiş Tarihi: 09.11.2020 / Devam Ediyor

2. Uçaklar için Makine Öğrenmesine Dayalı Arıza Toleranslı Kontrol Sistemi Tasarımı

Proje Türü: Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi / 301-DR1 Tez Projesi

Başlangıç – Bitiş Tarihi: 16.01.2020 / Devam Ediyor

3. Tam Mertebe Gözleyicinin Adanmış Gözleyici Yapısı ve Genelleştirilmiş Gözleyici Yapısı Şeklinde Kullanılarak Algılayıcı Arızalarının Tespiti ve Ayrımı

Proje Türü: Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi

Başlangıç – Bitiş Tarihi: 05.05.2017 / 01.12.2017

4. Hastane Bilgi Sistemi Veri Kümelerinden Yararlanılarak SQL Server ile Hastalık Profili Tahmini

Proje Türü: Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi

Başlangıç – Bitiş Tarihi: 24.02.2017 / 29.12.2017

5. Mekanik Ventilatörden Ayırma Başarısı Tahmin Parametrelerinin LabVIEW ile Modellenmesi

Proje Türü: Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi

Başlangıç – Bitiş Tarihi: 10.11.2015 / 17.11.2016

6. Yapay Zeka Tabanlı Akıllı Weaning Algoritmasının Geliştirilmesi

Proje Türü: Bilim Sanayi ve Teknoloji Bakanlığı Teknogirişim
Sermayesi Desteği

Başlangıç – Bitiş Tarihi: 08.06.2015 / 09.08.2016

Ödülleri:

1. 2012, Birincilik, Winner of BISI-Building Interfaces for Social Inclusion/InnoEvent 2012, Danimarka.
2. 2012, Birincilik, Category Winner of BISI-Building Interfaces for Social Inclusion/InnoEvent 2012, Danimarka.