

T.C.
AKDENİZ ÜNİVERSİTESİ



**VERİ FÜZYONU VE DERİN ÖĞRENME YÖNTEMİ KULLANILARAK
YAPISAL SAĞLIK İZLEME SİSTEMİ GELİŞTİRİLMESİ**

Songül DEMİRTAŞ

FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

ŞUBAT 2024

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**VERİ FÜZYONU VE DERİN ÖĞRENME YÖNTEMİ KULLANILARAK
YAPISAL SAĞLIK İZLEME SİSTEMİ GELİŞTİRİLMESİ**

Songül DEMİRTAŞ

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

ŞUBAT 2024

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

VERİ FÜZYONU VE DERİN ÖĞRENME YÖNTEMİ KULLANILARAK
YAPISAL SAĞLIK İZLEME SİSTEMİ GELİŞTİRİLMESİ

Songül DEMİRTAŞ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez TUSAŞ-TÜRK HAVACILIK VE UZAY SANAYİİ A.Ş. BİLİMSEL
ARAŞTIRMA PROGRAMI (BAP) tarafından desteklenmiştir

ŞUBAT 2024

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

VERİ FÜZYONU VE DERİN ÖĞRENME YÖNTEMİ KULLANILARAK
YAPISAL SAĞLIK İZLEME SİSTEMİ GELİŞTİRİLMESİ

SONGÜL DEMİRTAŞ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 19/02/2024 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Doç. Dr. Övünç POLAT (Danışman)	[imza]
Prof. Dr. Ömer Halil ÇOLAK	[imza]
Doç. Dr. Serdar GÜNDOĞDU	[imza]

ÖZET

VERİ FÜZYONU VE DERİN ÖĞRENME YÖNTEMİ KULLANILARAK YAPISAL SAĞLIK İZLEME SİSTEMİ GELİŞTİRİLMESİ

Songül DEMİRTAŞ

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Övünç POLAT

Şubat 2024; 38 sayfa

Yapılarda hasarlar, yaşlılık ve çevresel etkenlere bağlı olarak sistem elemanlarında dayanım azalmalarına, yapı geometrisinde sistemin zayıflamasına sebep olan değişikliklerin meydana gelmesine ve yapı elemanlarında ilave zorlamaların oluşmasına neden olabilmekte ve tasarımda öngörülemeyen durumlar ortaya çıkabilmektedir. Yapısal sağlık izleme (YSİ), bir yapıda meydana gelen hasarın tespit edilmesi, konumu belirlenmesi, büyüklüğünün değerlendirilmesi ve yapıda kalan ömrün belirlenmesi amacıyla belirli stratejilerin uygulandığı bir süreçtir. Hava taşıtlarında hasar tespiti için tahribatlı ve tahribatsız muayene yöntemleri kullanılmaktadır. Tahribatlı muayene teknikleri, muayene edilen malzeme veya ürünlerin tekrar kullanılma olasılıklarını ortadan kaldıran veya kısmen yok eden yöntemleri ifade ederken, tahribatsız muayene (NDT), malzemenin veya parçanın bütünlüğünü bozmadan gerçekleştirilen bir muayene türünü ifade etmektedir. NDT prosedürleri günümüzde yapısal sağlık izleme (YSİ) tekniklerinden daha olgun teknolojilere sahiptir, ancak insan müdahalesi gerektirir ve daha fazla iş gücüne ihtiyaç duyar. Ayrıca, harici prob veya ekipman kullanımı nedeniyle daha maliyetlidir. NDT, duruma dayalı bakım kavramı için uygun bir seçenek değildir. Bu nedenle, sahada kullanım sırasında hasarları izlemek için bir yol olarak, sensör tabanlı akıllı yapıların kurulumu önem kazanmaktadır. Kompozit malzemelerin kullanımı, nano seviyeden makro seviyeye kadar olan tasarım ve üretim süreçlerinde sensörlerle yapısal sağlığın anlık ve sürekli olarak izlenmesine imkân tanır. Bu sayede, bu yapıların akıllı yapılar haline dönüşmesi ve etkin bir şekilde kullanım sırasında izlenmesi mümkün olabilir.

Hasar tespit yöntemlerinin otomasyona geçirilmesi, kurumlara teknik yenilikler ve kolaylık sağlayarak analiz hassasiyetini artırılabilir ve insan kaynaklı yöntemlere olan bağımlılığı azaltılabilir. Bu çalışmada, hava taşıtında kullanılmak üzere üretilmiş gerçek yapısal kullanılmıştır. Özgün olarak oluşturulan veri setinde bu yapısalardan üzerinden alınan görüntüler ile yapısalardan üzerine yerleştirilmiş titreşim sensörlerinden elde edilen titreşim verileri kullanılmıştır. Bu yapısalardan üzerinden farklı açılardan çekilmiş 101 adeti hasarlı ve farklı açılardan çekilmiş 32 adeti hasarsız olmak üzere toplam 133 adet görüntü alınmış, hasarlı ve hasarsız olarak iki gruba ayrılmıştır. Hasarlı yapısal parçalar üzerinden 25 ölçüm, hasarsız parçalar üzerinden ise 12 adet ölçüm olmak üzere toplamda 37 adet ölçüm yapılmıştır. Her bir parçadan 5 sensör ölçümü olmak üzere tüm sensörlerden toplamda 185 adet sensör verisi elde edilmiş ve veri setinde kullanılmak üzere bilgisayar ortamında kaydedilmiştir. Sensör verileri hasarlı ve hasarsız olarak iki gruba ayrılmıştır.

Derin öğrenme teknikleriyle eğitilen görüntü işleme algoritmaları, yapısal görüntülerle birlikte sensör verilerini incelemek amacıyla kullanılmıştır. Yapay sinir ağlarının eğitilmesi için büyük miktarda veri ve uzun bir süre gerektiği göz önüne alındığında, özgün elde edilen yapısal parça görüntülerinin analizi için transfer öğrenmesi yöntemi kullanılarak SqueezeNet ağ yapısı, ve probleme özgün CNN yapısında bir ağ modeli kullanılmıştır. Sensör verileri tek başına 1 D-CNN Yapısının girişine uygulanarak ağ eğitilmiş ve veriler sınıflandırılmıştır. Bunun yanı sıra

alışmada probleme zgn olarak Multi-Input CNN yapısı oluřturularak ağıın bařarısı deęerlendirilmiřtir. Bu ağı modelinde hem hasarlı/hasarsız para grntleri, hem de hasarlı/hasarsız sensr verilerinin zamana gre deęiřiminin grntleri giriř olarak tanımlanmıř ve ağı yapısında iki verinin birlikte kullanılması sonucunda eęitim ve test sınıflandırma yapılmıřtır.

Yapılan alıřmalar neticesinde hasarlı ve hasarsız para sınıflandırması tm modellerde gerekleřtirilmiř ve en bařarılı sonu Multi-Input CNN ağı mimarisi kullanımında alınmıřtır. Oluřturulan modellerin daha fazla sayıda veri ieren veri seti kullanımı sayesinde geliřtirilmesi ve daha iyi sonular vermesi ngrlmektedir.

Elde edilen sonular erevesinde, mevcut yapısal saęlık izleme prosedrlerine katkıda bulunabilecek, uygun maliyetli ve hızlı bir hasar tespiti yntemi nermektedir. Kullanılan derin ęrenme yntemleri sayesinde deneti tecrbesine baęımlı olmayan ve insan kaynaklı hata oranını ortadan kaldıran bir zm sunmaktadır. Hava tařıtlarına ait yapıřalları hasar tespiti, uzman personel eęitimi ve tecrbesi gereksinimine ek olarak insan faktrnden kaynaklanan znellik gibi durumlar nedeniyle bilgisayar tabanlı zmlerle daha pratik ve hassas hale getirilebilir.

ANAHTAR KELİMELELER: Ardunio, Derin ęrenme, Evriřimsel sinir aęları, Grnt iřleme, Hasar tespiti, Programlama, Titreřim Sensr, Transfer ęrenim, Veri Fzyonu

JRİ: Do. Dr. vn POLAT

Prof. Dr. mer Halil OLAK

Do. Dr. Serdar GNDOęDU

ABSTRACT

DEVELOPMENT OF STRUCTURAL HEALTH MONITORING SYSTEM USING DATA FUSION AND DEEP LEARNING METHOD

Songül DEMİRTAŞ

MSc Thesis in Electrics and Electronics Engineering

Supervisor: Assoc. Prof. Dr. Övünç POLAT

February 2024; 38 pages

Damages in structures may cause strength decreases in system elements due to aging and environmental factors, changes in the structure geometry that cause the system to weaken, and additional stresses on the structural elements, and unforeseen situations may arise in the design. Structural health monitoring (SPI) is a process in which certain strategies are applied to detect damage to a structure, determine its location, evaluate its magnitude and determine the remaining life of the structure. Destructive and non-destructive testing methods are used to detect damage in aircraft. While destructive testing techniques refer to methods that eliminate or partially destroy the possibility of reuse of the inspected materials or products, non-destructive testing (NDT) refers to a type of inspection performed without compromising the integrity of the material or part. NDT procedures today have more mature technologies than structural health monitoring (SPI) techniques, but require human intervention and require more labor. It is also more costly due to the use of external probes or equipment. NDT is not a viable option for the condition-based maintenance concept. Therefore, the installation of sensor-based smart structures is gaining importance as a way to monitor damages during use in the field. The use of composite materials allows instantaneous and continuous monitoring of structural health with sensors in design and production processes from nano level to macro level. In this way, it may be possible to turn these structures into smart structures and monitor them effectively during use.

Automating damage detection methods can increase analysis sensitivity and reduce dependence on human-based methods by providing technical innovations and convenience to institutions. In this study, real structures produced for use in aircraft were used. In the originally created data set, images taken over these structures and vibration data obtained from vibration sensors placed on the structures were used. A total of 133 images were taken from these structures, 101 of which were damaged and 32 of which were undamaged, taken from different angles, and were divided into two groups as damaged and undamaged. A total of 37 measurements were made, 25 measurements on damaged structural parts and 12 measurements on undamaged parts. A total of 185 sensor data were obtained from all sensors, 5 sensor measurements from each part, and were recorded in the computer environment to be used in the data set. Sensor data is divided into two groups: damaged and undamaged.

Image processing algorithms trained with deep learning techniques have been used to examine sensor data along with structural images. Considering that a large amount of data and a long time is required to train artificial neural networks, the SqueezeNet network structure and a problem-specific CNN structure network model were used using the transfer learning method to analyze the originally obtained structural part images. By applying the sensor data alone to the input of the 1 D-CNN Structure, the network was trained and the data was classified. In addition, in the study, the success of the network was evaluated by creating a Multi-Input CNN structure specific to the problem. In this network model, both damaged/undamaged part images

and images of damaged/undamaged sensor data changing over time were defined as input, and training and test classification was made as a result of using the two data together in the network structure.

As a result of the studies, damaged and undamaged part classification was performed in all models and the most successful result was obtained when using the Multi-Input CNN network architecture. It is envisaged that the models created will be improved and provide better results by using a dataset containing more data.

Within the framework of the results obtained, it proposes a cost-effective and rapid damage detection method that can contribute to existing structural health monitoring procedures. Thanks to the deep learning methods used, it offers a solution that is not dependent on auditor experience and eliminates the rate of human error. Damage detection of aircraft structures can be made more practical and precise with computer-based solutions, due to situations such as subjectivity arising from human factors, in addition to the need for expert personnel training and experience.

KEYWORDS: Arduinio, Deep learning, Convolutional neural networks, Image processing, Damage detection, Programming, Vibration Sensor, Transfer learning, Data Fusion

COMMITTEE: Assoc. Prof. Dr. Övünç POLAT

Prof. Dr. Ömer Halil ÇOLAK

Assoc. Prof. Dr. Serdar GÜNDOĞDU

ÖNSÖZ

Günümüzde uzay ve havacılık mühendisliği başta olmak üzere pek çok alanda yapısal sağlık denetiminde kullanılmaya başlanan akıllı yapılar 21. yüzyıl mühendislik teknolojisine damgasını vuracak bir kavram olmaya adaydır. Tüm dünya genelinde özellikle 5. Nesil uçakların tasarımı ve üretimi ile ilgili rekabet söz konusu iken, bu akıllı yapıların söz konusu hava taşıtları için kullanımı ve geliştirilmesi zorunlu hale gelmiştir. Bu çalışma, mevcut yapısal sağlık izleme prosedürlerine katkıda bulunabilecek, uygun maliyetli ve hızlı bir hasar tespiti yöntemi önermektedir. Kullanılan derin öğrenme yöntemleri sayesinde denetçi tecrübesine bağımlı olmayan ve insan kaynaklı hata oranını azaltabilecek bir çözüm sunmaktadır. Hava taşıtlarına ait yapısal hasar tespiti, uzman personel eğitimi ve tecrübesi gereksinimine ek olarak insan faktöründen kaynaklanan öznellik gibi durumlar nedeniyle bilgisayar tabanlı çözümlerle daha pratik ve hassas hale getirilebilir.

Bu çalışma Türk Havacılık ve Uzay Sanayii A.Ş. BAP programı tarafından desteklenmiştir. Bu hususta bu desteği veren Türk Havacılık ve Uzay Sanayii A.Ş. ve ilgili birimde görevli tüm çalışanlara teşekkür ediyorum. Çalışma konusunun belirlenmesinde ve çalışmanın hazırlanma sürecinin her aşamasında bilgilerini, tecrübelerini ve değerli zamanını esirgemeyen değerli danışman hocam Sayın Doç. Dr. Övünç Polat' a (Doç. Dr, Akdeniz Üniversitesi) teşekkürlerimi sunuyorum. Tez çalışmam süresince desteğini hep hissettiğim değerli yöneticilerime teşekkürü bir borç biliyor ve şükranlarımı sunuyorum. Yine çalışmamda konu ve yöntem açısından bana sürekli yardımda bulunarak yol gösteren ve gelecekteki hayatında çok daha başarılı olacağına inandığım kıymetli meslektaşlarım Sayın Ali Erdem Altınbaş' a ve Sayın Fevzi Bozkurt' a teşekkür ediyorum.

Yüksek lisans eğitimim süresince yanımda olan ve bu süreçte beni sürekli destekleyen, çalışmamı en iyi şekilde tamamlayabilmemi sağlayan çok sevgili eşim Mustafa Demirtaş' a ve çok değerli oğlum Demir Demirtaş' a teşekkür ediyorum.

Bu çalışmamı tüm eğitim hayatım boyunca emeklerini benden esirgemeyen sevgili annem Sultan Yazıcıoğlu ve sevgili babam Numan Yazıcıoğlu' na ithaf ediyorum.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
AKADEMİK BEYAN.....	iv
SİMGELER VE KISALTMALAR	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ.....	vii
1. GİRİŞ	1
2. KAYNAK TARAMASI.....	4
2.1. Hava Taşıtlarında Hasar Tespiti ve Kullanılan Yöntemler	4
2.1.1. Optik teçhizatlarla ve gözle kontrol	4
2.1.2. Ultrasonik yöntem ile kontrol.....	4
2.1.3. Radyografik yöntem ile kontrol	5
2.1.4. D-Görüntüleme kontrol yöntemi	5
2.1.5. Termografik yöntem ile kontrol	5
2.1.6. Senkronize basınç dalgaları kontrol yöntemi	5
2.1.7. Bondaskop kontrol yöntemi	5
2.1.8. Akustik emisyon tekniğiyle kontrol	6
2.2. Yapısal Sağlık İzleme.....	6
2.3. Yapay Zekâ	6
2.4. Görüntü İşleme	7
2.5. Makine Öğrenmesi	8
2.6. Derin Öğrenme	9
2.6.1. Derin öğrenme katmanları.....	10
2.6.1.1. Giriş katmanı	10
2.6.1.2. Konvolüsyon katmanı.....	10
2.6.1.3. Aktivasyon katmanı	11
2.6.1.4. Havuzlama katmanı	12
2.6.1.5. Ezberleme (Dropout) katmanı	13
2.6.1.6. Tam bağlantı (FullConnected, FC) katmanı	14
2.6.1.7. Sınıflandırma (Classification) katmanı.....	14
2.7. Transfer öğrenimi	15

2.8. Hava Taşıtlarında Hasar Tespiti İçin Akıllı Yapılar ve Derin Öğrenme Teknikleri ile İlgili Benzer Çalışmalar	16
3. MATERYAL VE METOT.....	19
3.1. Veri Setinin Hazırlanması	19
3.1.1. Yapısal parçaların görüntüleri	19
3.1.2. Titreşim sensör verileri.....	19
3.1.3. Titreşim sensör verilerinin zamana bağlı değişiminin görüntüleri.....	21
3.2. Derin öğrenme mimarilerinin kullanılması	21
3.2.1. Ön işleme.....	21
3.2.2. Eğitim ve test verilerinin seçimi	22
3.2.3. Tasarlanan/kullanılan derin öğrenme modelleri.....	22
3.2.3.1. SqueezeNet mimarisi ile yapısal parça görüntülerinin sınıflandırılması.....	22
3.2.3.2. Probleme özgü CNN mimarisi ile yapısal parça görüntülerinin sınıflandırılması.....	24
3.2.3.3. 1D-CNN mimarisi ile sensör verilerinin sınıflandırılması	25
3.2.3.4. Probleme özgü Multi-Input CNN mimarisi ile yapısal parça görüntüleri ve sensör verilerinin sınıflandırılması	26
4. BULGULAR	28
5. TARTIŞMA	33
6. SONUÇLAR	35
7. KAYNAKLAR.....	36
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “VERİ FÜZYONU VE DERİN ÖĞRENME YÖNTEMİ KULLANILARAK YAPISAL SAĞLIK İZLEME SİSTEMİ GELİŞTİRİLMESİ” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

...../...../20....

Songül DEMİRTAŞ

İmzası

SİMGELER VE KISALTMALAR

Kısaltmalar

CNN	:	Convolutional neural network
DARPA	:	Defence advanced research projects agency
DenseNet	:	Dense convolutional network
FAA	:	Federal aviation administration
JPEG	:	Joint photographic experts group
NASA	:	National aeronautics and space administration
NDT	:	Non-destructive testing
RELU	:	Rectified linear unit FOS : Fiber optik sensör
SAE	:	Society of automobile engineers
TanH	:	Hiperbolik tanjant
VGG	:	Visual geometry group
YSA	:	Yapay sinir ağları
YSİ	:	Yapısal sağlık izleme
1D-CNN	:	1 boyutlu convolutional neural network

ŞEKİLLER DİZİNİ

Şekil 2.1. Dijital görüntüye ait matematiksel ifade (Petrou ve Petrou, 2010).....	7
Şekil 2.2. Klasik ile makine öğrenmesi karşılaştırması (Metlek ve Çetiner, 2021).....	8
Şekil 2.3. Klasik bir derin öğrenme mimarisi (Metlek ve Çetiner, 2021).....	10
Şekil 2.4. Konvolüsyon işleminin Kernel ile yapılması (Metlek ve Çetiner, 2021) ..	10
Şekil 2.5. Konvolüsyon katmanı (Metlek ve Çetiner, 2021).....	11
Şekil 2.6. Havuzlama katmanı (Metlek ve Çetiner, 2021)	13
Şekil 2.7. (a) Ezberleme yapmış ağ modeli, (b) Ezberleme katmanı kullanılmış ağ .	14
Şekil 2.8. Tam bağlantı katmanı (Metlek ve Çetiner, 2021)	14
Şekil 2.9. YSİ sistemi (Günaydın vd. 2019)	16
Şekil 2.10. Bladesense projesi kapsamında kurulan sensör ağı (Günaydın vd. 2019)	17
.....	17
Şekil 3.1. Hasarlı yapısal parça görüntüleri	19
Şekil 3.2. Hasarsız yapısal parça görüntüleri	19
Şekil 3.3. Hasarlı/hasarsız yapısalara kurulmuş olan elektronik sistem görüntüsü ..	20
Şekil 3.4. Hasarlı yapısalardan alınan titreşim verilerinin değişim görüntüleri.....	21
Şekil 3.5. Hasarsız yapısalardan alınan titreşim verilerinin değişim görüntüleri	21
Şekil 3.6. SqueezeNet mimarisi	24
Şekil 3.7. Probleme özgü CNN mimarisi	25
Şekil 3.8. Titreşim sensör verilerini sınıflandırmada kullanılan 1D-CNN mimarisi .	26
Şekil 3.9. Probleme özgü Multi-Input CNN mimarisi	27
Şekil 4.1. SqueezeNet mimarisi eğitim süreci değişimi	29
Şekil 4.2. SqueezeNet mimarisi test verisi karışıklık matrisi.....	29
Şekil 4.3. Probleme özgü CNN mimarisi eğitim süreci değişimi	30
Şekil 4.4. Probleme özgü CNN mimarisi test verisi karışıklık matrisi	30
Şekil 4.5. Probleme özgü Multi-Input CNN mimarisi eğitim süreci değişimi.....	31
Şekil 4.6. Probleme özgü Multi-Input CNN mimarisi test verisi karışıklık matrisi....	31

ÇİZELGELER DİZİNİ

Çizelge 2.1. Makine öğrenme modelleri	8
Çizelge 3.1. SqueezeNet mimarisi katmanları (Metlek ve Çetiner,2021).....	22
Çizelge 4.1. Görüntü eğitim ve test verileri sınıflandırma sonuçları	28
Çizelge 4.2. Sensör eğitim ve test verileri sınıflandırma sonuçları.....	32
Çizelge 4.3. Multi-Input CNN ile 1D-CNN mimarisi test verisi performansları.....	32



1. GİRİŞ

Hava taşıtlarının bakım standartları ve muayene gereklilikleri diğer araç ve makinalara göre yüksek seviyededir (Yasuda vd. 2022; Megson 2022). Bu nedenle hava araçlarında ve yapılarında uçuş öncesi, uçuş sonrası, belirli uçuş süreleri sonunda ve belirli yıllarda kapsamı genişleyen bakım ve kontrol muayenelerine tabi olurlar (Namkung vd. 2016). Bu kontrol ve muayeneler sayesinde, hava taşıtına ait tasarım ve analiz parametreleri ışığında, kontrol ve değişim sıklığı belirlenmektedir. Ancak her uçak için uçtuğu ortam koşulları, taşıdığı yük, uçurucu ekip deneyim ve kabiliyeti, bakım ve malzeme kalitesine göre arıza sıklığı ve yeri değişmektedir (Bravo-Mosquera vd. 2022). Örneğin karasal iklim şartlarında uçan bir eğitim uçağında görülebilecek korozyon hasarının şiddeti nemli ve denize yakın ortamda uçan uçaklarda görülebilecek korozyon hasarından çok daha azdır (Ignatovich vd. 2022). Aynı şekilde örneğin Boeing 777 gibi bir uçağın, yolcu veya kargo taşımaya bağlı olarak gövde malzemelerinde görülebilecek yıpranma ve hasar sıklığı değişebilecektir. Bu nedenle aynı hava aracında bile olsa yukarıda bahsedildiği üzere fiziksel ve kullanım şartlarına bağlı olarak her aracın farklı kontrollerden geçirilmesi ve farklı hasarların tespit edilebilmesi gerekmektedir (Wanhill vd. 2022). Bakım maliyetleri ön görülerek her aracın aynı bakım sıklığında ve aynı bölgelerin kontrol edilmesi, maliyet, zaman ve iş gücü kaybına neden olmaktadır (Mofokeng vd. 2020; Liu 2021). Bu parametreler ışığında yapılardaki hasar, yaşlılık vb. durumların izlenebilirliği oldukça güncel ve önemli bir hal almıştır.

Yapılarda hasarlar, yaşlılık ve çevresel etkenlere bağlı olarak sistem elemanlarında dayanım azalmalarına, yapı geometrisinde sistemin zayıflamasına sebep olan değişikliklerin meydana gelmesine ve yapı elemanlarında ilave zorlamaların oluşmasına neden olabilmekte ve tasarımda öngörülemeyen durumlar ortaya çıkabilmektedir. Yapısal sağlık takibi, bir yapının önemli parametrelerini devamlı olarak veya belirli aralıklarla izlenmesi ve analiz edilmesini ifade eder. SAE Standardı ARP6461- Sabit Kanatlı Uçaklarda Yapısal Sağlık İzlemenin Uygulanmasına İlişkin Kılavuza göre (2013) Yapısal Sağlık İzleme (YSİ); duruma dayalı bakım, bir yapı/sistem üzerine kalıcı sensörlerin kurulumu ile “verilerin elde edilmesi ve analiz edilmesi süreci” olarak tanımlanmaktadır.

Yapısal sağlık izleme (YSİ); yapının üzerinde bir hasar oluşmasının ardından, bu hasarın tespiti, konumu, büyüklüğü ve yapının ömür bilgisine ulaşabilmek için belirli tekniklerin uygulandığı bir prosestir. YSİ, bu sistemlerin veya bileşenlerin sürekli olarak değişen koşullara tepkisini ölçerek gerçekleştirilir. Bu sürekli izleme, erken arıza tespiti ile ciddi hasarların önceden engellenmesine, bakım çalışmalarının azaltılmasına ve gereksiz denetimlerden kaçınılmasına olanak tanır. Bu süreç, devamlı olması durumunda perspektifte yapısal sağlık hakkında değerli bilgiler sağlar. Erken arıza tespiti, yapının önceden belirlenen fonksiyonlarını yerine getirip getirmediği konusunda düzenli olarak güncellenen çıktılar aracılığıyla sağlanır.

YSİ' nin avantajları arasında etkin zamanlama, ciddi hasarlardan kaçınma, bakım maliyetlerinin azaltılması ve gereksiz denetimlerden kaçınılması yer alır. Bu süreç, mühendislik yapılarının uzun ömürlü ve güvenli bir şekilde işlemlerini destekleyerek yapısal sağlığı koruma amacını taşır.

Hava taşıtlarında hasar tespiti için tahribatlı ve tahribatsız muayene yöntemleri kullanılmaktadır. Tahribatlı muayene, bir ürün üzerinde yapılmakta olup, uygulanan parçanın tekrar kullanılabilme durumunu ortadan kaldırmaktadır. Tahribatlı muayene teknikleri genellikle; korozyon, eğme, sürünme, basma, çekme, burulma, eğme, yorulma şeklinde parçaya zarar verilerek uygulanmaktadır (T.C. Millî Eğitim Bakanlığı, 2012). Hava taşıtlarında

kullanılan yapısal parçaların bir kısmına tahribatlı muayene yapılması mümkün olmadığından sadece belirli bölümler için tahribatlı muayene yöntemleri kullanılabilir.

Tahribatsız muayene (NDT), bir yapısalın ya da ürünün bütünlüğünü bozmadan gerçekleştirilen bir muayene türüdür. Bu yöntem, malzeme üzerindeki kusurları ve boyutları kontrol etmeyi, değerlendirmeyi ve belirlemeyi amaçlar. Tahribatsız muayene, özellikle sivil ve askeri hava taşıtlarının bakım ve servis sürelerini azaltmada önemli bir rol oynayan uçak bakım alanında büyük bir öneme sahiptir. Bu yöntem, farklı boyuta ya da geometriye sahip yapısal ya da parçaların kontrol edilebilmesini sağlar.

Tahribatsız muayene yöntemleri yapısal sağlık izleme sistemlerine göre daha olgun teknolojiler olmasına rağmen uzman bir personel tarafından uygulansa dahi öznel bir yorum taşımaktadır. Ayrıca YSI' ne göre daha fazla iş gücüne ihtiyaç duyar. Tahribatsız muayene tekniklerini uygulamak için harici prob veya ekipman kullanımı gerektiğinden YSI' ne göre daha maliyetlidir. Ayrıca güncel teknolojinin ihtiyacı olan ana özelliklerin başında gelen duruma dayalı bakım özelliği tahribatsız muayene teknolojilerinde bulunmamaktadır. Bu nedenle, sahada kullanım sırasında hasarları izlemek için bir yol olarak, sensör tabanlı akıllı yapıların kurulumu önem kazanmaktadır. Kompozit malzemelerin kullanımı, nano seviyeden makro seviyeye kadar olan tasarım ve üretim süreçlerinde sensörlerle yapısal sağlığın anlık ve sürekli olarak izlenmesine imkan tanır. Bu sayede, bu yapıların akıllı yapılar haline dönüşmesi ve etkin bir şekilde kullanım sırasında izlenmesi mümkün olabilir.

Yapay sinir ağları (YSA), insana ait olan öğrenme yeteneğini taklit ederek bilgisayar işlemlerine öğrenme yeteneği kazandırmaya yönelik modellerdir. Bu modeller, örnek veriler üzerinde çalışarak öğrenme gerçekleştirir ve yapay sinir hücrelerinin birbirine bağlanmasıyla meydana gelir. Yapay sinir ağları, sınıflandırma, örüntü tanıma, tahmin, sinyal filtreleme, veri sıkıştırma ve optimizasyon gibi çeşitli alanlarda başarıyla kullanılmaktadır.

Yapay sinir ağı eğitimlerinde genellikle büyük miktarlarda veri gerekliliği, diğer istatistiksel modellere kıyasla bu modeli farklı kılan bir özelliktir. Mükemmel bir performans elde etmek için geniş bir veri kümesinin eğitilmesi gerekebilir, ancak bu durum genellikle zor, zaman alıcı ve maliyetlidir. Transfer öğrenimi, eldeki veri setlerini daha etkili bir şekilde kullanarak, özellikle evrimsel sinir ağlarıyla yapıldığında, eğitim süresini kısaltabilir ve istenilen sonuca daha hızlı ulaşılmasını sağlar. Transfer öğrenimi, uzun süre eğitilen modellerin sınıflandırıcı katmanlarının değiştirilerek özelleştirilmiş ağlar oluşturulmasına olanak sağlar. Bu yöntemle algoritmanın doğruluğu artabilir ve eğitim süresi kısaltılabilir.

Görüntü işleme uygulamalarının ilk yıllarında istatistiksel yöntemler yaygınken, günümüzde daha çok derin öğrenme yaklaşımı tercih edilmektedir. Derin öğrenme, özellikle yapay sinir ağlarının kullanımıyla, görüntü işleme alanında önemli başarılar elde etmiştir.

Makine öğreniminin bir alt dalı olan derin öğrenme, makine öğrenimi tarihindeki gelişmeler, yapay zekaya olan ilginin artması ile ortaya çıkmıştır. Derin öğrenme mimarilerinin geliştirilmesi sayesinde, yapay zekâ problemlerini çözmek için bir dizi yaklaşım geliştirilebilmiştir.

Görüntü işleme, bilgisayar ortamında görüntülerin otomatik olarak işlenmesini, analiz edilmesini ve bu sürecin sonucunda yorumlanmasını algoritmalar ve kodlar kullanarak yapabilen bir teknolojidir. Günümüzde görüntü işleme teknikleri; tıp, haberleşme teknolojileri, robotik ve uzaktan kontrol, televizyon, endüstriyel muayene gibi farklı alanda kullanılmaktadır. (Dey, 2018). Görüntüler belirli bir kaynaktan elde edilmiş ve belli bir amaca yönelmiş farklı içeriklerden oluşur.

Bilgisayar ortamında kullanılabilen görüntüler, görüntü işleme alanında kullanılan bir dizi algoritma ve kod yardımıyla otomatik olarak işlenir, analiz edilir ve yorumlanır. Görüntü işleme teknikleri uygulanırken, ilk olarak görüntülere ön işleme uygulanır. Buradaki amaç; gürültüyü azaltmaktır. Gürültüyü azaltmak için; görüntülere düşük, orta ve yüksek seviyeli işlemler uygulanır.

Filtreleme yoluyla giriş ve çıkış görüntülerinin gerçekliğini düşük seviyedeki işlemler sağlar. Görüntülerdeki nesnelerin tanınması ve sınıflandırılması için, orta düzeydeki işlemlerde bölme ve tanıma işlemleri gerçekleştirilir. Görüntülerdeki nesnelerin tanınması ve görüntülerin analiz edilmesi işlemleri ise yüksek seviyesi işlemlerde yapılır. Görüntülerin bilgisayar ortamında analiz edilmesi, görüntülerdeki nesnelerin içeriğinin detaylandırılmasına olanak tanır. Bu detaylandırma aşaması, etkili bir görüntü işleme sürecinin gerçekleştirilmesini sağlar.

Veri füzyonu, temel olarak bir bilgi bütünleştirme problemini çözmeye odaklanan çoklu algılayıcı yöntemidir. Bu yöntem, farklı algılayıcılardan gelen verileri birleştirerek, ilgili durumlar için tek bir algılayıcı kullanımından daha etkili bir analiz yapılmasını ve daha iyi kararlar alınmasını sağlamaktadır. Veri füzyonundaki kritik zorluk, algılayıcılardan elde edilen verilerin sadece toplanması veya karmaşık yapıların uygulanmasının ötesinde, karmaşık algoritmalar ve paralel işlemciler kullanılarak analiz edilmesidir. Ayrıca, başlangıçta işlenen algılayıcı verilerinin, karar sistemine uygun bir zamanda ve uygun bir bilgi biçiminde sunulması da bu bağlamda önemlidir. Veri füzyonu, yeni algılayıcıların ortaya çıkması, teknolojinin ilerlemesi ve gelişen donanımın düzelmesiyle birlikte gerçek zamanlı veri füzyonunu artırarak mümkün kılmaktadır. (Biroğul ve Güvenç 2007).

Bu çalışmada, derin öğrenme yöntemi ve veri füzyonu-çoklu algılayıcı yöntemi kullanılarak hava araçlarında kullanılan ve gelişmekte olan yapısal sağlık izleme sistemleri için etkili bir çözüm sunulması amaçlanmıştır. Bu amaç doğrultusunda hava aracına ait yapısal parçalardaki hasar tespiti için derin öğrenme algoritmaları ile yapay sinir ağları ve transfer öğrenimi yöntemi kullanılmış hem görüntü işleme yöntemleri hem de yapısalara ait titreşim verilerinin titreşim sensörü üzerinden alınan veriler ile birlikte hasarlı/hasarsız sınıflandırması yapılmıştır. Yapılan tüm çalışmalar sonucunda veri setine dahil edilen görüntüler ve titreşim sensör verilerinin analizleri yapılarak incelenen parçalardaki hasarlı/hasarsız durumunun tespiti ile hasarların gözden kaçmasını minimize etmek hedeflenmiştir.

2. KAYNAK TARAMASI

2.1. Hava Taşıtlarında Hasar Tespiti ve Kullanılan Yöntemler

Uçağın ana bileşenleri, kanat, motor, iniş takımı, gövde ve kuyruk olmak üzere beş temel kısma ayrılmaktadır. Bu temel kısımların yanı sıra, uçağın yerde ve havada yönlendirilmesini sağlamak amacıyla kanat ve kuyruk üzerinde bulunan uçuş kontrol yüzeyleri de bulunmaktadır. Uçaklar, uçuş sırasında maruz kaldıkları basınç değişimleri nedeniyle stres altında kalabilir, bu da uçak parçalarında hasar oluşumuna neden olabilir. Bu hasarlar, erken tespit edilmezse ilerleyebilir ve uçaklarda yapısal bozulmalara veya ciddi hasarlara yol açabilir. Bu nedenle, uçakların güvenli ve verimli bir şekilde kullanılabilmesi için havacılık sektörü için hatasız veya en düşük hata seviyesinde güvenilir sonuçlar üreten muayene yöntemlerinin kullanılması son derece kritiktir (Erdem, 2022). Özellikle uçakların yaşı arttıkça bu tür muayenelerinin yapılması daha da önem kazanmaktadır.

Askeri ve sivil uçaklar için düzenli olarak tahribatsız kontrol yöntemleri kullanılarak periyodik olarak hata ilerlemesini kontrol etmeyi, böylece hata toleranslı tasarım ve sertifikasyon süreçlerine imkân tanınmıştır. Bu süreç Amerikan Federal Havacılık Otoritesi Federal Aviation Administration (FAA) tarafından 1970’de sabit kanatlı uçaklar için etkin olarak uygulamaya geçirilmiş, gaz türbinli motorlar için ise 1980’de uygulanmaya başlamıştır (Groshal ve Kim 2006). Tahribatsız muayenede uygulanmakta olan yöntemler aşağıda detaylandırılmıştır:

2.1.1. Optik teçhizatlarla ve gözle kontrol

Büyük boyutlu darbe hasarlarını tespit etmek için optik teçhizatlar ve gözle kontrol yöntemleri kullanılabilir. Bu yöntem ekonomik ve uygulanması kolay bir yöntemdir, bu sebeple tercih edilmekte olup yaygın bir şekilde kullanılmaktadır. (Airbus A300 Nondestructive Testing Manual, Airbus Industrie, 2007) Darbe hasarlarının genellikle uçak dış yüzeylerinde oluşması nedeniyle, gözle kontrol bu tür hasarları tespit etmek için doğru yöntemdir.

Bunun yanı sıra hat bakımında, bir uçağın tamamının kontrolü için uygulanan analizlerde, yapı ile uygulayıcı arasındaki mesafelerin büyük olması durumunda, büyük darbe izleri gözlemlenebilir. Hat bakımı sırasında, uçağın burnundan başlanılarak tüm çevresi dolaşıldıktan sonra başlangıç noktasına geri dönülerek kontrol tamamlanır (Gaillardon, 1985). Bu süreçte, sırasıyla; burun radar konisinin darbe hasar analizi, gövde dış yüzeylerinin darbe hasarları analizi, burun iniş takımı lastikleri ve dikmesinin kontrolleri yapılır. Darbe yükleri yönünden en hassas noktalar kanat hücum kenarlarıdır. Darbe hasarı kontrolü için özellikle dikkat edilen bölgeler motor tutucuları ile hava alığı ve türbin palleri, egzoz bölgesidir. Motora ait iç bölgelerin incelenmesinde, optik aletler kullanılmaktadır, böylece; daha küçük boyutlu hasarlar ve söküm gerektiren zor ulaşılabilir kısımlar çok daha rahat bir şekilde kontrol edilebilir. Kanat fırar kenarları, kanatçıklar, hız frenleri ve flaplar detaylı bir incelemeye tabi tutulur. Uçağa ait arka gövde kısmı ve kuyruk kısmı da darbe hasarı yönünden ayrıca kontrol edilmektedir.

2.1.2. Ultrasonik yöntem ile kontrol

Darbe hasarı analizi yapabilmek için bilinen metal alaşımları üzerinde ultrasonik kontrol yöntemi uygulanabilmektedir. Uçak parçalarının oldukça ince olması ve probun alanı göz önünde bulundurulduğunda, bu yöntemde dair uygulama zorlukları meydana gelmektedir. Ultrasonik enerjinin probun yakınlarında yarattığı türbülans alanının etkilerini ortadan kaldırmak için bu testlerin su içerisinde yapılması önerilmektedir. Bu testin adı daldırma

testidir ancak uygulanması zor olduğundan genellikle araştırma ve geliştirme faaliyetlerinde kullanılmaktadır.

2.1.3. Radyografik yöntem ile kontrol

Metal alaşımlardaki küçük darbe hasarları, radyografi yöntemi kullanılarak belirlenebilir çünkü bu hasarlar üç boyutlu olma eğilimindedir. Apron uygulamalarının zor olmasının nedeni çevre sağlığına elektromanyetik ışınların zarar vermesidir. Kompozit parçalarda, tabakalar arasında meydana gelen ince ayrışmalar ile ışınlar doğrultusunda iki boyutlu hataların belirlenmesi zor olduğundan, bu yöntem etkili şekilde kullanılmamaktadır.

2.1.4. D-Görüntüleme kontrol yöntemi

Bu yöntem, tek bir seferde büyük yüzeylerin kontrol edilmesini sağlayan hem metal parçalarda hem de kompozit parçalarda kullanılabilen bir yöntemdir. Bu yöntemde bir kaynak üzerinden test edilen parçaya ışık gönderilir, bu ışık sonrasında bir perdeye iletilir. Perde üzerine gelen ışık demeti tekrardan parçaya iletdikten sonra finalde kameraya iletilir.

2.1.5. Termografik yöntem ile kontrol

Termografik kontrol yöntemi, metal ve kompozit parçaların yüzeyindeki darbe izlerini belirlemede oldukça etkilidir. Büyük yüzeyler, bir seferde kontrol edilebilir. Bu yöntem uygulanırken ilk olarak, yüzeyin tamamında sıcaklıkla renk farkı yaratan bir solüsyon kullanılır. Bu işlemin arkasından yüzeylere spot ışığıyla ısıtma işlemi yapılır. Burada dikkat edilmesi gereken husus ısı enerjisinin homojen olarak yüzeye yayılmasını sağlamaktır. Termal dalgaların malzemenin içine dağılmasıyla, yapıdaki bir hatayla karşılaşıldığında saçılma ve dağılma meydana gelir. Birden fazla fotoğraf çekimi yapılarak hatalı bölge tespit edilir.

2.1.6. Senkronize basınç dalgaları kontrol yöntemi

Bu yöntem uygulanırken ilk olarak, test edilen parça bir çeşit vakum yapılarak basınç gerilmeleri meydana getirilir. Parçanın yüzey alanı, lazer ışını vasıtasıyla taranır, basınç altında olan yüzeyden yansıyan ve basınç altında olmayan yüzeyden alınan görüntüler karşılaştırılır. Böylece, darbe hasarının oluşturduğu yüzey süreksizlikleri ya da bozukluklar, varsa iç yapıda oluşmuş su birikintileri ve tabaka ayrılımları mikro düzeyinde tespit edilir. Buradaki önemli husus test edilen yüzeylere homojen basınç uygulamaktır. Bir kamera vasıtasıyla, test parçası üzerinden alınan yüzey topoğrafyası gerekli bilgileri kaydeder.

2.1.7. Bondaskop kontrol yöntemi

Yöntem, tabakalardan oluşan kompozit yapılara uygulanmış darbe yükleri sebebiyle tabakalar arasında meydana gelen ayrılımların belirlenmesinde kullanılır. Bondaskop kontrol yöntemi, metal ve ametallerden oluşan tüm yapılarda kullanılabilir. Cihazın probu belirli bir konumda olduğunda, tüm tabakalar arası ayrılımların görüntülenebilir. Bondaskop'ta, ultrasonik empedans analizine dayalı olarak empedansın amplitüd değişiklikleri, ekran üzerinde dikey hareketliliği sağlar. Faz değişiklikleri ise dairesel hareketi temsil eder. Bu şekilde her tabakadaki ayrılma, ekranda belirgin bir sinyal meydana getirir. Ultrasonik kontrol yöntemi uygulandığında genellikle probun bağlı olduğu tabakanın kontrolü yapılabilmektedir. Ancak, daha derinlerdeki hatalar, ultrasonik enerjinin ilk tabakadan şiddetle yansması nedeniyle görülemeyebilir.

2.1.8. Akustik emisyon tekniğiyle kontrol

Bu yöntem, diğer tüm tekniklerden ayrılan, sürekli izleme prensibine dayanan bir tekniktir ve temelde ultrasonik prensibiyle çalışır. Algılayıcı probun görevi, parçada hasar oluştuğunda ortaya çıkan ultra sesleri kaydetmektir.

2.2. Yapısal Sağlık İzleme

Son 40 yılda, yapısal sağlık izleme sistemleri alanında, görsel incelemenin yerine geçmeye çalışan otomatik yöntemlerle ilgili bir dizi çalışma gerçekleştirilmiştir. Bu çalışmalar, yapının sağlığı hakkında çok daha fazla güvenli sonuçlar elde edilmesini ve değerlendirmelerin çok daha hızlı bir şekilde yapılmasını hedeflemektedir. Görsel kontrol usullerine alternatif olacak şekilde, akıllı yapılar konsepti düşünülmüş ve akıllı malzemeler çevresel değişikliklere karşı yüksek hassasiyet gösterme yetenekleri nedeniyle bu alanda önemli bir rol oynamıştır. Yapısal sağlık izleme (YSİ), genellikle yapının veya bileşenlerinin meydana gelen beklenmedik durumlar sırasında ve sonrasında ortaya çıkarabileceği sonuçları izlemek ve oluşabilecek hasar nedeniyle çalışmaları esnasındaki durumu değerlendirmek amacıyla uygulanmaktadır, ayrıca bu sebepler nedeniyle oluşabilecek anormallikleri tespit etmek amacıyla da kullanılmaktadır.

A.B.D 1990'lı yıllardan itibaren, akıllı malzemelerin ve yapıların oldukça teknolojik imkanlar sunduğunu DARPA (Defence Advanced Research Projects Agency) öncülüğünde kabul etmiş ve bu hususta yapılan çalışmaları kabul etmeye ve destek olmaya başlamıştır. Bu çabalar sonucunda, titreşim azaltma, gürültü azaltma, yapısal sağlığın sürdürülmesi, aerodinamik kontrol ile hidrodinamik kontrol alanlarında önemli ilerlemeler kaydedilmiştir. A.B.D Hava, Kara ve Deniz Kuvvetleri, çeşitli programlar başlatarak akıllı yapıların, uçak, helikopter ve denizaltı gibi araçlarda kullanılmasının etkili olduğunu kanıtlamıştır, ayrıca bu çalışmalar NASA tarafından da kabul görmüştür. Özellikle, bu uygulamalardan titreşim kontrolünün yanı sıra aerodinamik ve hidrodinamik akım kontrolüne odaklanan çalışmalar, titreşim ve gürültünün azaltılmasını amaçlamıştır. Bu çalışmalar ayrıca, taşıma yüzeylerine ait şekil optimizasyonu ve dinamik-aeroelastik özelliklerine ait iyileştirilme hedeflerini de taşımaktadır. Tüm bu çalışmaların ana hedefi, askeri uçaklarda akıllı teknolojilerin verimli bir şekilde kullanılmasıdır. (Günaydın vd. 2019)

Teknolojinin gelişmesiyle birlikte havacılık sektörü, yüksek katma değerli bir alan olarak sivil hava taşımacılığından askeri uygulamalara kadar geniş bir yelpazede 20. yüzyılda büyük bir ilerleme kaydetmiş ve 21. yüzyılda da bu alanda yapılan çalışmalar gelişmeye devam etmektedir. Güvenliğin öncelikli olduğu havacılık sektörü, üretiminden son kullanıma kadar kullanılan parça ve malzemelerin tamamının her bir aşamada yüksek düzeyde kontrolünü gerektirmektedir. Uçaklar genellikle gövde, kanatlar, kuyruk, uçuş kontrol yüzeyleri ve iniş takımları olmak üzere beş temel bölümden oluşur. Uçaklar, uçuş sırasında maruz kaldıkları basınç değişiklikleri nedeniyle stres altındadırlar ve bu durum, parçalarda hasar oluşma riskini taşır. Örneğin, başlangıçta küçük çatlaklar kullanım sonrasında ve biriken stres sebebiyle büyümeye devam edebilir. Bu tür hasarların erken dönemde tespit edilememesi, uçaklarda meydana gelebilecek yapısal bozulmalara veya hasarlara sebebiyet vermektedir. Bu sebeplerden ötürü, uçakların güvenli bir şekilde, aynı zamanda uzun ömürlü kullanılabilmesi için hatasız veya en düşük hata seviyesinde sonuçlar üreten güvenilir muayene yöntemlerinin kullanılması kritiktir. Uçakların yaşı arttıkça, muayene işlemlerinin önemi daha da artmaktadır.

2.3. Yapay Zekâ

1950'li yıllarda, bilgisayarların insanlar gibi düşünüp düşüneyemeyeceğinin sorgulanması ile yapay zekâ kavramı ortaya çıkmıştır. Yapay zekâ kavramı, bir makinenin insanların öğrenme ve problem çözme gibi bilişsel yeteneklerini modelleyen algoritmalar kullanması demektir.

İnsanların bu bilişsel yetenekleri olan öğrenme, dil işleme, akıl yürütme ve sonuca varma, sınıflandırma, konuşma ve tanıma gibi beceriler bulunmaktadır. Bu bilişsel becerilerin bazıları örnek alınarak yapay zekâ geliştirilmiştir.

Yapay zekâ, pek çok disiplini etkileyen ve aynı zamanda bu disiplinler üzerinde doğrudan etkisi olan bir yapı oluşturmaktadır. Bu durum, tıp, askeriye, ekonomi, meteoroloji gibi pek çok alanda uygulamaların gelişmesine yol açmaktadır.

2.4. Görüntü İşleme

Görüntü işleme, malzeme ve yapısal karakterizasyon alanında otuz yılı aşkın süredir önemli bir araç olarak kabul edilmektedir. Gürültüyü gidermek ve hizalamayı gerçekleştirmek amacıyla, filtreleme ve iyileştirme teknikleri gibi ön işleme adımları sıkça kullanılmaktadır. Görüntü işleme, derin öğrenme alanında önemli bir gelişmeye öncülük etmiştir. Derin öğrenme mimarisinin başarısı, görsel verilerden çok sayıda soyutlama düzeyini (düşük seviyeli özelliklerden daha yüksek dereceli gösterimlere, yani özelliklerin özelliklerine) modellenmesine dayanmaktadır. Görüntü işleme, sinir ağı ve derin öğrenme temelli kümeleme ve bölütleme yaklaşımlarıyla, yapısal karakterizasyon problemleriyle benzerlik gösteren multimodal tıbbi görüntülerde yaygın bir şekilde kullanılmaktadır.

Görüntü işleme, bilgisayar ortamında görüntülerin otomatik olarak işlenmesini, analiz edilmesini ve bu sürecin sonucunda yorumlanmasını algoritmalar ve kodlar kullanarak yapabilen bir teknolojidir. Günümüzde görüntü işleme teknikleri; tıp, haberleşme teknolojileri, robotik ve uzaktan kontrol, televizyon, endüstriyel muayene gibi farklı alanda kullanılmaktadır. (Dey, 2018). Görüntüler belirli bir kaynaktan elde edilmiş ve belli bir amaca yönelmiş farklı içeriklerden oluşur.

Görüntüler, siyah-beyaz tonda veya renkli tonlardan oluşmaktadır. Siyah-beyaz bir görüntü, (x, y) koordinatlarında parlaklığın $f(x, y)$ iki boyutlu ışık fonksiyonu ile orantılı olduğu ve x ve y 'nin uzaysal koordinatlarını temsil ettiği bir yapıya sahiptir. Renkli görüntü, $f(x, y)$ parlaklığını temsil eden bir vektör olup, her bir bileşeni spektral banttaki parlaklığı ifade eder. Dijital görüntüler, uzaysal koordinatlarda ayrıca parlaklıkta ayrıklaştırılmış bir $f(x, y)$ görüntüsüdür. İki boyutlu dizi olarak temsil edilen dizilerin her biri bir renk bandına karşılık gelir. Gri seviye sayısallaştırılmış parlaklık değerine denir. Piksel bu dizilerin her bir elemanına verilen addır. $0 \leq f(x, y) \leq G-1$ aralığında görülebilen dijital görüntüler, aşağıdaki gibi ifade edilir.

$(N=2^n, G=2^G)$ (Petrou ve Petrou, 2010).


$$f(x, y) = \begin{bmatrix} f(1,1) & f(1,2) & \dots & f(1,N) \\ f(2,1) & f(2,2) & \dots & f(2,N) \\ \vdots & \vdots & & \vdots \\ f(N,1) & f(N,2) & \dots & f(N,N) \end{bmatrix}$$

Şekil 2.1. Dijital görüntüye ait matematiksel ifade (Petrou ve Petrou, 2010)

Gri seviyeli görüntüler, piksel değerlerinde 256 farklı tonu içerir. Bu tonlar, 0 değeri siyahı temsil ederken, beyazı ifade eden değer 255' tir. Gri seviyelere sahip görüntüler, bu aralıkta yer alan diğer değerlere sahiptir (Johnson, 2006). Gri seviyeli görüntülerden elde edilen ikili (binary) görüntüleri oluşturmak için görüntü eşikleme yöntemi kullanılır. Bu ikili görüntüler, çeşitli görüntü işleme uygulamalarında kullanılmaktadır.

2.5. Makine Öğrenmesi

Bilgisayarda belirli veriler ve kurallar kullanılarak gerçekleştirilen programlarından biri klasik programlamadır. Sonuçlar ile veriler arasında oldukça sıkı bir ilişki olan bu programlamada, çıkacak sonuçlar ve olası durumlarla ilgili algoritma geliştirmek için geniş bir perspektiften bakmak ve tüm durumları göz önünde bulundurmak önemlidir. Bazı durumlarda veriler ile çıkan sonuç arasında bir ilişki kurulamaz, bu durumda kurallar oluşturulamaz. Kuralların eksikliği, bu tür durumlarda klasik programlama ile sorunlara çözüm bulunamayacağı anlamına gelir. Bu tür sorunlara çözüm getirmek amacıyla yapay zekâ algoritmaları geliştirilmiş olup bu teknolojiye makine öğrenme algoritmaları denmektedir. Bu algoritmaların klasik programlamadan farkları Şekil 2.2. 'de gösterilmiştir (Metlek ve Çetiner, 2021).



Şekil 2.2. Klasik ile makine öğrenmesi karşılaştırması (Metlek ve Çetiner, 2021)

Veriler ile sonuçlar arasında ilişki kurabilen makine öğrenmesi, sahip olduğu bu yetenek sayesinde ticari ve askeri birçok alanda tercih edilme sebebini oluşturmuştur. Makine öğrenme algoritmaları üç ana kategoriye ayrılmaktadır (Metlek ve Çetiner, 2021). Bunlar; denetimli öğrenme modeli, denetimsiz öğrenme modeli ve pekiştirmeli öğrenme modelidir.

İlk model olan denetimli öğrenmede, eğitim aşamasında etiketli giriş ve çıkış verileri birlikte kullanılır. Diğer bir model olan denetimsiz öğrenmede sistemin doğru çalışıp çalışmadığını test etmek amacıyla etiketli eğitim verileri çıkış değeri kullanılmaktadır. Son model olan pekiştirmeli öğrenme modelinde bir geri bildirim elde edilir bu geri bildirim gerçekleştirilen işlem sonucunda elde edilen değerin doğru ya da yanlış olması ile sağlanır. Tüm bu makine öğrenme modelleri için, farklı sorunları çözmeye yönelik özel makine öğrenme bu algoritmaları, kullanım alanlarına göre kıyaslanarak Çizelge 2.1'de özetlenmiştir.

Çizelge 2.1. Makine öğrenme modelleri

Öğrenme Tipleri	Veri işleme yöntemi	Uzaklık normları	Öğrenme algoritmaları
Danışmanlı öğrenme	Sınıflandırma Regresyon Varsayım	Hesaplamalı sınıflandırıcılar	Destek vektör makine
		İstatistiksel sınıflandırıcılar	Naive Bayes
			Gizli Markov model
		Bağılantılı sınıflandırıcılar	Bayes ağları
			Sinir ağları

Devamı Arkada

Çizelge 2.1.' in devamı

Danışmansız öğrenme	Kümeleme Tahmin	Parametrik	K - ortalamalar
			Gaussian model
		Parametrik olmayan	Dirichlet işlem modeli
			X-ortalamalar
Pekiştirmeli öğrenme	Karar verme	Model-free	Q öğrenme
			R öğrenme
		Model tabanlı	TD öğrenme
			Sarsa öğrenme


Çizelge 2.1 detaylı olarak incelendiğinde; veri analizi odaklı modellerin denetimli ve denetimsiz öğrenme modelleri olduğu, pekiştirmeli öğrenme modelinin ise daha çok karar verme odaklı olduğu görülmektedir.

2.6. Derin Öğrenme

Yapay sinir ağı eğitimlerinde genellikle büyük miktarlarda veri gerekliliği, diğer istatistiksel modellere kıyasla bu modeli farklı kılan bir özelliktir. Mükemmel bir performans elde etmek için geniş bir veri kümesinin eğitilmesi gerekebilir, ancak bu durum genellikle zor, zaman alıcı ve maliyetlidir. Transfer öğrenimi, eldeki veri setlerini daha etkili bir şekilde kullanarak, özellikle evrimsel sinir ağlarıyla yapıldığında, eğitim süresini kısaltabilir ve istenilen sonuca daha hızlı ulaşılmasını sağlar. Transfer öğrenimi, uzun süre eğitilen modellerin sınıflandırıcı katmanlarının değiştirilerek özelleştirilmiş ağlar oluşturulmasına olanak sağlar. Bu yöntemle algoritmanın doğruluğu artabilir ve eğitim süresi kısaltılabilir.

Görüntü işleme uygulamalarının ilk yıllarında istatistiksel yöntemler yaygınken, günümüzde daha çok derin öğrenme yaklaşımı tercih edilmektedir. Derin öğrenme, özellikle yapay sinir ağlarının kullanımıyla, görüntü işleme alanında önemli başarılar elde etmiştir.

Makine öğreniminin bir alt dalı olan derin öğrenme, makine öğrenimi tarihindeki gelişmeler, yapay zekaya olan ilginin artması ile ortaya çıkmıştır. Derin öğrenme mimarilerinin geliştirilmesi sayesinde, yapay zekâ problemlerini çözmek için bir dizi yaklaşım geliştirilebilmiştir. Şu anda makine öğrenme alanındaki en son gelişmeler, derin öğrenme algoritmalarıyla elde edilmiştir. Derin öğrenme, geleneksel öğrenme yöntemlerinden farklı olarak hiyerarşik bir yapı kullanır. Özniteliklerin otomatik olarak çıkarılması için derin öğrenme modelleri; denetimli ve denetimsiz öğrenme yöntemlerinin meydana gelmesinden oluşabilir (Metlek ve Çetiner, 2021). Yapay sinir ağı modellerinden konvolüsyon tabanına dayanan derin öğrenme algoritmaları Şekil 2.3' te gösterilen mimariye sahiptir. Son teknolojik gelişmeler sayesinde artan donanım kapasitesi ile birlikte, mimaride kullanılan katman ve bağlantı sayıları farklılaştırılabilmekte ve alternatif derin öğrenme mimarilerinin geliştirilmesine olanak tanımaktadır.



Şekil 2.3. Klasik bir derin öğrenme mimarisi (Metlek ve Çetiner, 2021)

2.6.1. Derin öğrenme katmanları

2.6.1.1. Giriş katmanı

Yapay zekâ algoritmalarında ağa sunulmak üzere verilerin standart hale getirildiği katman giriş katmanıdır. Giriş katmanında ağ modelinde kullanılan mimariye ve ağa verilen veri setine bağlı olarak Denklem 2.1 de gösterilen şekilde normalizasyon işlemi uygulanmaktadır.


$$xnorm = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.1)$$

$xnorm$ =normalize edilmiş veri,

$\min(x)$ = veri seti içerisindeki en küçük değer,

$\max(x)$ veri seti içerisindeki en büyük değeri,

x = normalize edilecek veri anlamını taşımaktadır.



Şekil 2.4. Konvolüsyon işleminin Kernel ile yapılması (Metlek ve Çetiner, 2021)


2.6.1.2. Konvolüsyon katmanı

Giriş verileri üzerinde bir dizi filtre (kernel) gezdirildiği katman konvolüsyon katmanıdır. Bu kısımda filtrelerin içerikleri, boyutları ve sayıları uygulamaya özel bir şekilde değişebilir. Veri boyutundan küçük filtreler kullanılmalıdır. Veri üzerinde yatay ve dikey bir şekilde gezdirilen filtreler ile gezdirildiği alandaki veri değerleri ile çarpılır böylece yeni bir veri seti oluşur. Seçilen filtreler ağa tanımlanmış olan tüm veri üzerinde gezdirilir. Böylece yeni

bir iki boyutlu veri matrisi elde edilir. İşlemin nasıl gerçekleştiği Şekil 2.4'te detaylı olarak gösterilmiştir.

Şekil 2.5'te gösterildiği gibi, bias değeri renkli bir görüntünün her boyutu üzerinde dolaştırılan filtrelerin toplamına ek olarak eklenmektedir. Ağ modelinde kullanılan mimariye bağlı olarak bias değeri değişebilir. Matematiksel olarak işlemin nasıl gerçekleştiği, Denklem 2.2' de anlatılmıştır.

Şekil 2.6' de gösterildiği gibi,
 $(x+i-1),(y+j-1)$ boyutuna sahip I veri matrisi üzerinde
 $[i,j]$ boyutunda bir filtre (K matrisi) gezdirilerek,
 $[x,y]$ boyutunda yeni bir $I*K$ veri matrisi elde edilir.



Şekil 2.5. Konvolüsyon katmanı (Metlek ve Çetiner, 2021)

$$(I * K)_{xy} = \sum \sum K_{ij} \cdot I_{x+i-1,y+j-1} \quad (2.2)$$

Ağın performansını doğrudan etkileyen faktörlerden en önemlisi görüntü üzerinde gezdirilecek filtredir. Örneğin, ağ üzerinde gezdirilecek matrisin boyutu çok büyük ve büyük sayılardan oluşuyorsa, ağın eğitimi uzun sürebilir ve hatta tercih edilen rakamlara bağlı olarak hata olasılığı artabilir (Pang vd. 2017).

2.6.1.3. Aktivasyon katmanı

Bu katman, çoğu zaman elde edilen negatif değerleri pozitif çevirmek amacıyla, elde edilen değerleri uygun aralıklara indirmek için kullanılır (Raman vd. 2018). Literatürde en iyi bilinen ve aktivasyon katmanında kullanılan aktivasyonlar fonksiyonlarının başında ReLu, Sigmoid, Adım (Step) gelmektedir. Yapılan işlemin matematiksel gösterimi Denklem 2.3' te verilmiştir. Şekil 2.5' te gösterilen görüntünün her bir boyutuna bu denklem uygulanır.

$$conv(I, K)_{xy} = \alpha \left(b + \sum_{i=1}^h \sum_{j=1}^w \sum_{k=1}^d K_{ij} \cdot I_{x+i-1,y+j-1,k} \right) \quad (2.3)$$



d= görüntünün boyutları,

b=bias değeri,

α = aktivasyon fonksiyonunu anlamını taşımaktadır.

Çizelge 2.2' de kullanılan aktivasyon fonksiyonları verilmiştir.

Çizelge 2.2. Aktivasyon fonksiyonları (Metlek ve Çetiner, 2021)


İsim	Grafik	Denklem $f(x)$	Türev $f'(x)$
Identity		$= x$	$= 1$
Binary Step		$= \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$= \begin{cases} 0 & \text{for } x \neq 0 \\ 1 & \text{for } x = 0 \end{cases}$
Logistic		$= \frac{1}{1 + e^{-x}}$	$= f(x)(1 - f(x))$
TanH		$= \tanh(x)$ $= \frac{2}{1 + e^{-2x}} - 1$	$= 1 - f(x)^2$
ArcTan		$= \tan^{-1}(x)$	$= \frac{1}{x^2 + 1}$
ReLu		$= \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$= \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
PReLU		$= \begin{cases} \alpha x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$= \begin{cases} \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
ELU		$= \begin{cases} \alpha(e^x - 1) & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$= \begin{cases} f(x) + \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
SoftPlus		$= \log_e(1 + e^x)$	$= \frac{1}{1 + e^{-x}}$

2.6.1.4. Havuzlama katmanı

Aktivasyon katmanının ardından kullanılan havuzlama katmanının temel amacı, verileri küçük boyutlara indirmektir. Bu işlem sürerken kullanılan havuzlama fonksiyonlarından dolayı veri kayıpları meydana gelebilir (Hinton 2012). Bu nedenle, bu katmanın uygulanması esnasında makul düzeyde veri kaybının olabileceği öngörülmelidir.

Kullanılan havuzlama fonksiyonlarının başında; en büyük (max pooling) fonksiyonu gelmektedir. Ayrıca küçük (min pooling) havuzlama fonksiyonu ve ortalama (average pooling) fonksiyonları da sıklıkla kullanılmaktadır. Şekil 2.6' da gösterildiği üzere, aktivasyon


katmanından elde edilen matris üzerinde bu fonksiyonlar dolaştırılarak yeni bir veri matrisi elde edilmektedir.



Şekil 2.6. Havuzlama katmanı (Metlek ve Çetiner, 2021)

2.6.1.5. Ezberleme (Dropout) katmanı


Sınırlı veri setleri üzerinde çalışan modellerde, eğitim sürecinde sistem, modelde kullanılan verileri ezberleme yönelimine girebilmektedir. Bu sebepten ötürü, geliştirilen ağ mimarisi içerisinde verilerin ezberlenmesinin önüne geçilmelidir. Bu işlem genellikle ezberleme katmanı kullanılarak gerçekleştirilir ve bazı derin öğrenme modellerinde de benzer bir mekanizma uygulanabilir. Şekil 2.7, ezberlemenin çalışma prensibine kısa bir bakış sunmaktadır. Şekil 2.7(a), ezberleme yapmış bir ağ yapısını gösterirken, Şekil 2.7(b), ezberleme katmanının kullanıldığı bir ağ yapısını göstermektedir. ezberleme katmanı literatürde genellikle, havuzlama katmanı ile tam bağlantı katmanı arasında konumlanmaktadır.



Şekil 2.7. (a) Ezberleme yapmış ağ modeli, (b) Ezberleme katmanını kullanılmış ağ Modeli (Metlek ve Çetiner, 2021)

2.6.1.6. Tam bağlantı (FullConnected, FC) katmanı

Tam bağlantı katmanı, sınıflandırma katmanından önce kullanıldığı gibi, havuzlama veya ezberleme katmanlarından önce de kullanılabilir. Veriler, boyutlu bir vektöre dönüştürülerek tam bağlantı katmanına iletilmektedir. Bu durum, Şekil 2.8’ de görsel olarak açıklanmıştır.



Şekil 2.8. Tam bağlantı katmanı (Metlek ve Çetiner, 2021)

2.6.1.7. Sınıflandırma (Classification) katmanı

Derin öğrenme algoritmalarının da yapay zekâ algoritmalarında da olduğu gibi sınıflandırma katmanı son katmandır. Sınıflandırma katmanı, tam bağlantı katmanı üzerinden

kendisine iletilen verileri değerlendirerek, çıkışı bir değer olarak ağa vermektedir. Çıkışta üretilmiş olan sonuç, bir sınıflandırma bilgisi taşıyabilir ya da polinom katsayısı olarak bir eğri uydurma yönteminde de kullanılabilir. Bu katmandan alınan değer bilgisi, pek çok sınıflandırma fonksiyonu ile belirlenebilmektedir.

SoftMax, olasılıksal bir hesaplama yöntemi olup sınıflandırma katmanlarında sıklıkla kullanılmaktadır. Bu sınıflandırıcı 0-1 aralığında bir değer üreterek her sınıf için tanımlama yapmaktadır. Elde edilen bu değerler, eğer 1'e yakınsa, üzerinde çalışılan girişe ait sınıf bilgisi verir.

2.7. Transfer öğrenimi

Transfer öğrenimi, önceki bir alakalı görevden edinilen bilgilerin, yeni bir görevdeki öğrenme sürecine hızlı bir şekilde uygulanarak performansın artırılmasını amaçlayan bir eğitim modelidir. "Transfer Öğrenimi Üzerine Anket" çalışması, alan, görev ve marjinal olasılıkları kullanılmıştır (Pan ve Yang, 2009). Bu çalışmalar transfer öğrenimini tanımlamak için teorik bir açıklama sunmaktadır. (Olivas vd. 2009).

D =Alan (domain),

X =Özellik uzayı

$P(X)$ = Bu uzayın marjinal olasılık dağılımını ifade etmektedir. Bu işlemler matematiksel olarak

$D = \{X, P(X)\}$ ifade edilmektedir.

T =Görev (task),

Y =Etiket uzayı,

$f(x)$ =Amaç fonksiyonunu ifade eder.

$f(x)$ -Amaç fonksiyonu $P(Y|X)$ olarak gösterilmektedir.

Burada görev;

$T = \{Y, f(x)\} = \{Y, P(Y|X)\}$ olarak ifade edilebilir.

$f(x)$ fonksiyonunun eğitimini gösteren matematiksel işlemler şu şekilde ifade edilir.

$\{x_i, y_i\}$ = eğitim veri kümesi,

$x_i \in X$ ve $y_i \in Y$ üzerinde eğitilir

Bu işlem sonucunda elde edilen her özellik vektörü için $f(x_i) = y_i$ tahminini elde edilir.

Transfer öğrenimi, bir kaynak alan DS ve kaynak görev TS ile başlar. Ancak amacı, DS ve TS' den edinilen bilgileri kullanarak hedef alan DT ve hedef görev TT için $P(YT|XT)$ koşullu olasılık dağılımını öğrenmektir.

DS ve DT , $D = \{X, P(X)\}$ kaynak ve hedef alanları temsil eder,


TS ve TT , $T = \{Y, P(Y|X)\}$ kaynak ve hedef görevleri temsil eder

Bu bağlamda, öğrenme senaryosu olarak dört farklı transfer öğrenimi ortaya çıkar:

1. kaynak ve hedef alanların özellik uzayı farklı olan $\rightarrow XS \neq XT$,
2. kaynak ve hedef alanlarına ait olasılık dağılımı marjinalde farklı olan $\rightarrow (XS) \neq P(XT)$,
3. kaynak ve hedef görevlerin etiket uzayları birbirinden farklı olan $\rightarrow YS \neq YT$,
4. kaynak ve hedef görevlerin olasılık dağılımları birbirinden farklı olan $\rightarrow P(YS|XS) \neq P(YT|XT)$ (Ruder, 2017).

2.8. Hava Taşıtlarında Hasar Tespiti İçin Akıllı Yapılar ve Derin Öğrenme Teknikleri ile İlgili Benzer Çalışmalar

Havacılık ve uzay alanında YSİ için sensörler kullanılarak elde edilen sistemlerin kullanımı hakkında, Amerika Birleşik Devletleri'nde 1990'lı yıllarda pek çok çalışma yapılmıştır. Bu çalışmalar genellikle büyük havacılık firmaları, örneğin Northrop Corporation gibi, ve ABD Hava Kuvvetleri gibi kuruluşların ortaklığıyla yürütülmüştür. Yapılan ilk çalışmalarda öncelikli olarak YSİ'nin nasıl kullanılabileceğine dair durumlar belirlenmiş ve bu kullanımlar için yöntemler oluşturulmasına odaklanılmıştır (Şekil 2.9). Bu yöntemlerin nasıl uygulanacağını anlatan yol haritasının belirlenmesi sürecinde uygulanabilirlik ve kullanımı uygun sensörlerin olgunluk seviyeleri üzerinde çalışmalar yapılmıştır (Günaydın, Hatipoğlu ve Fidanboylu, 2019). Yapılan bu çalışmalarda, fiber optik sensörler dahil olmak üzere çeşitli sensörlerin kullanılabilirliği araştırılmıştır (Kudva, Marantidis, Gentry, Blazic, 1993).



Şekil 2.9. YSİ sistemi (Günaydın vd. 2019)

Geometrik ve yapısal özelliklerini kendisinden beklenen görevlere uygun şekilde değiştirilebilen yapılara akıllı yapılar denmektedir. Bu yapılar, görevlerini yerine getirirken çalışma ortamındaki değişiklikleri veya diğer uyarıları algılayabilir ve durumları hakkında veri toplayabilirler (Boller, 2003; Galea ve Baker 2001). Bu yetenek, genellikle yapıya entegre edilmiş sensörler, aktüatörler veya malzemenin doğal bir yanıt mekanizması ile elde edilir (Galea ve Baker 2001).

Yapısal sağlık izleme (YSİ) sisteminin temel unsurlarından biri, yapısal bileşene kalıcı bir şekilde eklenebilen sensörlerin varlığıdır. Yapısalara bu şekilde entegre edilen sensörler sayesinde yapısal sağlık izleme sistemleri akıllı yapı halini almakta, bu sayede kazanmış olduğu gerçek zamanlı hasar tespiti yeteneği ile çeşitli taşıtların yapısal sağlığını izleme ve olası hasarları giderme çalışmalarında önemli bir rol oynamaktadır (Lawson vd. 2016).

Yapısal sağlık izleme sistemlerinin akıllı yapılara dönüşmesinde yapılan ilk uygulamalar genellikle havacılık ve uzay teknolojisinde gerçekleşmiştir. Örneğin, uzay araçlarının yüzeylerine çarpan yabancı maddelerin neden olduğu potansiyel hasarların tespit edilmesi için fiber-optik sensörler kullanarak yeni teknikler geliştirilmiştir (Lawson vd. 2016). Ayrıca, piezoelektrik sensörlerin kullanıldığı bir uzay kafes sisteminin titreşiminin bastırılmasının mümkün olabileceği belirtilmiştir (Mrad ve Xiao, 2005). Uzay antenlerinde piezoelektrik uyarıcılar ve algılayıcılar kullanılarak titreşimlerin bastırılmasını amaçlayan çalışmalar da yapılmıştır (Guo vd. 2011)

Virginia Politeknik Enstitüsü'nde yapılan araştırmalarda hem uyarıcı hem de algılayıcı görevini yerine getiren parça piezoelektrik elemanlar kullanılarak çeşitli havacılık yapılarındaki YSİ problemleri incelenmiştir. Akıllı yapılar ve YSİ genellikle birbirine entegre iki kavram olarak ele alınmış ve birçok yayında bu iki olgunun iç içe geçmiş olduğu vurgulanmıştır.

Kompozit yapıların hava taşıtlarında kullanımının yaygınlaşması ile, FOS' ların bu yapılar içerisine gömülebilmeleri ile yapısalın bütünlüğüne etkileri hakkında pek çok çalışma yapılmaya başlanmıştır. Özellikle yapısalın bütünlüğüne olan etkilerini araştıran bu çalışmalara 1990'lı yılların sonlarında başlanmıştır. (Foedinger vd. 1999)

Airbus, küresel bir havacılık firması olarak, yapısal sağlık izleme (YSİ) konusunda önemli çalışmalar yürütmeye devam etmektedir. Airbus, YSİ' ye özel bir departmanla, özellikle fiber optik sensörler (FOS) dahil olmak üzere bir dizi sensör üzerinde çalışmaktadır. Airbus yapılarındaki darbeler, bağlantı kalitesi, tamir yamalarının bağlantısının tespiti, delaminasyon, yükleme izleme ve gerinim izleme gibi süreçlerde FOS' ları aktif şekilde kullanmaktadır. (Bockenheimer ve Speckmann, 2013)

Airbus, A340-600 uçakları üzerinde FBG sensörlerin kullanımıyla ilgili çalışmalar yapmıştır (Speckmann, 2007). Firma, "BLADESENSE" adlı projesinde; FBG sensörlerini kullanarak dinamik olarak helikopter rotor palindeki deformasyonu ölçmüştür. Bu projeyi Cranfield Üniversitesi ve diğer iş ortaklarıyla birlikte gerçekleştirmiştir (Weber, 2017). Bu çalışmanın yapıldıktan sonra bir dizi veri elde edilmiştir. Bu verileri sonrasında, döner kanatlı hava araçları üzerinde oluşan rotor palinin aeroelastisitesinin uçuşa olan etkisini incelemişlerdir (Weber, 2017). Bu çalışmaya ait görsel Şekil 2.10' da verilmiştir.



Şekil 2.10. Bladesense projesi kapsamında kurulan sensör ağı (Günaydın vd. 2019)

Görüntü işleme teknikleri, özellikle İnşaat Mühendisliği alanında, beton çatlakları üzerinde çeşitli analizler yapmak amacıyla geliştirilmiştir. Bu teknikler, bina, köprü, boru gibi yapıların yanı sıra yol yüzeylerinde oluşan çatlakların detaylı analizine odaklanmıştır.

Görüntü işleme tekniklerinin hava taşıtı üzerinde hasar tespiti için kullanılmaya başlaması 1990'lı yıllardan itibaren gerçekleşmiştir. Yapılan ilk çalışmalarda dijitalleştirilen radyografik görüntüler, görüntü işleme teknikleriyle analiz edilmeye başlanmıştır. Radyografi analizleri genellikle metal kaynaklama sırasında ortaya çıkan hataların tespitinde kullanılmaktadır. Bu yöntem uygulanırken uzman kontrolü ve yorumuna ihtiyaç duyulmaktadır. Bu yöntemde; radyografi kalitesi ve kontrastının düşük olması, kaynak kalınlığı oldukça hassas bir konudur. Aynı zamanda yöntemin uygulanması için uzman kişilerin eğitilmesi ve deneyim kazanması gerekmektedir. Uygulamada tecrübeli uzmanların bile küçük hasarları tespit edememesi sorunu ortaya çıkabilmektedir. Bu tür yöntemlerde insana bağlı yorumlamaların yapılması aynı zamanda da çok fazla sayıda görüntü üzerinde çalışıyor olması da yöntemin uygulanabilirliğini zorlaştırmakta iş yükünü arttırmaktadır. (Hou ve ark., 2020). Bu sebepler doğrultusunda, bu yöntemle birlikte metal kaynaklarının bilgisayarlı görüntüleme kullanılması gerekli olmuş ve bu alanda çeşitli çalışmalar geliştirilmeye başlanmıştır (Shafeek vd. 2004; Liao ve Li, 1998; Gayer vd., 1990; Liao ve Ni, 1996; Mery ve Berti, 2003).

X-ışını radyografileri başlangıçta sadece film üzerinde görüntülenebilirken, detektörlerden dijital olarak elde edilen uçak parçalarının görüntüleri günümüzde gelişen görüntüleme teknikleriyle birlikte algoritmalar vasıtasıyla işlenebilmektedir (Wang ve ark., 2008). İlerleyen dönemlerde dijital X-ışını radyografilerinin kullanılabilir hale gelmesi durumunda, bu yöntem gelişmeye oldukça açık olacaktır. Yöntemin sunmakta olduğu arşivleme ve düzenleme kolaylığı ile birlikte yüksek duyarlılıkta görüntüler elde etme ve filminden dijital ortama geçirme zorunluluğunun ortadan kalkması gibi avantajlar sayesinde sürecin verimliliği artırılabilir (Wang vd. 2008).

Yapılan literatür taraması sonucunda; akıllı yapılar ve derin öğrenme teknikleri, uçak motorları üzerinde çeşitli bakım öngörüsü yöntemlerini incelemek amacıyla yapılan çalışmalara da rastlanmıştır. Xu ve ekibi, 100 farklı motordan elde edilen 21 sensör verisiyle motor sağlığını izlemeye çalışmıştır. Veriler incelendikten sonra, 7 sensör dışındakilerin motor durumuyla ilgili anlamlı bilgi içermediği belirlenmiş ve bu veriler elemine edilmiştir. Verilerin elemine edilmesinin ardından elde edilen veriler bir birleşik sistem oluşturularak Dempster-Shafer Regresyonu (DSR), Destek Vektör Makinesi (SVM) ve Tekrarlayan Sinir Ağı (RNN) teknikleriyle tahmin edilmeye çalışılmıştır. Bu tahminin ortalama karesel hatası (MSE) alınarak sonuç olarak 3.49 değeri elde edilmiştir. Bu çalışmada, topluluk oylamasına dayalı bileşik sınıflandırıcı ile elde edilen en yüksek sınıflandırma başarımı %90' ın biraz üzerinde bulunmuştur. Bu çalışma, sonuç olarak yüksek güvenilirlik oranı ve kabul edilebilir bir hata oranıyla hasar belirleme yapmayı başarmıştır.

3. MATERYAL VE METOT


Bu araştırmada, hava taşıtı yapılarında hasar tespiti için yapısal sağlık izleme sisteminin geliştirilmesine katkı sağlamak amacıyla derin öğrenme teknikleri ve veri füzyonu yöntemi kullanılmıştır. Çalışma kapsamında gerçekleştirilen adımlar aşağıda detaylandırılmıştır.

3.1. Veri Setinin Hazırlanması


Bu çalışmada, hava taşıtında kullanılmış gerçek yapısal parçalar kullanılmıştır. Veri seti oluşturulurken, bu yapısal bileşenlerden elde edilen görüntülerle birlikte, yapısal parçalara yerleştirilmiş titreşim sensörlerinden elde edilen titreşim verileri kullanılmıştır.

3.1.1. Yapısalara ait görüntüler

Birinci aşamada hava taşıtı üzerinde kullanılmış aynı geometriye sahip olan 9 adet hava taşıtı yapısalına ait görüntüler alınmıştır. Bu yapısalarda üzerinde kesik, çizik ve parçalama şeklinde oluşturulan yapay hasarlar verilmiştir. Yapay hasar verilen hasarlı yapısal parçalardan farklı açılardan çekilmiş 101 adet görüntü, hasarsız olan yapısal parçalara ait farklı açılardan çekilmiş 32 adet görüntü elde edilmiş ve jpeg formatında bilgisayara aktarılmıştır. Görüntüler hasarlı ve hasarsız olarak iki gruba ayrılmıştır. Veri setinde kullanılan yapısalara ait örnek görüntüler aşağıdaki gibidir.



Şekil 3.1. Hasarlı yapısal parça görüntüleri



Şekil 3.2. Hasarsız yapısal parça görüntüleri

3.1.2. Titreşim sensör verileri


Veri seti hazırlama sürecinin ikinci aşamasında, hasarlı ve hasarsız parçalar üzerine 5 adet titreşim sensörü ve 1 adet titreşim motoru yerleştirilmiştir. Buradaki amaç hasarlı ve hasarsız yapısal parçaların titreşim sinyallerine nasıl cevap vereceğini görmek ve anlamlı bir titreşim verisi elde ederek derin öğrenme ile analiz etmektir. Titreşim sensörü olarak SW-420

NC Tipi Titreşim Sensör Modülü, titreşim motoru olarak ta Arduino Titreşim Motoru Modülü kullanılmıştır.

SW-420 NC, yaygın olarak kullanılan bir titreşim sensörüdür ve genellikle titreşim algılama uygulamalarında kullanılmaktadır. "NC" tipi, "Normalde Kapalı" anlamına gelmektedir, sensör normalde bir titreşim algılanmadığında kapalı haldedir. SW-420, bir titreşim algılandığında devreyi kapatır ve bu sayede bir tetikleme sinyali üretir. Sensörün temel çalışma prensibi, içerisinde bir yay bulunan bir metal topunun titreşimi algılayarak bir devre değişikliği yaratmasıdır. Titreşimler, metal topunun yayın pozisyonunu değiştirmekte ve bu da sensörün çıkışındaki değişikliği tetiklemektedir.

SW-420 sensörü iki ana bağlantıya sahiptir: biri toprak (GND), diğeri ise besleme gerilimi (VCC) bağlantısıdır. Sensörün çıkışı bir dijital sinyal olarak sağlanmaktadır. Sensörün çıkışı titreşim algılandığında "1" vermekte ve algılanan titreşim durduğunda tekrar "0" veya düşük seviyeye düşmektedir. Çalışma kapsamında kurulan elektronik sistemde titreşim motorundan gelen titreşimin sensörler üzerinde çıkış ile titreşim algılamalarının ölçümü için kullanılmıştır. Burada analiz edilmek istenen durum, hasarlı/hasarsız parçalar arasında titreşim çıkışındaki farkların derin öğrenme teknikleri ile yakalanarak yapının sağlık durumunu hakkında analiz yapmasını sağlamak olmuştur.

Öncelikle sensörler S1, S2, S3, S4, S5 olarak isimlendirilmiş ve tüm parçalarda aynı konumda olacak şekilde yüzey üzerine yapıştırılmıştır. Sensörleri kullanmadan önce titreşim hassasiyetini ayarlamak için potansiyometre üzerinden tüm sensörler aynı değerde ayarlanmıştır. Yapısal parçaların orta bölümüne yakın olarak yerleştirilen titreşim motorunun çalışması ile bu sensörler üzerindeki veriler 30 sn. boyunca kaydedilmiştir. Kurulan elektronik devrenin kontrolü için Ardunio Nano geliştirme kartı kullanılmıştır. Ardunio Nano üzerinden devrenin kontrolü ve yazılımlarının yapılması için Ardunio programı kullanılmıştır. Veri okuma işlemleri için CoolTerm programı kullanılarak sensörlere gelen datalar text formatında kaydedilmiştir. Her bir sensör için 2000 Hz. Ve 4000 Hz. Olmak üzere iki ayrı titreşim frekansında çalışılmıştır. Daha çok veri elde etmek amacıyla bazı parçalardan birden çok kez veri ölçümü yapılmıştır. Hasarlı yapısal parçalar üzerinden 25 ölçüm, hasarsız parçalar üzerinden ise 12 adet ölçüm olmak üzere toplamda 37 adet ölçüm yapılmıştır. Her bir parçadan 5 sensör ölçümü olmak üzere tüm sensörlerden toplamda 185 adet sensör verisi elde edilmiş ve veri setinde kullanılmak üzere bilgisayar ortamında kaydedilmiştir. Sensör verileri hasarlı ve hasarsız olarak iki gruba ayrılmıştır. Kurulan elektronik sisteme ait görüntüler şekil 3.3' te verilmiştir.



Şekil 3.3. Hasarlı/hasarsız yapısalara kurulmuş olan elektronik sistem görüntüsü

3.1.3. Titreşim sensör verilerinin zamana bağlı değişiminin görüntüleri

Çalışmada hedeflenen sonuçlardan birisi de hem yapısal görüntülerinin hem de bu yapısalardan alınan sensör verilerinin tek bir derin öğrenme modeli kullanarak analiz edilmesi ve yapının sağlık durumu ile ilgili sonuç üretmesidir. Bu çalışmayı yapabilmek için kullanılacak veri setinde hem yukarıda gösterilmiş olan hasarlı/hasarsız parça görüntüleri, hem de titreşim sensör verilerinin zamana bağlı değişimini gösteren görüntüler kullanılmıştır. Kullanılan hasarlı ve hasarsız yapısal parçalara ait bu görüntülere ait örnekler Şekil 3.4 ve 3.5'te verilmiştir.



Şekil 3.4. Hasarlı yapısalardan alınan titreşim verilerinin değişim görüntüleri



Şekil 3.5. Hasarsız yapısalardan alınan titreşim verilerinin değişim görüntüleri

3.2. Derin öğrenme mimarilerinin kullanılması

Çalışma için görüntü sınıflandırma probleminde önceden eğitilmiş SqueezeNet mimarisi kullanılmış ve probleme özgü CNN mimarisi tasarlanmıştır. Sensör verilerinin eğitimi ve analizi içinse probleme özgü 1D CNN mimarisi tasarlanmıştır. Derin öğrenme modeli olarak kullanılan son ağ modeli ise iki girişli veri yapısına uygun sınıflandırma problemine özgü olarak tasarlanan iki girişli Multi Input-CNN mimarisi olmuştur. Bu modelde yapısal parçalara ait görüntüler ile sensörlerden alınan titreşim verilerinin zamanla değişimini gösteren görüntüler birlikte kullanılarak başarımlar elde edilmeye çalışılmıştır.

Derin öğrenme teknikleri kullanılarak hasar tespiti yapmak amacıyla MATLAB 2023b programı ile image processing, deep learning, statistics ve machine learning toolboxları kullanılmıştır.

3.2.1. Ön işleme

Hasar tespiti için kullanılan hasarlı ve hasarsız yapısal parça görüntüleri, ön işleme tabi tutularak yeniden boyutlandırılmıştır. Bu yaklaşımın temel sebebi, farklı derin öğrenme modellerinde uygulanan girişlerde optimum boyutu sağlamaktır. Görüntüler, ağ girişleri için

224x224 piksel boyutuna ayarlanmıştır.

1D-CNN modelinde kullanılan titreşim sensör verileri, aynı formatta ve aynı giriş düzenine sahip olacak şekilde düzenlenmiştir. Bu düzenleme sonucunda, giriş olarak kullanılmak üzere veri seti 209x1x1 boyutuna getirilmiştir.

Multi-CNN modelinde toplamda 70 hasarlı, 20 hasarsız olmak üzere toplam 90 yapısal parça görüntüsü ile, 70 adeti hasarlı yapısalardan alınmış, 20 adet hasarsız yapısalardan alınmış olmak üzere 90 adet sensör verisinin zamana bağlı değişimini gösteren görüntü kullanılmıştır. Multi-Input CNN yapısında ağ girişlerine uygulanan her bir giriş için random olacak şekilde eşit sayıda veri seçilmiştir. Görüntülerin tamamı 224x224 piksel boyutunda ayarlanmıştır.

3.2.2. Eğitim ve test datalarının seçimi

Derin öğrenme modellerinde kullanılan veriler eğitim ve test verisi olarak ayrılmaktadır. Oluşturulan derin öğrenme modellerinde veri seti olarak ağı sunulan görüntüler; %70 oranında eğitim, %30 oranında ise test verisi olarak ayrılmıştır. Toplamda 133 adet görüntünün 93 adeti eğitim seti olarak 40 adeti ise test seti olarak kullanılmıştır.

1D-CNN modelinde kullanılan sensör veriler; %60 oranında eğitim verisi, % 40 oranında test verisi olacak şekilde ayrılmıştır. Her bir ölçümden gelen sensör verileri ayrı ayrı olacak şekilde eğitim ve test verisi olarak ayrılmıştır. Toplamda 185 adet sensör verisinin, 111 adeti eğitim verisi, 74 adeti test verisi kullanılmıştır.

Multi-Input CNN mimarisinde kullanılan veriler de; %70 oranında eğitim, %30 oranında ise test verisi olarak ayrılmıştır. Bu verilerden 63 tanesi eğitim verisi, 27 tanesi ise test verisi olarak seçilmiştir.

3.2.3. Tasarlanan/kullanılan derin öğrenme modelleri

3.2.3.1. SqueezeNet mimarisi ile yapısal parça görüntülerinin sınıflandırılması





Kullanılan ilk model SqueezeNet mimarisidir. Squeeze.net mimarisinde bulunan katmanlar Çizelge 3.1’ de detaylı olarak anlatılmıştır. Ayrıca bu yapıyı anlatan görsel, Şekil 3.6’ da verilmiştir.


Çizelge 3.1. SqueezeNet mimarisi katmanları (Metlek ve Çetiner,2021)

Katmanlar ve özellikleri	Görüntü
Her bir konvolüsyonel sinir ağı giriş katmanından başlar ve ağı sunulan veriler bu katmanda ilk kez işlenir. Veriler üzerinde boyutlandırma yapıldıysa veriler doğrudan bu şekilde ağı veri iletilir. Ancak, eğer verilerin boyutlarında optimum boyutlar kullanılmadıysa ve ağın kuralı gereğince olması gereken bir boyut var ise gerekli boyutlandırma işlemi burada gerçekleştirilir	

Devamı Arkada

Çizelge 3.1.' in devamı

Katmanlar ve özellikleri	Görüntü
Kendisinden önceki giriş katmanından gelen veriler üzerinde çalışan katman Konvolüsyon katmanıdır. Bu katmanda, geliştiricilerin belirlediği $m \times n$ boyutlarındaki filtreler, veri matrisi üzerinde dolaştırılarak yeni öznitelik matrisleri oluşturulur. Bu süreç, girdi verisinin özelliklerini vurgulamak ve çeşitlendirmek için filtrelerin uygulanması yoluyla gerçekleşir.	
Kendisinden önceki Konvolüsyon katmanından elde edilen matris değerleri üzerinde işlem yaparak bu değerleri belirli bir aralığa getiren katman, Aktivasyon Katmanıdır. Bu işlem, kullanılan aktivasyon fonksiyonları aracılığıyla gerçekleştirilir. Sigmoid, hiperbolik tanjant sigmoid, adım (step), ve ReLU gibi çeşitli aktivasyon fonksiyonları, matris değerlerini dönüştürmek ve modelin öğrenme yeteneğini artırmak için kullanılır.	
Bir sonraki katman, Havuzlama Katmanıdır. Bu katmanda gelen verileri daha küçük boyutlardaki matrislere indirgeme işlemi yapılır. Bu katman, veri boyutunu azaltarak ağına daha etkili ve hızlı çalışmasına olanak tanır, ancak bazı durumlarda veri kaybına neden olabilir. Ortalama, minimum ve maksimum değer matrisleri gibi çeşitli tekniklerle gerçekleştirilen veri indirgeme işlemi, farklı uygulama senaryolarına uygun şekilde kullanılabilir.	
Kullanılan verilerin az sayıda olması ağ modelinde aşırı öğrenme problemini doğurmaktadır. Kullanılan eğitim setinde Ezberleme Katmanı ile ezberleme oluşmasının önüne geçilmektedir.	
Bir önceki katmandan gelen verilerin tamamını alıp tek boyutlu vektör matrisine çeviren katman Tam Bağlantı Katmanıdır. Buradan elde edilen matris dizini bir sonraki katman olan sınıflandırma katmanına direkt bir şekilde giriş olarak atar.	
Ağ modelinde final katmanı sınıflandırma katmanı olup bu katmanda, bir önceki tam bağlantı katmanından gelen veriler değerlendirilir. Bu veriler derin öğrenme ağının çıkışı oluşturulur. Genellikle bu katmanda SoftMax sınıflandırıcısı sıkça kullanılmaktadır.	



Şekil 3.6. SqueezeNet mimarisi

SqueezeNet mimarisinde toplamda 68 katman bulunmaktadır. Bu katmanlarda öğrenebilen katman sayısı 18'dir (Matlab 2023b). Bu mimarinin temel özelliği, başarılı bir analiz yapabilmesi için boyut kapasitesini ve parametre sayısını azaltmaktır (Iandola et al., 2016). Bu nedenle günümüzde tercih edilen bir mimari haline gelmiştir.

3.2.3.2. Probleme özgü CNN mimarisi ile yapısal parça görüntülerinin sınıflandırılması

Derin öğrenme modeli olarak yapısal parça görüntülerinin giriş olarak tanımlandığı diğer bir model ise probleme özgü olarak tasarlanan CNN Modelidir. Tipik bir CNN mimarisi olarak tasalanan bu modelde; 10 evrişimli katman, 3 ReLU katmanı, 4 maksimum havuzlama katmanı, 2 tam bağlantılı katman, 1 softmax katmanı ve 1 sınıflandırma katmanı olmak üzere toplamda 20 katman bulunmaktadır. Katmanların özet bilgileri şu şekildedir:

Giriş Katmanı (imageInputLayer): Giriş olarak yeni boyutlanmış görüntülerin kabul edildiği katmandır. Bu katman, yeni boyutlanmış giriş boyutlarını alır.

Evrişimli Katmanlar (convolution2dLayer): Yapılan evrişim işlemleri sayesinde görüntüdeki özellikler çıkarılır. Bu özelliklerin sayısı ve boyutları, katmanların parametreleri tarafından belirlenir. Kod örneğinde, 3x3 boyutunda ve farklı filtre sayılarına sahip evrişimli katmanlar kullanılmıştır. Örnek olarak, 16, 32, 64 ve 128 filtrelili evrişimli katmanlar mevcuttur.

ReLU Katmanları (reluLayer): ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, evrişimli katmanların çıktılarını sıfırdan büyük değerlere dönüştürür. Bu katmanlar, ağın doğrusallığını kırmak ve ağı öğrenme kapasitesini artırmak için kullanılır.


Maksimum Havuzlama Katmanları (maxPooling2dLayer): Maksimum havuzlama, evrişimli katmanların çıktılarını örneğin boyutunu küçültmek ve özellik haritalarındaki konumsal değişikliklere karşı duyarsız hale getirmek için kullanılır. Örneğin, 2x2 boyutunda ve belirli bir adımda (stride) maksimum değeri alarak havuzlama işlemi yapılır.

Tam Bağlantılı Katmanlar (fullyConnectedLayer): Tam bağlantılı katmanlar, evrişimli ve havuzlama katmanlarının çıktılarını alıp, bu çıktıları sınıflandırma için uygun boyutlara dönüştürür. Bu katmanlar genellikle ağırlıklı toplam işlemi yaparak çıktıları oluştururlar.

Softmax Katmanı (softmaxLayer): Softmax aktivasyon fonksiyonu, ağıın sınıflandırma sonuçlarını olasılık dağılımına dönüştürür. Bu katman, ağıın her bir sınıfa ait olasılıkları hesaplar.

Sınıflandırma Katmanı (classificationLayer): Sınıflandırma katmanı, ağıın çıktılarını sınıflar arasında bir karar verir.

Kullanılan ağ mimarisinin katmanları şekil 3.7' de detaylı olarak gösterilmektedir.



Şekil 3.7. Probleme özgü CNN mimarisi

3.2.3.3. 1D-CNN mimarisi ile sensör verilerinin sınıflandırılması

Yapısal parçalar üzerine yerleştirilen sensör verilerinin derin öğrenme yöntemi kullanılarak sınıflandırıldığı model olarak klasik 1D-CNN modeli kullanılmıştır. Kullanılan bu model 7 katmandan oluşmaktadır. Ağıın sahip olduğu katmanlar ve işlevleri şu şekildedir:

ImageInputLayer: Sensör verilerini kabul etmek için kullanılmaktadır. Görüntülerin boyutu 209x1x1 olarak ayarlanmıştır.


Convolution2dLayer: 6 adet 32 filtre içeren evrişim katmanıdır. 'Padding' parametresi 'same' olarak ayarlanmıştır, bu da çıktı boyutunun giriş boyutuyla aynı olacağı anlamına gelmektedir.

ReluLayer: ReLU (Rectified Linear Unit) aktivasyon fonksiyonunu uygulamaktadır.

FullyConnectedLayer: 500 nöron içeren tam bağlantılı bir gizli katmandır.

SoftmaxLayer: Sınıflandırma sonuçlarını hesaplamak için softmax aktivasyon fonksiyonunu kullanmaktadır.

Kullanılan ağ mimarisinin katmanları şekil 3.8’ de gösterilmektedir.



Şekil 3.8. Titreşim sensör verilerini sınıflandırmada kullanılan 1D-CNN mimarisi

3.2.3.4. Probleme özgü Multi-Input CNN mimarisi ile yapısal parça görüntüleri ve sensör verilerinin sınıflandırılması

Derin öğrenme modeli olarak kullanılan son ağ modeli ise özgün olarak tasarlanan iki girişli CNN ağ modeli olmuştur. Bu modelde yapısalara ait görüntüler ile sensörlerden alınan titreşim verilerinin zamanla değişimini gösteren görüntüler kaydedilerek iki farklı görüntü kaynağı olarak ağın girişine verilmiştir. Ağ yapısındaki katmanlar, iki farklı görüntü kaynağından gelen verileri işleyecek ve sonuçları birleştirerek karmaşık bir derin öğrenme modeli problemini çözmek amacıyla tasarlanmıştır. Ağın sahip olduğu katmanlar ve işlevleri şu şekildedir:

Giriş Katmanları (input1 ve input2):

İki farklı görüntü kaynağından gelen verileri kabul eden katmandır. Giriş katmanına giriş olarak tanımlanan veriler 3 kanallı (RGB) 224x224 piksel boyutundadır.

Evrişim Katmanları (conv_1 ve conv_2):

Bu katman her iki veri için de giriş katmanından sonra gelmektedir. Evrişim işlemi, görüntü üzerinde belirli boyutlarda filtrelerin kaydırılmasıyla yapılmaktadır. Burada 3x3 boyutunda 16 filtre kullanılmakta ve "same" dolgusu uygulanmaktadır.

ReLU Katmanları (relu_1 ve relu_2):

Evrişim katmanlarının çıktılarını alana ve negatif değerleri sıfıra eşitleyen katmandır. Bu katmanlar, ağın doğrusal olmayan özellikler öğrenmesine yardımcı olmaktadır.

Tam Bağlantılı Katmanlar (fc11 ve fc21):

Evrişim ve ReLU katmanlarının çıktılarını almakta ve her bir pikselin her bir sınıf için bir ağırlık ile çarpılıp toplanmasını sağlamaktadır. Tam bağlantılı katmanlarında 10 nöron bulunmaktadır.

Toplama Katmanı (add):

İki tam bağlantılı katmanın çıktılarını toplayan katmandır. İki farklı giriş kaynağından gelen bilgiler toplama katmanında birleştirilmektedir.

Son Tam Bağlantılı Katman (fc12):

Toplama katmanından gelen çıktıları alan ve sınıflandırma işlemi için kullanan katmandır. Burada, numClasses kadar çıktı nöronu bulunur.


Softmax Katmanı (softmax):

Son tam bağlantılı katmanın çıktılarını alan ve bu çıktıları sınıf olasılıklarına dönüştüren katmandır. Sınıf olasılıkları, toplamın 1'e eşit olduğu bir olasılık dağılımı sağlar.

Sınıflandırma Katmanı (classOutput):

Softmax katmanının çıktılarını alan ve sınıf etiketlerini tahmin etmek için kullanan katmandır. Modelin nihai çıkışı oluşturur.

Kullanılan ağ mimarisinin katmanları şekil 3.9' da detaylı olarak gösterilmektedir.



Şekil 3.9. Probleme özgü Multi-Input CNN mimarisi

4. BÜLGÜLAR

Tez çalışması kapsamında hem görüntü verileri hem de sensör verileri derin öğrenme modelleri kullanılarak eğitilmiş ve test edilmiştir. Yapısal parçalara ait görüntüler SqueezeNet mimarisi ve probleme özgü temel CNN modeli kullanılarak eğitilmiş ve sınıflandırılmıştır. Sensör verilerinin eğitimi ve analizi için ise 1D-CNN modeli tercih edilmiştir. Hem yapısal görüntülerinin hem de sensör verilerine ait zamana bağlı değişimin görüntüleri birleştirilerek kullanıldığı ağ mimarisi ise probleme özgü olarak tasarlanan Multi-Input CNN modeli olmuştur. Elde edilen sonuçlar şu şekildedir.

Çizelge 4.1. Görüntü eğitim ve test verileri sınıflandırma sonuçları


Kullanılan Derin Öğrenme Mimarisi	Giriş Verisi	Accuracy_Eğitim (%)	Accuracy_Test (%)
SqueezeNet	Yapısal Parça Görüntüleri	96,77	87,5
Probleme özgü CNN Mimarisi	Yapısal Parça Görüntüleri	100	72,5
Probleme özgü Multi-Input CNN Mimarisi	Yapısal Parça Görüntüleri ve Parçalar üzerinden alınan titreşim verilerine ait değişimin görüntüleri	92,06	88,89

Çalıştırılan algoritmaların eğitim ilerlemelerini gösteren eğitim süreci değişim grafikleri ve karışıklık matrisleri görüntü sınıflandırma amacıyla kullanılan her bir mimari için ayrı ayrı sunulmuştur.


Şekil 4.1. yapısal parça görüntülerini sınıflandırmak için kullanılan ilk mimari olan SqueezeNet mimarisi eğitim süreci değişimini göstermektedir. Şekil 4.2’ de test verisi olarak kullanılan 40 görüntü için karışıklık matrisi sonuçlarını göstermektedir.

Şekil 4.3. yapısal parça görüntülerini sınıflandırmak için kullanılan ve probleme özgü oluşturulan CNN mimarisi eğitim süreci değişimini göstermektedir. Şekil 4.4’ de test verisi olarak kullanılan 40 görüntü için karışıklık matrisi sonuçlarını göstermektedir.


Şekil 4.5 yapısal parça görüntüleri ve sensör titreşim verilerinin zamana bağlı değişiminin görüntüleri üzerinden sınıflandırmak için kullanılan ve probleme özgü oluşturulan Multi-Input CNN mimarisi eğitim süreci değişimini göstermektedir. Şekil 4.6’ da test verisi olarak kullanılan 27 görüntü için karışıklık matrisi sonuçlarını göstermektedir.




Şekil 4.1. SqueezeNet mimarisi eğitim süreci değişimi




Şekil 4.2. SqueezeNet mimarisi test verisi karışıklık matrisi




Şekil 4.3. Probleme özgü CNN mimarisi eğitim süreci değişimi



Şekil 4.4. Probleme özgü CNN mimarisi test verisi karışıklık matrisi



Şekil 4.5. Probleme özgü Multi-Input CNN mimarisi eğitim süreci değişimi



Şekil 4.6. Probleme özgü Multi-Input CNN mimarisi test verisi karışıklık matrisi

Sensör verisi eğitim ve test sınıflandırma sonuçları:

Sensör verileri eğitimi ve analizi için 1D-CNN modelinde farklı eğitim seçenekleri kullanılmış, ağ parametrelerinde değişiklik yapılarak sınıflandırma problemine yönelik etkisi incelenmiştir. Kullanılan farklı optimizier türleri için 1D-CNN ağ modelinde elde edilen sonuçlar şu şekildedir:

Çizelge 4.2. Sensör eğitim ve test verileri sınıflandırma sonuçları

	Eğitim verileri				Test verileri			
Kullanılan Optimizer	Accuracy (%)	F1	Recall	Precision	Accuracy (%)	F1	Recall	Precision
adam	100	1	1	1	74,32	0.36	0.60	0.67
sgdm	100	1	1	1	64.86	0.32	0.25	0.43

Çizelge 4.3. Multi-Input CNN ile 1D-CNN mimarisi test verisi performansları

Kullanılan Derin Öğrenme Mimarisi	Kullanılan Veri Türü	Accuracy (%)	F1	Recall	Precision
1D-CNN mimarisi	Yapısal Parçalar üzerinden alınan sensör verileri (text)	74,32	0.36	0.60	0.67
Probleme özgü Multi-Input CNN mimarisi	Yapısal Parça Görüntüleri ve Parçalar üzerinden alınan titreşim verilerine ait değişimin görüntüleri (Jpeg)	88,89	0.93	1	0,875

5. TARTIŞMA

Hava taşıtlarında hasar tespiti, genellikle tahribatsız muayene yöntemleriyle gerçekleştirilmektedir. Tahribatsız muayene, malzeme veya parçanın bütünlüğünü koruyarak yapılan muayene yöntemidir. Bu yöntem kullanılarak, malzemelerin içindeki görünmeyen veya yüzeydeki süreksizlikler belirlenir. Sıklıkla kullanılan tahribatsız muayene yöntemleri; optik teçhizat ve gözle muayene, ultrasonik kontrol, radyografik kontrol, D-görüntüleme yöntemiyle kontrol, termografik kontrol, senkronize basınç dalgaları ile kontrol, bondaskop ile kontrol ve akustik emisyon tekniğiyle kontroldür.

Yapısal sağlık izleme (YSİ); yapının üzerinde bir hasar oluşmasının ardından, bu hasarın tespiti, konumu, büyüklüğü ve yapının ömür bilgisine ulaşabilmek için belirli tekniklerin uygulandığı bir prosestir. YSİ, bu sistemlerin veya bileşenlerin sürekli olarak değişen koşullara tepkisini ölçerek gerçekleştirilir. Bu sürekli izleme, erken arıza tespiti ile ciddi hasarların önceden engellenmesine, bakım çalışmalarının azaltılmasına ve gereksiz denetimlerden kaçınılmasına olanak tanır. Bu süreç, devamlı olması durumunda perspektifte yapısal sağlık hakkında değerli bilgiler sağlar. Erken arıza tespiti, yapının önceden belirlenen fonksiyonlarını yerine getirip getirmediği konusunda düzenli olarak güncellenen çıktılar aracılığıyla sağlanır.

Tahribatsız muayene yöntemleri yapısal sağlık izleme sistemlerine göre daha olgun teknolojiler olmasına rağmen uzman bir personel tarafından uygulansa dahi öznel bir yorum taşımaktadır. Ayrıca YSİ' ne göre daha fazla iş gücüne ihtiyaç duyar. Tahribatsız muayene tekniklerini uygulamak için harici prob veya ekipman kullanımı gerektiğinden YSİ' ne göre daha maliyetlidir. Ayrıca güncel teknolojinin ihtiyacı olan ana özelliklerin başında gelen duruma dayalı bakım özelliği tahribatsız muayene teknolojilerinde bulunmamaktadır. Bu nedenle, sahada kullanım sırasında hasarları izlemek için bir yol olarak, sensör tabanlı akıllı yapıların kurulumu önem kazanmaktadır. Kompozit malzemelerin kullanımı, nano seviyeden makro seviyeye kadar olan tasarım ve üretim süreçlerinde sensörlerle yapısal sağlığın anlık ve sürekli olarak izlenmesine imkan tanır. Bu sayede, bu yapıların akıllı yapılar haline dönüşmesi ve etkin bir şekilde kullanım sırasında izlenmesi mümkün olabilir.

Yapısal sağlık izleme (YSİ) sisteminin temel unsurlarından biri, yapısal bileşene kalıcı bir şekilde eklenebilen sensörlerin varlığıdır. Yapısalara bu şekilde entegre edilen sensörler sayesinde yapısal sağlık izleme sistemleri akıllı yapı halini almakta, bu sayede kazanmış olduğu gerçek zamanlı hasar tespiti yeteneği ile çeşitli taşıtların yapısal sağlığını izleme ve olası hasarları giderme çalışmalarında önemli bir rol oynamaktadır.

Bu çalışmada, hava taşıtlarında hasar tespiti yapan mevcut teknolojilere alternatif bir çözüm sağlamak ve literatüre bu alanda katkı sağlamak hedeflenmiştir. Bu hedef doğrultusunda hava taşıtında kullanılmış gerçek hava taşıtı yapısalı kullanılarak özgün olarak oluşturulan veri setinde bu yapısalardan üzerinden alınan görüntüler ile yapısalardan üzerine yerleştirilmiş titreşim sensörlerinden elde edilen titreşim verileri kullanılmıştır. Kullanılan bu görüntü ve sensör verileri derin öğrenmeyle eğitilen görüntü işleme algoritmaları kullanılarak incelenmiştir. Yapay sinir ağlarının eğitilmesi çok fazla veri ve uzun zaman gerektirdiğinden elde edilen verilerin analizi için transfer öğrenmesi metoduyla daha önceden eğitilmiş SqueezeNet ağ yapısı kullanılmış ayrıca özgün CNN yapısında bir ağ modeli de geliştirilerek hasarlı-hasarsız sınıflandırma probleminin sonuçları analiz edilmiştir. SqueezeNet ağ mimarisi kullanılarak eğitim setinde % 96,77 doğruluk, test setinde ise % 87,5 doğruluk elde edilmiştir. Özgün olarak geliştirilen CNN mimarisinde ise eğitim setinde %100, test setinde ise % 72,5 doğruluk elde edilmiştir.

Çalışmanın özgün tarafını oluşturan kısımlardan birisi de hem yapısal görüntülerinin hem de sensör verilerinin veri füzyonu yöntemi ile birlikte analiz edildiği ağ modeli Multi-Input CNN ağ mimarisinin tasarlanması olmuştur. Bu mimarinin kullanımı sonrasında eğitim verilerinde % 92,06 doğruluk, test verilerinde % 88,89 elde edilmiştir.

Görüntülerde tespit edilmesi istenen hasarları en yüksek başarı oranıyla eğiten ağ yapısı probleme özgü tasarlanan CNN ağ modeli olmuştur. Ancak hem görüntüleri hem de sensör verilerinin görüntüleri üzerinden sınıflandırma yapmayı sağlayan Multi-Input CNN modeli ise eğitilen görüntüler arasında en iyi test sonucunu veren ağ modeli olmuştur.

Sensör verilerinin tek başına analiz sonuçlarına bakıldığında ise, 1D-CNN yapısında kullanılan parametrelerin doğruluk ve diğer ağ başarımlarını etkilediği görülmektedir. Kullanılan 1D-CNN modelinde en etkili sonuçları adam optimizör seçeneği sunmuştur. Adam optimizör eğitim seçeneği ile eğitim verilerinin doğruluğu %100 olurken, test verilerinde % 74,32 oranında doğruluk elde edilmiştir. F1score 0.3529, Recall 0.60, Presicion değeri ise 0.67 olarak hesaplanmıştır.

Sadece sensör veri setini en iyi sonuçlar ile analiz eden parametrelere sahip olan 1D-CNN ağ modeli ile Multi-Input CNN ağ modeli kıyaslandığında ise tüm performans kriterlerinde Multi-Input CNN ağ modelinin 1D-CNN ağ modeline göre çok daha iyi başarımlar sağladığı sonucu elde edilmiştir.

Veri setinde bulunan hasarlı ve hasarsız yapısal parçalara ait titreşim verilerinin derin öğrenme kullanılarak analiz edilebilmesi için daha fazla veriye ihtiyaç olduğu aşikardır. Ancak elde edilen veriler ışığında yapısal parçalar üzerindeki hasarların titreşim verisinde etkiye sebep olduğu net bir şekilde ifade edilebilir.

6. SONUÇLAR

Derin öğrenme algoritmalarının eğitim ve çalışma süreleri dikkate alındığında, hata tespiti süre ve maliyet açısından önemli verim sağlamak için daha etkin sonuçlar elde edilebilir. Bu tez kapsamında, literatürdeki benzer çalışmaların detayları, bu çalışma ile olan benzerlikler ve farklılıklar Bölüm 2'de ayrıntılı bir şekilde açıklanmıştır. Genellikle derin öğrenme algoritmalarını eğitmek için binlerce veriye ihtiyaç duyulmaktadır ancak bu çalışmada veri seti oluşturulurken kısıtlı şekilde elde edilmiş hava taşıtında kullanılmış gerçek hava taşıtı yapıları kullanılmıştır. Özgün olarak oluşturulan veri setinde bu yapılar üzerinden alınan görüntüler ile yapılar üzerine yerleştirilmiş titreşim sensörlerinden elde edilen titreşim verileri kullanılmıştır. Bu yapılar üzerinden 101 adeti hasarlı, 32 adeti hasarsız olmak üzere toplam 133 adet görüntü alınmış ve 25 adeti hasarlı, 12 adeti hasarsız parçalar üzerinden olmak üzere 37 adet sensör verisi ölçülmüştür. Her bir ölçümde beşer adet sensör verisi ölçüldüğünden toplamda 185 adet sensör verisi elde edilmiştir. Hasarlı/hasarsız parça görüntüleri eğitmek ve sınıflandırmak için derin öğrenme mimarilerinden SqueezeNet ve klasik bir CNN modeli özgün olarak geliştirilmiştir. Sensör verileri tek başına 1 D-CNN Yapısı kullanılarak eğitilmiş ve sınıflandırılmıştır. Bunun yanı sıra çalışmanın özgün tarafını oluşturan bir diğer bölüm Multi-Input CNN yapısının kullanımı olmuştur. Bu ağ modelinde hem hasarlı/hasarsız parça görüntüleri, hem de hasarlı/hasarsız sensör verileri giriş olarak tanımlanmış ve ağ yapısında iki verinin birlikte kullanılması sonucunda eğitim ve sınıflandırma yapılmıştır. Transfer öğreniminin kullanılıyor olmasındaki amaç, model geliştirmek için gereken büyük miktarda veri, zaman, beceri ve teknik kaynakları minimize ederek, mevcut küçük veri setiyle etkili sonuçlar elde etmek olmuştur.

Yapılan çalışmalar neticesinde hasarlı ve hasarsız parça sınıflandırması tüm modellerde gerçekleştirilmiş ve en başarılı sonuç Multi-Input CNN ağ mimarisi kullanımında alınmıştır. Oluşturulan modellerin daha fazla sayıda veri içeren veri seti kullanımı sayesinde geliştirilmesi ve daha iyi sonuçlar vermesi öngörülmektedir.

Bu çalışma, mevcut yapısal sağlık izleme prosedürlerine katkıda bulunabilecek, uygun maliyetli ve hızlı bir hasar tespiti yöntemi önermektedir. Kullanılan derin öğrenme yöntemleri sayesinde denetçi tecrübesine bağımlı olmayan ve insan kaynaklı hata oranını ortadan kaldıran bir çözüm sunmaktadır. Hava taşıtlarına ait yapıların hasar tespiti, uzman personel eğitimi ve tecrübesi gereksinimine ek olarak insan faktöründen kaynaklanan öznellik gibi durumlar nedeniyle bilgisayar tabanlı çözümlerle daha pratik ve hassas hale getirilebilir.

Bu çalışmadan elde edilen sonuçlar bu alanda yapılabilecek çalışmalara örnek oluşturması öngörülmektedir. Gelecekte yapılacak çalışmalarda radyolojik görüntü, termal görüntü, ultrasonik frekans ölçümleri gibi yapısal parçalar üzerinden alınacak farklı veriler de veri füzyonuna dahil edilerek başarımları artırılabilir.

7. KAYNAKLAR

- Aktan A. E., Catbas F. N., Grimmelsman K. A., and Tsikos C. J., 2000, Issues in Infrastructure Health Monitoring for Management Authors: Journal of Engineering Mechanics, vol. 126, 7 s.
- Anonim 1: SAE Standardı ARP6461- Sabit Kanatlı Uçaklarda Yapısal Sağlık İzlemenin Uygulanmasına İlişkin Kılavuz, www.sae.org/iaqg/publications/standards.html [Son erişim tarihi: 20.12.2023].
- Aysenur Hatipoglu, Kemal Fidanboyu, Conference Paper · October 2019, Havacılık Sektöründe Fiber Optik Sensör Uygulamaları, pp. 57-65
- Biroğul S., Sönmez Y., Güvenç U., 2007, Veri Füzyonuna Genel Bir Bakış Politeknik Dergisi
- Boller C., 2003, Smart Structures in Engineering and Technology — An Aerospace and Automotive Perspective, European Workshop on Smart Structures in Engineering and Technology, pp. 39-52
- C. Bockenheimer, H. Speckmann, Stanford, USA, 2013, Validation, Verification and Implementation of SHM at Airbus, IWSHM 2013.
- Dey, S. 2018. Hands-On Image Processing with Python, Packt, 1-492.
- Doğan F., Türkoğlu İ., 2019, Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, DÜMF Mühendislik Dergisi 10:2 (2019) : 409-445
- Erdem S. 2022. Jet Uçaklarında Transfer Öğrenimi Yöntemiyle Hasarlı Parçaların Tespiti. Yüksek lisans tezi, Sakarya Üniversitesi, Sakarya, 57 s.
- Galea S.C., Baker A. A., 2001, Smart Structures Approaches for Health Monitoring of Aircraft Structures Smart Structures and Devices, pp.340-354
- Gayer, A., Saya, A., Shiloh, A. 1990. Automatic recognition of welding defects in real-time radiography. Ndt International, 23(3): 131-136.
- Goodfellow, I., Bengio, Y., Courville, A. 2017. Deep Learning (Adaptive Computation And Machine Learning Series). Chapter 9, pp. 321-359.
- Guidelines for Implementation of Structural Health Monitoring on Fixed Wing Aircraft ARP6461, 2013, USA, 95 s.
- Guo H., Xiao G., Mrad N., Yao J., 2011, Fiber Optic Sensors for Structural Health Monitoring of Air Platforms, pp. 3687-3705
- Günaydın A.C., Hatipoğlu A., Fidanboyu K., 2019, Havacılık Sektöründe Fiber Optik Sensör Uygulamaları, TMMOB Makina Mühendisleri Odası X. Ulusal Uçak, Havacılık ve Uzay Mühendisliği Kurultayı, ss. 57-65, 11-12 Ekim, Eskişehir.
- H. Speckmann, Cologne, 2007, Structural Health Monitoring (SHM), IMRBPB Meeting, EASA.
- Hinton, Geoffrey E. 2012, A Practical Guide to Training Restricted Boltzmann Machines, In Neural Networks: Tricks of the Trade, Springer, 599–619.
- Hou, W., Zhang, D., Wei, Y., Guo, J., Zhang, X. 2020, Review on computer aided weld defect detection from radiography images. Applied Sciences, 10(5): 1878.
- Ignatovich S., Yutskevych S., and Makarov I., 2022, Features of aircraft structures corrosion damage during storage under COVID-19 restrictions, Procedia Structural Integrity, vol. 36, pp. 66–70.

- J. Liu, Jul. 2021, Maintenance model of aircraft structure based on three-stage degradation process, *Computers & Industrial Engineering*, vol. 157, p.
- J. N. Kudva, C. M. Arantidis, J. D. Gentry, E. B. Lazic, 1993, Smart structures concepts for aircraft structural health monitoring, *Smart Structures and Materials, Smart Structures and Intelligent Systems*, Albuquerque, NM, s.964-971.
- Johnson, S. 2006. Stephen Johnson on Digital Photography, O'Reilly & Associates, 1-320.
- Lawson N. J., Correia R., James S. W., Partridge M., Staines S. E., Gautrey J. E., Garry K. P., Holt J. C., Tatam R. P., 2016, Development and application of optical fibre strain and pressure sensors for in-flight measurements, *Measurement Science and Technology*, pp.17
- Liao, T. W., Li, Y. 1998. An automated radiographic NDT system for weld inspection: Part II—Flaw detection. *Ndt & E International*, 31(3): 183-192.
- Liao, T.W., Ni, J. 1996. An automated radiographic NDT system for weld inspection: Part I—Weld extraction. *Ndt & E International*, 29(3): 157-162.
- Lin B., Zhao Y., and Huang X., 2018, A CNN Accelerator on FPGA Using Depthwise Separable Convolution, *IEEE Transactions on Circuits and Systems II: Express Briefs* 65(10): 1415–19.
- Mery, D., Berti, M. A. 2003. Automatic detection of welding defects using texture features. *Insight-Non-Destructive Testing and Condition Monitoring*, 45(10): 676-681.
- Metlek S., Çetiner H., 2021, *Matlab Ortamında Derin Öğrenme Uygulamaları*, İksad Yayınevi, Ankara, 71 s.
- Mofokeng T., Mativenga P. T., and Marnewick A., 2020, Analysis of aircraft maintenance processes and cost, *Procedia CIRP*, vol. 90, pp. 467–472.
- Mrad N., Xiao G. Z., 2005, Multiplexed Fiber Bragg Gratings For Potential Aerospace Applications, *International Conference on MEMS, NANO and Smart Systems (ICMENS'05)*, pp. 359–363
- Namkung M., Wincheski B., and Padmapriya N., 2016, NDT in the Aircraft and Space Industries, *Reference Module in Materials Science and Materials Engineering*,
- P. D. Bravo-Mosquera, F. M. Catalano, and D. W. Zingg, 2022, Unconventional aircraft for civil aviation: A review of concepts and design methodologies, *Progress in Aerospace Sciences*, vol. 131, p.
- Petrou, M.M., Petrou, C. 2010. *Image processing: The Fundamentals*, 2nd Edition,
- R. C. Foedinger, D. L. Rea, J. S. Sirkis, C. S. Baldwin, R. Troli, R. Grande, C. S. Davis, T. L. VanDiver, CA, 1999, Embedded fiber optic sensor arrays for structural health monitoring of Filament wound composite pressure vessels, *Smart Structures and Materials, Sensory Phenomena and Measurement Instrumentation for Smart Structures and Materials*, Newport Beach, pp. 289-301.
- Raman A., Basu A., Mianjy P., Mukherjee A., 2018, Understanding Deep Neural Networks with Rectified Linear Units, *ICLR 2018 Conference Blind Submission*, P.584
- Ruder, S. 2017. *Transfer Learning - Machine Learning's Next Frontier*. <https://ruder.io/transfer-learning/> [Son Erişim Tarihi: 10.07.2023].
- S. Weber, 2017, Measurement of dynamic rotor blade deformation (BLADESENSE)™ Aerospace Technology Institute.

- S.Weber, L. R. Valle, X. Barral, D. Hayes, A. Cooke, M. Lone, Grapevine, Texas, 2017, Impact of Rotor Blade Aeroelasticity on Rotorcraft Flight Dynamics, AIAA Atmospheric Flight Mechanics Conference, pp. 1-14.
- Shafeek, H. I., Gadelmawla, E. S., Abdel-Shafy, A. A., Elewa, I. M. 2004. Assessment of welding defects for gas pipeline radiographs using computer vision. NDT & e International, 37(4): 291-299.
- T.C. Millî Eğitim Bakanlığı, 2012, Uçaklarda Tahribatsız Muayene, Ankara, 81 s.
- Yasuda Y. D. V., Cappabianco F. A. M., Martins L. E. G., and Gripp J. A. B., 2022, Aircraft visual inspection: A systematic literature review, Computers in Industry, vol. 141, p.
- Wanhill R. J. H., Molent L., and Barter S. A., 2022, Milestone Case Histories in Aircraft Structural Integrity, Reference Module in Materials Science and Materials Engineering.



ÖZGEÇMİŞ

SONGÜL DEMİRTAŞ

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2020-2024	Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Antalya
Lisans	Kocaeli Üniversitesi
2007-2011	Fen Bilimleri Fakültesi, Elektronik ve Haberleşme Mühendisliği, Kocaeli

MESLEKİ VE İDARİ GÖREVLER

Proje Şefi	Türk Havacılık ve Uzay Sanayii A.Ş. , Antalya
2021-Devam Ediyor	Kıdemli Lider Mühendis
TTO & Proje Koordinatörü	Antalya Teknokent Yönetici ve İşletici A.Ş., Antalya
2015-2021	
Proje Mühendisi	Bizlife Danışmanlık Ltd. Şti., İstanbul
2014-2015	
Lider Proje Mühendisi	Hedef Ar-Ge Danışmanlık, Ankara
2012-2014	
Proje Mühendisi	PCS Endüstriyel Otomasyon Ltd. Şti., Ankara
2011-2012	