

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

JET UÇAKLARINDA TRANSFER ÖĞRENİMİ YÖNTEMİYLE HASARLI PARÇALARIN TESPİTİ

YÜKSEK LİSANS TEZİ

Safa ERDEM

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Gültekin ÇAĞIL

Eylül 2022

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

JET UÇAKLARINDA TRANSFER ÖĞRENİMİ YÖNTEMİYLE HASARLI PARÇALARIN TESPİTİ

YÜKSEK LİSANS TEZİ

Safa ERDEM

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez .../.../20... tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

Jüri Başkanı

Üye

Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Safa ERDEM

01.09.2022

TEŞEKKÜR

Yüksek lisans tez çalışmam boyunca her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Gültekin ÇAĞIL'a ve tez çalışması sürecinde bilgi ve tecrübelerini esirgemeyen sayın hocam Doç. Dr. Emrah AYDEMİR'e ve Prof. Dr. A.Kürşad TÜRKER'e teşekkürlerimi sunarım.

Yüksek lisans eğitimim süresince yanımda olan ve bu süreçte beni sürekli destekleyen, çalışmamı en iyi şekilde tamamlayabilmemi sağlayan başta ablam Dr. Merve ERDEM olmak üzere sevgili aileme teşekkür ediyorum.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	4
2.1. Havacılıkta Hasar Tespiti	4
2.1.1. Havacılıkta hasar tespitinde kullanılan yöntemler	4
2.1.2. Radyografik kontrol yöntemi	7
2.1.3. Radyografik kontrol yönteminin avantajları ve dezavantajları ..	10
2.2. Görüntü İşleme	10
2.2.1. Görüntü işleme teknikleri	12
2.3. Makine Öğrenmesi	14
2.3.1. Derin öğrenme	17
2.3.1.1. Yapay sinir ağları	19
2.3.1.2. Evrişimsel (Konvolüsyonel) sinir ağları	20
2.3.2. Transfer öğrenimi	22
2.3.2.1. Transfer öğreniminin sınıflandırılması	23
2.3.2.2. Derin öğrenmede transfer öğrenimi yaklaşımları	25

2.4. Literatürde Havacılık Malzemelerinde Hasar Tespiti Yapılması Amacıyla Görüntü İşleme Teknikleri Kullanan Bazı Çalışmalar	28
--	----

BÖLÜM 3.

MATERYAL VE YÖNTEM	34
3.1. Materyal	34
3.2. Yöntem	36
3.2.1. Veri setinin hazırlanması	36
3.2.2. Ön işleme	36
3.2.3. Verilerin model için seçimi ve çapraz doğrulama	36
3.2.4. Önceden eğitilmiş evrişimsel sinir ağlarından özellik çıkarma...	37
3.2.5. Sınıflandırma işlemi	39
3.2.6. Hata matrisi (confusion matrix) ve F-skoru	41

BÖLÜM 4.

ARAŞTIRMA BULGULARI	44
4.1. Uygulama Sonuçları	44
4.1.1. Eğitim modellerinin uygulama sonuçları	44
4.2. Uygulama Sonuçlarına Göre F-Skorlarının Hesaplanması	46
4.2.1. ResNet50 eğitim modeline göre oluşan yoğunluk haritaları	47

BÖLÜM 5.

TARTIŞMA VE SONUÇ	49
KAYNAKLAR	51
ÖZGEÇMİŞ	57

SİMGELER VE KISALTMALAR LİSTESİ

YSA	: Yapay sinir ağıları
ResNet	: Residual neural network
VGG	: Visual geometry group
DenseNet	: Dense convolutional network
GPU	: Graphics processing unit
JPEG	: Joint photographic experts group
mm	: Milimetre
AE-RTISNet	: Aeronautics engine radiographic testing inspection system net
Fast R-CNN	: Fast region-based convolutional neural network
YOLO	: You only look once

ŞEKİLLER LİSTESİ

Şekil 2.1. Radyografi kurulumunun temsili gösterimi	8
Şekil 2.2. Dijital görüntünün matematiksel gösterimi	11
Şekil 2.3. Genel bakışta görüntü işleme teknikleri	12
Şekil 2.4. Makine öğrenmesinin temelleri	16
Şekil 2.5. Yapay zeka, makine öğrenmesi ve derin öğrenme	16
Şekil 2.6. Derin öğrenme ve yaygın olarak kullanılan makine öğrenimi algoritmalarının geliştirilmesinin zaman çizelgesi	18
Şekil 2.7. Girdi, nöron, ağırlıklar, sapma (Bias), aktivasyon fonksiyonu, çıktı ilişkisi	19
Şekil 2.8. Üç giriş düğümü, iki gizli katman ve iki çıkış düğümü olan bir YSA ..	20
Şekil 2.9. Evrimsel sinir ağları yapısı ve karar süreci	21
Şekil 2.10. Transfer öğreniminin sınıflandırılmasındaki yaklaşımlar	23
Şekil 2.11. Önceden eğitilmiş ağlardan özellik çıkarımı yoluyla transfer öğreniminin yapılması	26
Şekil 2.12. Önceden eğitilmiş ağlarda ince ayar yoluyla transfer öğreniminin yapılması	26
Şekil 2.13. Öğrenme yöntemlerinde veri boyutuna karşı performans	28
Şekil 3.1. Bir parçaya ait hasarlı ve hasarsız görüntü verisi	34
Şekil 3.2. 10 katlı çapraz doğrulama veri seçimi	37
Şekil 3.3. AlexNet ve çekirdeklerin ağ yapısı	38
Şekil 3.4. VGG19 ağ modeli	39
Şekil 3.5. Öğrenme oranı seviyeleri	41
Şekil 3.6. Hata matrisi	41
Şekil 3.7. Hasarlı hasarsız veri tespiti ve eğitim modelinin seçim aşamaları	43
Şekil 4.1. Eğitim modelleri için hata matrislerinin toplam değerleri	46
Şekil 4.2. Hasarsız veri örneği ve yoğunluk haritası örneği	48

Şekil 4.3. Hasarlı veri örneği ve yoğunluk haritası örneği	48
--	----



TABLÖLER LİSTESİ

Tablo 2.1. Radyografik kontrol yönteminin diğer yöntemlere kıyasla avantaj ve dezavantajları	10
Tablo 2.2. Transfer öğrenme durumlarının farklı yaklaşımlarda kullanımı	25
Tablo 2.3. Hasar tespiti için askeri ve sivil uçaklardan alınan görüntülerle yapılan görüntü işleme ve/veya evrimsel sinir ağı tekniklerinin kullanıldığı çalışmalar	30
Tablo 4.1. Oluşturulan eğitim modellerinin başarı oranları	45
Tablo 4.2. Eğitim modeline göre F-skorları	47

ÖZET

Anahtar kelimeler: Görüntü işleme, derin öğrenme, evrişimsel sinir ağları, hasar tespiti, transfer öğrenim

Jet uçak parçalarının hasar tespitinde kullanılan en yaygın yöntemlerden biri, hasarsız bir muayene yöntemi olan X-ışını görüntülemesidir. Bu yöntemde X-ışını radyografileri kullanılarak uzmanlaşmış personel tarafından yapılan analizler sonucu hasarlar belirlenir. Hasarın tespiti uçuş emniyeti için büyük önem arz etmekte olup hasar incelemesinin çok dikkatli yapılması gerekmektedir. Bu hasar tespit yöntemlerinin otomasyona çevrilebilmesi hem analiz hassasiyetinin artırılması hem de insan kaynaklı yöntemlere olan bağımlılığın azaltılması açısından kurumlara teknik yenilikler ve kolaylık getirecektir. Bu nedenlerle hasar tespitinin görüntü işleme algoritmaları ve yapay zeka elemanları kullanılarak yapılabilmesi amacıyla, bu tez çalışması kapsamında X-ışını görüntüleri üzerinden askeri uçak parçalarında oluşan çatlak hasarları analiz edilmiştir. Bu analizlerde yapay zeka elemanlarından derin öğrenme metotları kullanılarak eğitilen algoritmalar kullanılmıştır. Eldeki 100 radyografi görüntüsünden (50 adet çatlak içeren ve 50 adet çatlak içermeyen görüntü) 90 tanesi eğitim veri seti, 10 tanesi test veri seti için kullanılmıştır. Evrişimsel sinir ağları yardımıyla önceden eğitilmiş ResNet50, AlexNet, VGG19 ve DenseNet169 ağlarından transfer öğrenimi yapılarak eldeki verilerde (görüntülerde) çatlak tespiti yapılmıştır. Bu ağ modellerindeki f-skoru oranları sırasıyla %78,85, %66,67, %73,68 ve %77,48'dir. Görüntülerde tespit edilmesi istenen hasarları en yüksek başarı oranıyla analiz eden ResNet50 evrişimsel sinir ağı modelinin karar sürecinde ağırlık verdiği pikselleri gösteren yoğunluk haritaları da gösterilmiştir. Sonuç olarak kullanılan metodolojinin radyografiler üzerinde yapılan hasar tespitinde doğruluk oranı yüksek bir şekilde sonuç verebileceği görülmüştür. Bu tez çalışmasında yapılmış olan otomatik hasar analizi yöntemiyle verinin kısıtlı olabileceği bir durumda da küçük veri setiyle transfer öğrenimi kullanılarak hasar tespitinin yapılmasına yardımcı olan bir model geliştirilmiştir.

DETECTION OF DAMAGED PARTS VIA TRANSFER LEARNING METHOD IN JET AIRCRAFTS

SUMMARY

Keywords: Image processing, deep learning, convolutional neural networks, defect detection, transfer learning

One of the most common methods used for defect detection of jet aircraft parts is X-ray imaging, which is a non-destructive inspection method. In this method, defects are identified in the analyses of X-ray radiographs made by specialized personnel. Defect detection is of great importance for flight safety and therefore damage inspection must be done very carefully. Transition of these defect detection methods into automated systems will bring technical innovations and convenience to the institutions, in terms of both increasing the sensitivity of analysis and reducing the dependence on human-sourced methods. For these reasons, in order to detect the defect using image processing algorithms and artificial intelligence elements, crack defects in military aircraft parts were analyzed on X-ray images within the scope of this thesis. In these analyses, algorithms trained by using deep learning methods from artificial intelligence elements were used. Within the available 100 radiography images (50 images with cracks and 50 images without cracks), 90 were used for the training dataset and 10 for the test dataset. With the help of convolutional neural networks, transfer learning was performed from pre-trained ResNet50, AlexNet, VGG19 and DenseNet169 networks, and crack detection was performed in the available data (images). The F-scores in these network models are 78,85%, 66,67%, 73,68% and 77,48%, respectively. Heat maps are also shown, in which ResNet50 convolutional neural network model, which analyzes the defects need to be detected in the images with the highest F-score, concentrates in its decision process. As a result, it is observed that the methodology can give results with a high rate of accuracy in the defect detection of radiographs. With the automated defect analysis application carried out in this thesis, a model was developed that helps to determine the defects by using transfer learning with a small data set in a case where data may be limited.

BÖLÜM 1. GİRİŞ

Uçakların periyodik bakımlarında uçuş emniyeti için gereken kontrollerin yapılması gereklidir. Yapılan kontrollerin en önemli adımlarından biri uçakların parçalarında oluşan hasarların tespit edilmesidir. Hasar tespitinde ise tahribatsız muayene yöntemlerinden radyografik muayene en çok kullanılan yöntemlerden biridir. Jet uçaklarındaki hasar tespiti de benzer şekilde radyografik muayene ile yapılmaktadır.

Radyografik muayenede kontrol edilecek parçalara kısa dalga boylu yüksek enerjiye sahip elektromanyetik dalgalar gönderilerek radyografik film üzerine bir görüntü kaydedilmektedir. Kontrol edilecek parçaya ışınlarla gönderilen radyasyon, malzemenin içindeki boşluklar, yoğunluk veya kalınlık farklılıklarından kaynaklı olarak farklı miktarda soğurulacaktır. Bunun sonucunda radyografik film görüntüsü ortaya çıkmaktadır. Oluşan görüntüler ile incelenen parça üzerindeki hasarların kalıcı olarak film üzerinde görülmesi sağlanacaktır. Görüntüler üzerinden de hasar ve çatlak durumları kontrol edilmektedir (Anık ve ark., 2000).

Görüntü işleme, bilgisayarların görüntüler üzerinde çeşitli işlemler yaparak tanımlamasını, anlamlandırılmasını ve yorumlanmasını sağlamaya yönelik bir bilgisayar bilimi alanıdır. Yapay zekâ türlerinin diğerleri gibi görüntü işleme de insan yeteneklerini kopyalayarak kendinden istenen görevleri gerçekleştirmeyi ve bu görevleri otomatik olarak yapmayı amaçlar. Görüntü işleme hem insanlar gibi görme hem de gördüğü görüntüleri yorumlama ve anlama tarafını taklit etmeye çalışmaktadır. Görüntü işleme uygulamaları, insanın görme sistemini taklit etmek için algılama cihazları, yapay zekâ, makine öğrenimi ve derin öğrenmeden gelen verileri işlemektedir. Kullanılan görüntü işleme uygulamaları çok sayıdaki görüntüler üzerinde eğitilmiş olan algoritmalarda çalışmaktadır. Radyografik film görüntülerini de makinalara tanıtarak yapay zekâ algoritmalarını eğitmek mümkündür. Derin

öğrenme metotlarıyla eğitilen algoritmalar radyografik filmleri inceleyerek istenilen sonuca yönelik tespitleri yapacaktır.

Derin öğrenme bir veya birden fazla katman içeren yapay sinir ağları ve buna benzer makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Yapılan çalışmalar sonucunda ulaşılan başarılı yapay zekâ uygulamaları insan hayatında daha fazla yer bulmaktadır. Güncel olarak yüz tanıma, ses tanıma, görüntü sınıflandırma, sağlık sektörü, savunma sanayi gibi pek çok farklı alandaki çalışmalar derin öğrenme metodu olan evrimsel sinir ağları (konvolüsyonel sinir ağları) kullanılarak geliştirilmektedir. Derin öğrenme algoritmalarının kusursuz işleyişi günümüzde insan ile yarışmakta ve algoritma kabiliyetleri insanı pek çok alanda geçmektedir. Fakat yüksek oranda doğruluk isteyen yapay zekâ sinir ağlarının eğitimi oldukça güçtür. Günümüzde ülkeler, akademisyenler, özel şirketler bu alanda yarışmaktadır.

Yapay sinir ağı eğitimlerinde çok fazla veri gerektiğinden istatistiksel modellere dayanan diğer makine öğrenim modellerinden bu yönüyle ayrılmaktadır. Mükemmel çalışacak bir ağı ihtiyaç varsa çok sayıda verinin eğitilmesi gerekmektedir fakat çoğu zaman bu kadar fazla veriye sahip olmak zor, zaman alıcı ve maliyetlidir. Elde olan veri sayısı çok olduğu durumlarda bile algoritmanın doğruluğu için yapılacak deneyler yıllar sürebilir. Evrimsel sinir ağlarını kullanarak transfer öğrenimi yöntemini uyguladığımızda süreç kısaltılarak istenilen sonuca ulaşılmaktadır.

Transfer öğrenimi sayesinde uzun yıllarca eğitilen AlexNet, VGG, ResNet50, ResNeXt, DenseNet, Darknet gibi evrimsel sinir ağlarını sınıflandırıcı modellerin çıkışındaki katman değiştirilerek özelleştirilmiş ağlar oluşturulabilmektedir. Bu sayede algorithmadan istenen doğruluk yakalanacak, eğitim süresi ise kısılacaktır.

Görüntü işleme uygulamalarının ilk kullanıldığı yıllarda verileri analiz etmek için istatistiksel yöntemler kullanılıyordu. Günümüzde ise daha çok derin öğrenme olarak bilinen yöntemle yaklaşılmaktadır.

Bu alıřmada ama grsel ğrenme ile uuř emniyeti iin ok nemli olan jet uaklarının paralarında oluřabilecek hasar tespiti iin yapay sinir ağılarıyla transfer ğrenimi yapılarak incelenen paralardaki hasarların bilgisayar tarafından yorumlanmasını saėlamak ve bylelikle paralarda oluřan atlak hasarlarının gzden kamasını engellemektir.



BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Havacılıkta Hasar Tespiti

Teknolojinin gelişmesiyle birlikte yüksek katma değerli alanlar arasında yerini alan havacılık sektörü hem sivil hava taşımacılığı hem de askeri alanlarda 20. yüzyılda gelişmiş ve bu yüzyılda da gelişmeye devam etmektedir. Güvenliğin ön planda tutulduğu bu sektör, kullanılan parçaların ve onların yapıldığı malzemelerin yüksek düzeyde kontrol altında tutulması gerekliliğini de beraberinde getirir.

Uçaklar genel olarak beş ana önemli parçadan oluşur. Bunlar, gövde, kanatlar, kuyruk, uçuş kumanda yüzeyleri ve iniş takımlarıdır. Uçakların uçuş sırasında basınç artışı ve azalışı dolayısıyla maruz kaldıkları stresten ötürü uçak parçalarının üzerinde hasar oluşabilir. Örneğin ilk başta küçük boyutta oluşan çatlaklar daha sonraki uçuşlarda artan stresle birlikte giderek büyüyebilir. Bu tarz hasarlar erken tespit edilemeyip ilerlediğinde uçaklarda yapısal bozulmalarla veya hasarlarla sonuçlanabilir. Bu nedenle uçakların hem güvenli uçuş yapabilmesi hem de uzun dönemde verimli kullanılabilirliğinin devamı için hatasız ya da en düşük hata seviyesinde ve güvenilir sonuç veren muayene yöntemlerinin kullanılması havacılık sektörü için son derece önemlidir. Bu muayenelerin önemi özellikle uçakların yaşı arttıkça daha da önem kazanır (Korkmaz, 2010).

2.1.1. Havacılıkta hasar tespitinde kullanılan yöntemler

Havacılık sektöründe uçak bakım faaliyetleri ister sivil havacılık isterse askeri havacılık olsun uçuş güvenliği açısından vazgeçilmez bir yere sahiptir. Uçakların bakımının yapılması ve olası hasarların tespiti periyodik olarak yapılan kontrollerle mümkündür. Bu kontrollerde malzemelerin incelenmesi ve olası kusurların

belirlenebilmesi için çeşitli yöntemler kullanılır. Bu yöntemler başlıca tahribatlı ve tahribatsız muayene yöntemleri olarak sınıflandırılabilir. Muayene yöntemleri malzemelerin zaman içerisinde bakımları ve hasar tespitlerinde kullanılmakla birlikte üretim sırasındaki kalite kontrol aşamasında da kullanılabildiğinden geniş bir uygulama alanına sahiptir. Tahribatlı muayene yöntemleri malzemelerin parçalanarak malzemenin yapısını ve dayanıklılık, sertlik ve esneklik gibi özelliklerini anlamaya yardımcı olan tekniklerdir. Bu tarz muayene yöntemleri genellikle tahribatsız muayenelere göre uygulaması daha kolay, daha fazla bilgi veren ve sonuçlarını yorumlaması daha kolay olan yöntemlerdir.

Sivil ve askeri havacılık alanında da kullanılan tahribatlı muayene yöntemleri güvenlik testleri açısından vazgeçilmezdir. Fakat bu yöntemler malzemelerin parçalanması zorunluluğunu gerektirdiğinden, kullarımdaki uçakların uzun dönemli periyodik bakım ve onarımının bir parçası olarak uygulanamamaktadır. Bu tarz bakım faaliyetlerinde tahribatsız muayene yöntemleri kullanılır. Bu muayene yöntemleri hem uçak bakımında hasar tespitinin yapılmasında hem de üretim alanında ürünlerin kalite kontrolünü yapmak ve güvenilirliğini teyit etmek için malzemelerde kalıcı bir etki bırakmadan kullanılabildiğinden havacılıkta önemli bir yer tutmaktadır (Onursal, 2010, Doğru, 2014).

Havacılıkta kullanılan başlıca tahribatsız muayene yöntemleri şöyle sıralanabilir: Görsel muayene, girdap akımları tekniğı, sıvı penetrant testi, ultrasonik muayene, manyetik parçacık kontrolü ve radyografik kontroldür.

Görsel muayene tahribatsız muayene yöntemleri arasında en geniş perspektifte kullanılan yöntemdir. Ekonomik olmasının yanı sıra muayene işlemlerinde ilk sırada yer alır. Görülebilir spektrumdaki ışık kullanılarak yapılan bu muayenelerde aydınlatılan parçalar çıplak gözle veya optik bir cihaz (optik mikroskop, boroskop gibi) yardımıyla analiz edilir. Bu analizlerde yüzeyin durumu, yüzeydeki bozukluklar ve süreksizlikler incelenir (Matzkanin, 2006) (Süreksizlik; malzemedeki yapısal bütünlüğün bozulması olarak tanımlanır ve çatlak, gözenekleşme, homojensizlik

oluşumu, dövme katlanmaları, dikişler, yabancı madde kalıntıları gibi durumları içerir).

Girdap akımları tekniği iletken maddelerde yüzey ya da yüzeye yakın hasarları tespit etmek için kullanılan temas gerektirmeyen bir tahribatsız muayene yöntemidir. Bu yöntemde elektromanyetik indüksiyon yardımıyla elde edilen girdap akımlarından faydalanılır. Bir bobinde alternatif akım yardımıyla oluşturulan manyetik alan, iletken malzeme üzerinde girdap akımlarını tetikler. Girdap akımlarını oluşturduğu ikincil manyetik alan bobin üzerindeki manyetik alana ters yönde olduğundan oradaki manyetik alanı azaltır, akımı artırır ve empedans değişikliğine neden olur. Malzemenin iletkenliği, süreksizlikler, korozyon ve malzeme kalınlığındaki değişimler girdap akımlarını da değiştireceğinden bu ölçümler hasarın tespit edilmesinde kullanılabilir (García-Martín ve ark., 2011).

Sıvı penetrant (sıvı girinim) testi özel sıvı kimyasallar kullanılarak gözeneksiz malzemelerin yüzeydeki hasarların belirlenmesidir. Bu yöntemin uygulanabilmesi için yüzeyin her türlü kirden ve yabancı maddelerden arındırılmış olması gerekir. Bu yöntemin temel prensibi yüzey gerilimiyle oluşan kapiler etkiyle birlikte sıvının yüzeydeki hasarlı bölgelere nüfuz etmesine dayanır. Bu sıvılar genellikle gözle görülebilir ve parlak ya da morötesi ışık altında görülebilen floresan maddelerdir. Bu sayede hasarlı bölgeye ulaşan sıvılar kontrast oluşturarak bu bölgeyi görünür hale getirir. İşlem sırasında fazla olan sıvı bölgeden temizlenerek geliştirici sıvı eklenir ve hasarlı bölge daha net bir şekilde görünür hale getirilir (Caturano ve ark, 2009).

Ultrasonik muayene, ultrasonik ses dalgaları kullanılarak gerçekleştirilen ve sadece havacılık değil boru hatlarının kontrolünden demiryolları sektörüne kadar geniş uygulama alanlarına sahip bir muayene yöntemidir. Bu yöntem ses dalgalarının malzeme içerisine gönderilmesi ve malzeme boyunca hareket etmesi prensibine dayanır. Ultrasonik muayene cihazının probundan çıkan yüksek frekanslı ses dalgaları malzeme içinde yayılarak arka yüzeyden geri döner. Malzemede bir süreksizlik ya da çatlak olduğunda ise bu ses dalgaları geri döner ve bu gözlenen yankıların konumları ve genlikleri malzemedeki hasar hakkında bilgi verir (Lu ve

Wong, 2017). Bu sayede bu yöntem havacılıkta hem malzeme kontrolünde hem de bakım/onarım programlarında kullanılır.

Bir diğer tahribatsız muayene yöntemi olan manyetik parçacık kontrol yöntemi, yüksek mıknatıslanma özelliğine sahip malzemelerin yüzey veya yüzeye yakın bölgelerinde hasar tespiti yapmasına olanak sağlar. Akım geçirilerek oluşturulan manyetik alan malzemeler üzerinde manyetik akım meydana getirir. Bu şekilde mıknatıslanan parçalarda hasarın olduğu bölgelerde iletkenlik azalacağından manyetik alan çizgilerinin akışı sapar. Mıknatıslanan parçaların üzerine serpilen manyetik parçacıklar (demir tozları) hasarlı bölgelerde toplanır ve hasarın görülmesini sağlayacak bir desen oluşturmuş olur. Bu desenlerin belirginliği de hasarın olduğu derinliğe göre değişkenlik gösterir (Federal Aviation Administration, 2018).


Tüm malzeme tiplerine uygulanabilirliği olan tek yöntem olan radyografik kontrol, malzemelerin iç kısmının durumunu ve hasarlarını göstermeye odaklanır. Bu tezde işlenen materyal olarak radyografik kontrolde elde edilen fotoğraflar kullanıldığından, tahribatsız muayene yöntemlerinden radyografik kontrol bir sonraki bölümde daha ayrıntılı olarak anlatılacaktır.

2.1.2. Radyografik kontrol yöntemi

Radyografik muayene yöntemi temel prensip olarak yüksek enerjili ve kısa dalga boyuna sahip elektromanyetik dalgaların malzemelerin içine nüfuz etme özelliğine dayanır. X-ışınları ve gama ışınlarının bu özelliklerinden dolayı metalik ve metalik olmayan maddelere uygulanabilirliği, bu yöntemi hasar tespitinde vazgeçilmez bir konuma getirmiştir. Elektromanyetik spektrumun görece kısa dalga boyuna sahip ve yüksek enerji taşıyan ışınları olan X-ışınları ve gama ışınları, malzeme tipi fark etmeksizin maddeler içinde yüksek girişim gösterme özelliğine sahiptir. Elektromanyetik ışınların dalga boyu kısaldıkça enerjisi ve girişim özelliği artar. Bu nedenle dalga boyları X-ışınlarına göre daha kısa olan gama ışınlarının girişim özellikleri daha yüksektir. Her iki tür de farklı alanlardaki endüstriyel muayenelerde malzeme kontrolü ve bakım/onarım gibi alanlarda kullanılır. Örneğin kaynak, döküm

parçaları veya kompozit maddelerde, uçak parçalarında, borular ve buhar kazanları gibi birçok endüstriyel üründe kullanılabilir. Havacılık sektöründe yapılan muayene işlemlerinde ise gama ışınları kullanılmamaktadır. Güvenlik ve ekonomik nedenlerden dolayı X-ışını temelli muayene tercih edilmektedir.

Endüstriyel radyografide sistem kurulumu iki ana elemandan oluşur, bunlar nüfuz ediciler ve algılayıcılar olarak adlandırılır. Nüfuz ediciler sistemin temel prensibini oluşturan X veya gama ışınlarıdır, algılayıcılar ise sonucu görmemizi sağlayan detektörlerdir (film ortamı ya da dijital detektör gibi). Bir radyografi sisteminde incelenecek malzemenin bir tarafına ışıma kaynağı, diğer tarafına da detektör yerleştirilmelidir (Şekil 2.1.). Işıma kaynağı olarak X-ışınları tercih edilecekse, elektrik kaynağı kullanan X-ışını tüpleri kullanılabilir. Bu tüplerde anot kolun ucundaki tungsten, katot uçtan gelen elektronları aşağı doğru yönlendirir ve buradaki çarpışma ile yüksek ısı ve X-ışınları meydana gelir. Ortaya çıkan ısı yağ veya su gibi soğutmalı sistemler ile soğutulur. Radyografi sisteminde ışın olarak gama ışınları kullanılacaksa bunlar radyoaktif elementlerin bozunmasıyla elde edilebilir. Bu elementlerin yarılanma ömürleri süresince yaptıkları bozunmalarla muayene işlemleri yapılmaktadır. Ancak dikkat edilmelidir ki, bu kaynakların kullanılması ve saklanması yüksek derecede güvenlik tedbirleri ve özen gerektirmektedir.



Şekil 2.1. Radyografi kurulumunun temsili gösterimi (Lu ve Wong, 2017).

Şekil 2.1.'de şematik olarak gösterilen bir radyografi kurulumunda olduğu gibi bir ışıma kaynağından gelen ışınlar malzemeye çarpar, ışınlar malzeme içerisine nüfuz eder ve malzemenin özelliklerine (kalınlık, yoğunluk) bağlı olarak bu ışınların bir kısmı malzeme tarafında emilir. Malzeme içerisinden geçip diğer taraftaki detektöre ulaşan ışınlar ise buradaki ortam (film ya da dijital detektör) üzerinde bir desen oluşturur ve bu desen bir görüntü olarak kaydedilir. İşlemden geçirilen film üzerine ya da dijital ortamda kaydedilen görüntüler, X-ışınları kullanılarak yapılan ölçüm sonrası oluşturulduysa X-ışını grafi, gama ışınları kullanılarak oluşturulduysa gamagrafi adı verilir. Bu görüntüler genel olarak da radyografi olarak adlandırılır.

Radyografik muayene sonucu elde edilen radyografik görüntüler kullanılarak malzemelerdeki boşluk ve kalıntılar da dahil olmak üzere hasar tespiti yapılabilir. Çatlak veya yırtıklar bu görüntülerde iki boyutlu bir görsel oluştururken, boşluk alanlar ise üç boyutlu yuvarlak görünümü verir. Diğer hatalar (gözeneklenme ve kısalma gibi) ise bu iki görüntünün arasında bir görüntü verecektir. Örneğin X-ışınları kullanılarak yapılan bir muayene sonucunda elde edilen film görüntüsünde, daha çok ışık alan bölgeler daha çok kararır (bu kararmaya yoğunluk da denir). Bu görüntülerde farklı yoğunluklarda bölgeler olması numunedeki malzemede farklı yapılar olduğunu gösterir. Hasarlı bölgelerde de malzemenin sürekliliği değişeceğinden geçirdiği ışın miktarı da değişecek ve böylelikle hasarlı bölge oluşan görüntüde belirecektir. Optimum görüntü için kayma olmamalı ve netlik yüksek olmalıdır. Özellikle malzemenin kenar alanlarındaki görüntü keskin olmalı ve görüntü genelinde kontrast yüksek olmalıdır. Optimum kalitede görüntü alabilmek için malzemenin pozlanması kritik önem taşımaktadır. Bunun sağlanabilmesi için numunenin aldığı ışık miktarı, malzeme boyunca ışınların nüfuz etmesi için yeterli seviyede olmalı ve aynı zamanda en az maruz kalmayla pozlanma işlemi tamamlanmalıdır. Görüntülerin büyüklükleri ve netlikleri, ölçüm kriterleri olan ışıma kaynağının odak büyüklüğüne, ışıma kaynağının filme olan uzaklığına ve malzemenin filme olan uzaklığına bağlıdır. Bu kriterler çerçevesinde istenilen görüntünün elde edilmesine yönelik olarak, malzeme kalınlığına bağlı seçilmesi gereken X-ışını voltaj miktarı veya radyoizotop kaynağı önerileri belli kurumlarca belirlenmiştir.

Bu bölümdeki bilgiler Onursal (2010), Uçak bakım (2012), Lu ve Wong (2017) ve Federal Aviation Administration 2018 AMT Handbook (2018) kaynaklarından derlenerek yazılmıştır.

2.1.3. Radyografik kontrol yönteminin avantajları ve dezavantajları

Sistemin avantajları ve dezavantajları aşağıdaki Tablo 2.1.'de özetlenmiştir (Shull, 2002, Lu ve Wong, 2017).

Tablo 2.1. Radyografik kontrol yönteminin diğer yöntemlere kıyasla avantaj ve dezavantajları

Avantajlar	- Kalıcı görüntü elde edilmesi (film ya da dijital olarak) - Geriye dönük sonuç karşılaştırması yapılabilmesi - Tüm malzeme tiplerine uygulanabilmesi - Malzemenin içi hakkında bilgi vermesi - Malzemenin özellikleri (kalınlık, yoğunluk) hakkında bilgi vermesi - X-ışınlarının ince parçalar için uygun olması
Dezavantajlar	- İnsan sağlığı ve çevre açısından riskli olması - Yabancı maddeler sonuca müdahale edebilmesi - Uygulanabilirliğinin kolay olmaması (Çevre şartlarının kontrolü gerekliliği, sistemlerin kurulumunun zaman alması ve zahmetli olması, yüksek düzeyde özen ve emniyet şartlarının sağlanması ve devam ettirilmesi gerekliliği) - Tecrübeli eleman gerekliliği - Yüzeyin altındaki hatanın derinliği hakkında bilgi vermemesi - Diğer yöntemlere göre daha pahalı olması

2.2. Görüntü İşleme

Görüntü işleme, bir bilgisayarda algoritmalar ve kodlar kullanılarak görüntülerin otomatik olarak işlenmesi, analizi ve bunların sonucunda yorumlanması olarak tanımlanabilir. Günümüzde televizyon, fotoğrafçılık, robotik, uzaktan algılama, tıbbi

teşhis ve endüstriyel muayene gibi bilim ve teknolojideki birçok disiplin ve alanda görüntü işleme uygulamaları kullanılmaktadır. (Dey, 2018).

Görüntü siyah beyaz veya renkli olabilir. Siyah beyaz bir görüntü, x ve y 'nin uzaysal koordinatlar olduğu ve (x,y) 'deki f değerinin o noktada olan parlaklığı ile orantılı olduğu $f(x,y)$ iki boyutlu ışık fonksiyonudur. Renkli görüntü, $f(x,y)$, her bileşenine karşılık gelen spektral bantta olan noktanın $f(x,y)$ parlaklığını gösteren bir vektördür. Dijital bir görüntü ise, hem uzaysal koordinatlarda hem de parlaklıkta ayrıklaştırılmış bir $f(x,y)$ görüntüsüdür. Bir iki boyutlu tamsayı dizisi veya her bir renk bandı için bir tane olmak üzere bir dizi iki boyutlu dizi ile temsil edilir. Sayısallaştırılmış parlaklık değerine gri seviye denilmektedir. Dizinin her bir elemanı, resim elemanı teriminden türetilen piksel olarak adlandırılır. Genellikle bir dizinin boyutu birkaç yüz piksele birkaç yüz pikseldir. Dijital bir görüntü $0 \leq f(x,y) \leq G-1$ aralığında Şekil 2.2.'deki gibi görünür ve burada genellikle N ve G , 2'nin pozitif tamsayı kuvvetleri ($N=2^n$, $G=2^G$) olarak ifade edilir (Petrou ve Petrou, 2010).

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


Şekil 2.2. Dijital görüntünün matematiksel gösterimi (Petrou ve Petrou, 2010).

Piksel değerlerinde gri seviyeli görüntüler 256 farklı değer almaktadır. Piksellerin aldığı bu değerlerden 0 değeri siyahı, 255 değeri beyazı ifade etmektedir. Gri seviyeli görüntülerde diğer değerler bu aralıkta yer almaktadır ve grinin tonlarında bir görüntü oluşmaktadır (Johnson, 2006).

Görüntü eşikleme yöntemi kullanılarak gri seviyeli görüntülerden ikili (binary) görüntüler elde edilmektedir. Elde edilen ikili görüntüler görüntü işleme uygulamalarında kullanılmaktadır.

2.2.1. Görüntü işleme teknikleri

Görüntüler üzerinde yapılabilen her türlü işlem görüntü işleme sınıfında düşünülebilir. Görüntü işlemenin mantığı, görüntünün yapısal özelliklerinin değiştirilmesi ve geliştirilmesiyle birlikte görüntülerin analiz edilmesi ve makine öğrenmesi gibi uygulamalarda kullanılmak üzere uygun hale getirilmesidir. Görüntü işleme tekniklerini gösteren bir şema Şekil 2.3.'te verilmiştir.



Şekil 2.3. Genel bakışta görüntü işleme teknikleri (Güngörmüş, 2020).

Görüntü işleme dizininde temel olarak kullanılan adımlar şöyle sıralanabilir: Görüntünün elde edilmesi, görüntü iyileştirilmesi, görüntü onarma, morfolojik işlemler, segmentasyon (bölütleme), tanıma ve şablon eşleştirme.

Görüntünün elde edilmesi ve sayısallaştırılması: Kamera, fotoğraf makinesi, kameralı telefonlar, tarayıcı ya da spesifik görüntüleme cihazları yoluyla üç boyutlu nesnelerin iki boyut üzerinde analog görüntüleri elde edilir. Bu görüntülerin bilgisayar ortamında kullanılabilmesi için sayısallaştırılması gerekir. Bir önceki bölümde de bahsedildiği gibi analog görüntüler fonksiyonlardan oluşur ve bu fonksiyonlar kullanılarak oluşturulan matrislerle sayısal görüntü elde edilir (Sevgi, 2020).

Görüntü iyileştirilmesi: Görüntüleri mevcut durumundan daha iyi duruma getirmek için uygulanan işlemlerdir. Görüntünün kontrast ve parlaklık ayarlarıyla oynanması ya da histogram eşitlemenin yanı sıra görüntülerdeki gürültüyü gidermek için kullanılan filtreler (ortalama, medyan filtreleme gibi) de görüntü iyileştirilmesinde kullanılır (Çan, 2021).

Görüntü onarma: Bozulan görüntülerin onarılması ya da görüntülerdeki gürültünün giderilmesi demektir. Bu amaçla görüntü üzerinde filtreler kullanılarak görüntü kalitesi arttırılmaya çalışılır (Çan, 2021).

Morfolojik işlemler: Görüntülerdeki şekillerin biçimsel yapısıyla ilgilenen ve genişletme (dilation) ve aşındırma (erosion) denen iki temel işlem kullanılarak yapılan işlemlerdir. Bu temel işlemler kullanılarak yapılan açma ve kapama işlemleriyle nesneler ve onlar arasındaki boşluklarla ilgili işlemler gerçekleştirilir (Atalı ve ark., 2016).

Segmentasyon (bölütleme): Bir görüntüyü parçalarına ve nesnelere bölme işlemi olarak tanımlanır. İleri seviye işlem grubuna giren bu işlemlerle nesnelerin kenarları, çizgiler ve bölgeler belirlenerek nesnelerin arka plandan ve birbirlerinden ayrılması sağlanır. Böylelikle arka plandan ve birbirinden ayrılmış olan bölgelerin ve nesnelerin, yapay zekâ algoritmaları gibi karar verme mekanizmaları tarafından etiketlenmesi ve sınıflandırılması mümkün hale gelir (Sivakumar ve Meenakshi, 2016).

Tanıma (Recognition): Görüntü içinde olan bir nesneyi (araç, yüz, parmak izi gibi) belirlemek için yapılan işlemleri kapsar. Görüntülerdeki desen tanıma işlemleri karar teorik ve yapısal olmak üzere iki ana yöntemle yapılır. Karar teorik tanımda nicelik özellikleri kullanırken (uzunluk, alan gibi) yapısal yöntemde ise niteliksel tanımlayıcılardan yararlanılır (Gonzalez ve Woods, 2006).

Şablon eşleştirme: Bir görüntü içerisindeki alt görüntünün (şablon) eşleştiği bölgeleri arattırarak karşılaştırılmasını sağlamaktır (Şahin, 2021).

Görüntü işlemeyle, bilgisayarın görüntü veya videodaki nesneleri ve kişileri tanımlaması mümkündür. Fakat tespit edilen öğelerin istenilen detayda sınıflandırması yapılamayabilir. Bu ayrımın yapılabilmesi için çeşitli yapay zeka teknikleri kullanılmaktadır. Nesne bulma ve sınıflandırma çalışmalarında yapay zeka tekniklerinden evrimsel sinir ağları yaygın olarak kullanılmaktadır.

2.3. Makine Öğrenmesi

Makine öğrenmesi, bir görevi bir dizi örnekten öğrenen mantıksal veya ikili işlemlere dayalı otomatik hesaplama yöntemleridir. Karar verme sürecinde insanın öğrenme şekillerini çevreden öğrenerek insan zekasını yeterince taklit etmek için tasarlanmışlardır. Makine öğrenmesi gelişen algoritmalar, insan müdahalesi olmadan istatistiksel yaklaşımlar gibi arka plan bilgilerini kendilerini geliştirmede kullanılmaktadırlar (Michie ve ark., 1994). Yapay zekanın bir alt çalışma alanı olarak makine öğrenmesi, modelleri sürekli olarak optimize etmek ve algoritmaların rehberliğinde makul tahminler yapmak için büyük miktarda veri kullanır (Wu ve Sun, 2018).

Makine öğrenmesi, verileri kullanarak gerçek sorunları çözen modeller oluşturmak için kullanılacak birden çok algoritma, teknik ve metodolojiye sahiptir. Makine öğrenimi yöntemleri birden çok şekilde sınıflandırılabilir. Bu yöntemlerin başlıca alanlarından bazıları aşağıdadır (Sarkar ve ark, 2018).

Öğrenme sürecinde insan denetiminin miktarına dayalı yöntemler:

- Denetimli öğrenme
- Denetimsiz öğrenme
- Yarı denetimli öğrenme
- Pekiştirmeli öğrenme

Artımlı veri örneklerinden öğrenme yeteneğine dayalı yöntemler:

- Toplu öğrenme
- Çevrimiçi öğrenme

Veri örneklerinden genelleme yapma yaklaşımlarına dayalı yöntemler:

- Örnek tabanlı öğrenme
- Model tabanlı öğrenme

Bilgisayarların verilere dayalı tahminler veya davranışlar yaparak bunları geliştirmek için kullandığı bir dizi yöntem makine öğrenmesinin adımlarını oluşturmaktadır. Makine öğrenimi algoritması, parametreleri (ağırlıklar gibi) veya öğrenme yapılarını (ağaçlar gibi) tahmin ederek bir modeli öğrenir. Algoritma, minimize edilmiş bir skor veya kayıp fonksiyonu tarafından yönlendirilir. Tam olarak eğitilmiş bir makine öğrenimi modeli daha sonra yeni örneklerde tahminler yapmak için kullanılabilir. Tüm bu verilerin ortak noktası, makine öğrenimi ile çözülebilecek olmalarıdır. Görevler farklıdır, ancak algoritmalarındaki yaklaşım aynıdır. Makine öğrenme adımları şöyle sıralanır:


Adım 1: Veri toplama. Ne kadar çok veri varsa algoritma o kadar iyi sonuç verecektir. Veriler tahmin etmek istediğiniz sonucu ve tahminde bulunacağınız ek bilgileri içermelidir.

Adım 2: Verilerin kümelenmesi. Hazırlanan veriler, eğitim kümesi ve test kümesi olmak üzere iki gruba ayrılmalıdır. Veriler, makine öğrenmesi modellerinin en yüksek doğruluğa ulaşmasını sağlamaktadır.

Adım 3: Modelin yeni verilerle kullanılması. Seçilen modelin performansının ve doğruluğunun değerlendirilmesi için test kümesi kullanılmaktadır (Molnar, 2020).


Adım 4: Sonuçları yorumlanması ve incelenmesi.

Makine öğreniminin temel yönlerini, anlamları ve ilişkili olduğu organizasyon yapısının geniş hali Şekil 2.4.'te gösterilmektedir.



Şekil 2.4. Makine öğrenmesinin temelleri (Gollapudi, 2016).

Şekil 2.5.'te gösterildiği gibi makine öğrenmesi, derin öğrenme ve sinir ağları, yapay zekanın alt çalışma alanlarıdır. Derin öğrenme de makine öğrenmesinin alt alanıdır ve sinir ağları da derin öğrenmenin alt alanıdır.




Şekil 2.5. Yapay zeka, makine öğrenmesi ve derin öğrenme (Chollet, 2017).

2.3.1. Derin öğrenme

Derin öğrenmedeki derinlik, yaklaşımla elde edilen herhangi bir derin anlayışı değildir. Daha çok bu ardışık temsil katmanları fikrini temsil etmektedir. Bir veri modeline kaç katmanın katkıda bulunduğuna modelin derinliği denilmektedir. Modern derin öğrenme genellikle onlarca hatta yüzlerce ardışık temsil katmanını içerir ve bunların tümü eğitim verilerine maruz bırakılarak otomatik olarak öğrenilir. Derin öğrenmede, bu katmanlı temsiller (neredeyse her zaman) birbirinin üzerine yığılmış gerçek katmanlarda yapılandırılmış, sinir ağları adı verilen modeller aracılığıyla öğrenmektedir (Chollet, 2017). Ardışık katmanlarda, bir katmandan çıkan veri bir sonraki katmanda girdi olarak kullanılmaktadır (Deng ve Yu 2014).

Başka bir ifadeyle derin öğrenme, yeni ve hızla büyüyen bir makine öğrenimi alanıdır. Çok katmanlı derin sinir ağları kullanarak büyük ölçekli verilerden soyutlamayı modellemeye çalışır, böylece görüntüler, sesler ve metinler gibi verileri anlamlandırmada kullanılmaktadır. Genel olarak derin öğrenmenin iki özelliği vardır, bunlar doğrusal olmayan işlem birimlerinin çoklu katmanları ve her katmanda özellik sunumlarının denetimli veya denetimsiz öğrenimidir (Yu ve Deng, 2010).

Sinir ağlarının yapay zekada 1950'lere kadar uzanan uzun bir geçmişi vardır (Rosenblatt, 1958). Derin öğrenmenin ilk çerçevesi, 1980'lerde yapay sinir ağları üzerine kurulurken, derin öğrenmenin gerçek etkisi 2006'da çok katmanlı yapay sinir ağlarının daha verimli bir şekilde eğitilebileceğinin anlaşılmasıyla ortaya çıkmıştır (Fukushima, 1980), (Hinton ve ark., 2006).




Şekil 2.6. Derin öğrenme ve yaygın olarak kullanılan makine öğrenimi algoritmalarının geliştirilmesinin zaman çizelgesi (Zou ve ark., 2019).

Şekil 2.6.'da derin öğrenme ve yaygın olarak kullanılan makine öğrenimi algoritmalarının zaman içindeki gelişimi gösterilmektedir. Zaman çizelgesinin üst tarafında derin öğrenme ve sinir ağlarının gelişimi gösterilir, alt tarafında ise yaygın olarak kullanılan birkaç makine öğrenimi algoritması gösterilmektedir. Derin öğrenme ve makine öğrenmesi algoritmaları öğrenme şekilleri yönünden birbirlerinden ayrılmaktadırlar. Derin öğrenme ölçeklenebilir makine öğrenmesi olarak tanımlanabilir. Klasik veya derin olmayan, makine öğrenmesi öğrenme kısmında insan müdahalelerine daha bağımlı algoritmalarlardır.

Derin öğrenme yöntemleri, eğitim aşamasında mevcut örneklerin sayısı fazla olduğunda oldukça etkilidir. Örneğin, ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesinde (ILSVRC), bir milyondan fazla açıklamalı görüntü mevcuttur (Russakovsky ve ark., 2015).

Nöron, ağırlıklar, sapma (bias), aktivasyon fonksiyonu derin öğrenmenin kavramlarındandır. İnsan sinir hücrelerindeki nöronların taklit edilmesiyle yapay nöron kavramı oluşturulmuştur. Nöral ağda bir veri alınır, işlenir ve çıktı üretilir.

Girdiler nörona geldiğinde önem derecesine göre bir değer atanır ve bu değer eğitimde önemine göre güncellenmektedir. Bu değerler ağırlıkları oluşturur. Girdiye ek olarak uygulanan doğrusal bileşen sapma (bias) olarak adlandırılır. Sapma, ağırlık katsayılı girişin aralığını değiştirmek için temel olarak eklenir. Aktivasyon fonksiyonu ise giriş sinyallerini çıkış sinyallerine çeviren fonksiyondur (Yılmaz ve Kaya, 2021). Bu kavramların ilişkisi Şekil 2.7.'de gösterilmektedir.




Şekil 2.7. Girdi, nöron, ağırlıklar, sapma (Bias), aktivasyon fonksiyonu, çıktı ilişkisi (Yılmaz ve Kaya, 2021).

2.3.1.1. Yapay sinir ağları

Yapay sinir ağları (YSA) insan beynindeki öğrenme fonksiyonunu modelleyerek bu yeteneği kazanmaya çalışan bilgisayar işlemleridir. Bu işlemler örnekler yardımıyla yapılmaktadır. Bu ağlar yapay sinir hücrelerinin birbirine bağlanmasıyla oluşmaktadır. Sınıflandırma, örüntü tanıma, tahmin, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmaları gibi alanlarda YSA uygulanmaktadır (Öztemel, 2003).

Binlerce nörondan oluşan çok katmanlı algılayıcılar olarak adlandırılan sinir ağı mimarileri, çok karmaşık doğrusal olmayan fonksiyonları temsil edebilir. Bu çok katmanlı algılayıcılar, bir katman oluşturmak için birden fazla nöronun bir araya getirilmesi ve bu katmanların istiflenmesi, bir katmanın çıktısının bir sonraki katmanın girişine bağlanmasıyla oluşturulur. Derin öğrenmende derin ifadesi çok

katmanlı algılayıcıların Şekil 2.8.'deki gibi çok katmanlı mimarisini ifade etmektedir. Giriş katmanı olarak adlandırılan ilk katman, bireysel piksel yoğunlukları gibi girdi verilerini temsil ederken, çıktı katmanı, sınıflandırma sonucu gibi hedef değerleri üretir. Çok katmanlı ağların ara katmanlarına gizli katmanlar denir, çünkü bunlar doğrudan görünür istenen çıktıları üretmezler, onun yerine çıkarım sürecinde yararlı olan girdi özelliklerinin ara değerlerini hesaplamaktadırlar (Chartrand ve ark., 2017).



Şekil 2.8. Üç giriş düğümü, iki gizli katman ve iki çıkış düğümü olan bir YSA (Chartrand ve ark., 2017).

Üçten fazla katmandan oluşan sinir ağından oluşan sinir ağları derin öğrenme algoritması veya derin sinir ağı olarak görülebilir. İki veya üç katmana sahip sinir ağı ise temel bir sinir ağı olarak ifade edilmektedir.

Bazı büyük ölçekli problemlerde YSA'larının eğitim gereksinimleri zaman açısından pratik ve verimli değildir. Evrimsel sinir ağları ise ağırlık paylaşımı ve kullanılan daha karmaşık modeller nedeniyle, büyük paralelleştirmeye izin veren karmaşık problemleri hızlı bir şekilde öğrenebilmektedir (Pan ve Yang, 2009).

2.3.1.2. Evrimsel (Konvolüsyonel) sinir ağları


Evrimsel sinir ağları görüntü verilerinin analizinin yapılmasını sağlamaktadır ve derin öğrenmenin bir alt dalıdır. Bu sinir ağı matematiksel işlemler kullanır ve bu

işlemler evrişim adını almaktadır. Evrişimsel sinir ağları hayvanların görme merkezini taklit etmektedir. Evrişimsel sinir ağı, birçok bilgisayarla görme ve makine öğrenimi probleminde çok iyi performans göstermiştir (Wu, 2017).

İleri yönlü bir sinir ağı olan evrişimsel sinir ağı giriş ve çıkış katmanından başka birden çok birbirine bağlı alt ve gizli katmanlardan oluşur. Benzer boyutlu katmanlara sahip standart ileri beslemeli sinir ağları ile karşılaştırıldığında, evrişimsel sinir ağlarının çok daha az bağlantısı ve parametresi vardır ve bu nedenle eğitilmeleri daha kolaydır. (Ngiam ve ark., 2010).

Evrişimsel sinir ağları, çoklu yapay nöron katmanlarından oluşur. Yapay nöronlar, çoklu girdilerin ağırlıklı toplamını hesaplayan ve bir aktivasyon değeri veren matematiksel fonksiyonlardır. Yapay sinir ağlarında bir görüntü verisi için her katman bir sonraki katmana birkaç bilgi aktarımı yapar. İlk katman genellikle yatay veya çapraz kenarlar gibi temel özellikleri ortaya çıkarmaktadır. Bu çıktı, köşeler veya birleşik kenarlar gibi daha karmaşık özellikleri algılayan bir sonraki katmana iletilir. Ağın derinliklerine indikçe daha karmaşık özellikler tanımlanabilmektedir. Son evrişim katmanının etkinleştirme haritasına dayalı olarak sınıflandırma işlemi yapılmaktadır.

Evrişimsel sinir ağları görüntü verilerini Şekil 2.9.'daki gibi alt katmanlarında evrişim, doğrultucu, havuzlama gibi aşamalardan geçirerek sınıflandırma işlemini yapar. Sınıflandırılan veriler için algorithmadan beklenen sonucu ortaya çıkarmaya çalışmaktadır.



Şekil 2.9. Evrişimsel sinir ağları yapısı ve karar süreci (Furioso, 2022).

2.3.2. Transfer öğrenimi

Transfer öğrenimi daha önce öğrenilmiş olan ilgili bir görevden bilginin aktarılması yoluyla yeni bir görevde öğrenmenin geliştirilmesidir. Bu öğrenme ikinci görevi modellerken hızlı ilerlemeye ve iyileştirilmiş performansa katkı sağlayan bir eğitim modelidir (Olivas ve ark., 2009).


Teorik tanımlamasına baktığımızda Pan ve Yang 2009'da yayınladıkları 'Transfer Öğrenimi Üzerine Bir Anket' çalışmalarında transfer öğrenimini anlatmak için alan, görev ve marjinal olasılıkları kullanmışlardır. Alan (domain) $\mathcal{D}$, iki elemandan oluşur; bunlar bir özellik uzayı $\mathcal{X}$ ve onun marjinal olasılık dağılımı $P(X)$ 'dir (X , örnek veri noktası) olduğunda $X = \{x_1, \dots, x_n\}$, $x_i \in \mathcal{X}$ (x_i burada spesifik vektörü gösterir). Alan da matematiksel olarak şu şekilde gösterilebilir; $\mathcal{D} = \{\mathcal{X}, P(X)\}$. Görev (task) $\mathcal{T}$, etiket uzayı $\mathcal{Y}$ ve amaç fonksiyonu $f(\cdot)$ olarak iki bileşen içerir ve amaç fonksiyonu $P(Y|X)$ olarak tanımlanabilir. Herhangi bir alan için görev $\mathcal{T} = \{\mathcal{Y}, f(\cdot)\} = \{\mathcal{Y}, P(Y|X)\}$ olarak ifade edilebilir. Bir fonksiyon $f(\cdot)$ özellik vektörü/etiket ikilisinden eğitilir $\{x_i, y_i\}$, $x_i \in \mathcal{X}$ ve $y_i \in \mathcal{Y}$ ve alandaki her bir vektör için $f(\cdot)$ ona karşılık gelen etiketi tahmin eder $f(x_i) = y_i$.

Transfer öğrenimi şu şekilde ifade edilebilir: Bir kaynak alanı $\mathcal{D}_S$ ve kaynak görevi $\mathcal{T}_S$, bununla birlikte hedef alan $\mathcal{D}_T$ ve hedef görev $\mathcal{T}_T$ durumunda, transfer öğreniminin amacı $\mathcal{D}_S$ ve $\mathcal{T}_S$ 'ten ($\mathcal{D}_S \neq \mathcal{D}_T$ ya da $\mathcal{T}_S \neq \mathcal{T}_T$ olduğunda) edindiği bilgiler sayesinde $\mathcal{D}_T$ 'deki hedef koşullu olasılık dağılımını $P(Y_T|X_T)$ öğrenmeyi sağlamaktır. Kaynak ve hedef alanlar $\mathcal{D}_S$ ve $\mathcal{D}_T$, $\mathcal{D} = \{\mathcal{X}, P(X)\}$ ve kaynak ve hedef görevler $\mathcal{T}_S$ ve $\mathcal{T}_T$, $\mathcal{T} = \{\mathcal{Y}, P(Y|X)\}$ olduğunda dört transfer öğrenme senaryosu karşımıza çıkar:

- $\mathcal{X}_S \neq \mathcal{X}_T \rightarrow$ kaynak ve hedef alanların özellik uzayı farklıdır.
- $P(\mathcal{X}_S) \neq P(\mathcal{X}_T) \rightarrow$ kaynak ve hedef alanlarının marjinal olasılık dağılımı birbirinden farklıdır.
- $\mathcal{Y}_S \neq \mathcal{Y}_T$ kaynak ve hedef görevlerin etiket uzayları birbirinden farklıdır.
- $P(Y_S|X_S) \neq P(Y_T|X_T)$ kaynak ve hedef görevlerin koşullu olasılık dağılımları eşit değildir (Ruder, 2017).

2.3.2.1. Transfer öğreniminin sınıflandırılması

Transfer öğrenimi problem ve çözüm açısından bakıldığında farklı kategorik gruplara ayrılabilir. Şekil 2.10'da genel şema halinde görülebileceği gibi, problem yönünden bir sınıflandırma yapıldığında etkileyme ve uzay temelli iki sınıfa ayrılabilir. Bunlardan etiketleme temelli olan grup endüktif, transdüktif ve gözetimsiz olmak üzere üçe ayrılır.



Endüktif transfer öğrenmesinde kaynak ve hedef alanları aynı ya da farklı olabilir fakat hedef ve kaynak görevleri birbirinden farklıdır. Bu durumda algoritma kaynak alandan aldığı tümevarımsal önyargıları hedef görevde kullanır. Kaynak alanda etiketleme olmadığında kendi kendine öğrenme, etiketleme olduğunda ise çoklu öğrenme olarak alt kategorilere ayrılır.

Transdüktif öğrenmede ise kaynak ve hedef alanları farklıyken görevleri aynıdır ve veri etiketleri sadece kaynak alandan gelir.

Gözetimsiz öğrenme olan üçüncü grupta ise hedef ve kaynak görevleri farklıdır, her iki alanda da etiketlenme söz konusu değildir (Pan ve Yang, 2009).

Başka bir sınıflandırma çeşidi olan uzay tabanlı kategoride, kaynak ve hedefin özellik ve etiket uzaylarının arasındaki uyumluluk dikkate alınır. Homojen

öğrenmede kaynak ve hedefin özellik ($\mathcal{X}_S = \mathcal{X}_T$) ve etiket ($\mathcal{Y}_S = \mathcal{Y}_T$) uzayları aynıdır. Heterojen öğrenmede ise bu uzaylar birbirinden farklıdır ($\mathcal{X}_S \neq \mathcal{X}_T$, $\mathcal{Y}_S \neq \mathcal{Y}_T$) (Zhuang ve ark., 2020).

Transfer öğreniminde yukarıda bahsedilen durumlarda neyin transfer edileceğine yönelik olarak yapılan sınıflandırmada dört ana yaklaşım söylenebilir:

Örnek-tabanlı transfer: Kaynak alandaki datanın bir kısmının hedef alanda tekrar kullanılmasını ifade eder. Genellikle kaynak alandaki veri doğrudan doğruya kullanılamasa da kaynak alandaki bazı ‘örneklerin’ hedef alanda tekrar kullanılmasıyla sonuçlar iyileştirilebilir.

Özellik temsili transferi: Bu çeşit transferde amaç ‘iyi’ özelliklerin hedef alanda kullanılmak üzere öğrenilmesidir. Kaynak alandaki iyi özelliklerin alınıp hedef alanda kullanılmasıyla ırsamanın ve hata oranlarının azaltılması amaçlanır ve böylelikle hedef görevin gerçekleşmesinde önemli bir iyileşme olması beklenir.

Parametre transferi: Bu yöntem kaynak ve hedef görevlerin belli parametreleri ya da hiper-parametre dağılımlarını paylaşması önkoşuluyla transfer yapılmasına dayanır. Parametre ya da önsellerde kodlanan bilginin paylaşılmasıyla görevler arası bilgi transferi gerçekleştirilir.

İlişkili bilgi transferi: Bu yaklaşımda diğer üç yaklaşımdan farklı olarak, bağımsız olmayan ve eşit olarak dağılmış veri kullanarak ilgili alanlar arasında transfer öğrenmesi yapılır. Kaynak ve hedef alanlardaki verilerin aralarındaki bazı ilişkilerin benzer olması temeline dayanan bu yaklaşımda, her bir veri noktasının diğer veri noktalarıyla bir ilişkisi olması söz konusudur. Sonuçta veriler arasındaki ilişki transfer edilmiş olur. Örnek olarak sosyal ağ verilerinin bu yaklaşımı kullanması gösterilebilir (Pan ve Yang, 2009, Sarkar, 2018).

Tablo 2.2.’de bahsedilen bu yaklaşımların şimdiye kadar yapılan çalışmalarda hangi transfer öğrenme durumlarında kullanıldığı gösterilmiştir.


Tablo 2.2. Transfer öğrenme durumlarının farklı yaklaşımlarda kullanımı

	Endüktif transfer öğrenmesi	Transdüktif transfer öğrenmesi	Gözetimsiz transfer öğrenmesi
Örnek-tabanlı transfer	x	x	
Özellik temsili transferi	x	x	x
Parametre transferi	x		
İlişkili bilgi transferi	x		

2.3.2.2. Derin öğrenmede transfer öğrenimi yaklaşımları


Yukarıda makine öğrenmesinde kullanılabilen genel transfer öğrenme yöntemlerinden bahsedilmiştir. Derin öğrenmede ise transfer öğrenimi genellikle bir model geliştirilmesi veya önceden eğitilmiş bir modelin kullanılması şeklinde uygulanmaktadır. Ancak sıfırdan model geliştirmenin zaman alıcı ve maliyetli olması nedeniyle önceden eğitilmiş modeller de tercih edilebilmektedir. Bu amaçlarla derin öğrenmede kullanılan başlıca iki transfer öğrenme yöntemi şöyledir:

Önceden eğitilmiş ağlardan özellik çıkarmı: Bölüm 2.3.1.1. ve 2.3.1.2.'de de bahsedildiği gibi derin öğrenme modelleri çok katmanlı bir yapıdan oluşmaktadır. Bu modellerde farklı katmanlarda öğrenilen farklı özelliklerle geliştirilen bu yapı daha sonrasında sınıflandırma (karar) katmanına bağlanır. Bunun avantajı, önceden eğitilmiş modellerin bu sınıflandırma katmanının değiştirilerek elimizdeki veri seti için kullanılabilir olmasıdır. Eğitilen modellerden özellik çıkarmak için bu modellerin (örneğin Inception V3, VGG, AlexNet gibi) ağırlıklı katmanları değiştirilmeyerek burada öğrenilen bilgi sınıflandırma katmanına transfer edilir. Şekil 2.11.' de temsili biçimde gösterildiği gibi sınıflandırma katmanına yeni veri setiyle yeni görev verilerek önceden eğitilmiş ağların kaynak alanından elde ettiğimiz bilgiyi kendi amacımız için kullanmış oluruz.



Şekil 2.11. Önceden eğitilmiş ağlardan özellik çıkarımı yoluyla transfer öğreniminin yapılması (Öztürk, 2020)

Önceden eğitilmiş ağlarda ince ayar yapılması: Yukarıda bahsedilen özellik çıkarımından farklı olarak bu yöntemde sadece son katmanda değil diğer katmanlarda da değişiklikler yapılır. Yapay sinir ağlarındaki başlangıç katmanlarında genel özellikler öğrenilirken daha ileriki katmanlarda ise göreve yönelik daha spesifik özellikler öğrenilir. Şekil 2.12.'de temsili biçimde gösterildiği gibi bu yaklaşımda alt katmanlar dondurulabilir ya da bu katmanlarda ince ayar yapılarak model yeniden eğitilebilir. Böylelikle bu ağın bütün yapısındaki bilgiler yeniden eğitimde kullanılabilir ve sonuç olarak hedef görevi gerçekleştirmedeki başarı oranı daha kısa sürede artırılabilir (Sarkar, 2018).




Şekil 2.12. Önceden eğitilmiş ağlarda ince ayar yoluyla transfer öğreniminin yapılması (Öztürk, 2020)

Transfer öğreniminde en önemli gerekliliklerden biri de daha önceden eğitilmiş ve kaynak alandaki görevleri iyi yapan modellerin bulunmasıdır. Günümüzde birçok gelişmiş durumdaki modeller açık olarak hizmete sunulmuştur. Bu modeller en yoğun olarak doğal dil işleme, bilgisayarlı görü ve ses verisi tanıma alanlarında kullanılmaktadır. Görevlerindeki çeşitlilikten dolayı analizlerin daha zor olduğu doğal dil işleme alanı için Word2Vec, GloVe, FastText gibi kelime yerleştirme/gömme modelleri kullanılabilir. Bilgisayarlı görü alanında ise görüntü işlemek amacıyla birçok veri ve parametre/ağırlık kullanılarak gereken zaman süresince eğitilen ve geliştirilen evrimsel sinir ağlarından bazıları VGG-16, VGG-19, Inception V3, Xception, ResNet50, AlexNet, DenseNet169'dur. Bunlar gibi çok katmanlı ağlara kütüphaneler üzerinden ya da kendi sitelerinden açık kaynaklı olarak ulaşarak, bu ağları görüntü işlemek için transfer öğrenimiyle birlikte spesifik bir amaca yönelik olarak geliştirerek kullanmak mümkündür.

Transfer öğrenimi genellikle bir model geliştirilmesi veya önceden eğitilmiş bir modelin kullanılması şeklinde uygulanmaktadır. Ancak model geliştirmenin zaman alıcı ve maliyetli olması nedeniyle derin öğrenme alanında önceden eğitilmiş modeller tercih edilebilmektedir. Görüntü işlemede önceden eğitilmiş ResNet50, AlexNet, VGG19, DenseNet169 gibi çok katmanlı ağlar kullanılmaktadır.

Öte yandan bir evrimsel sinir ağının ölçeği, eğitim veri kümesinin ölçeği ile uyumludur. Doğal olarak evrimsel sinir ağı ne kadar derinse, önemli miktarda geçerli eğitim örneği gerektiren daha fazla parametrenin eğitilmesi gerekir. Farklı öğrenme yöntemleri için veri boyutu ve performans arasındaki temsili ilişki Şekil 2.13.'te gösterilmektedir. Büyük ölçekli bir evrimsel sinir ağının performansı, diğer yöntemlerin üstesinden gelme potansiyeline sahip olsa da eğitim verilerinin boyutuyla da derinden ilişkilidir. Öte yandan transfer öğrenimi, yalnızca küçük bir eğitim seti kullanarak büyük ölçekli evrimsel sinir ağlarıyla orantılı belirgin performans elde etme yeteneğine sahiptir. Yeterli eğitim verisiyle birlikte önceki görevlerde öğrenilen ve biriktirilen bilgi ve beceriler, transfer öğreniminin kullanılmasıyla küçük eğitim veri setinde dahi yeni bir göreve uygulandığında bir sinir ağının performansını iyileştirmek için olası bir çözüm sağlar (Cao ve ark.,

2018). Bu tez çalışmasında yapılan uygulamada işlenmek üzeri askeri gizlilik sebebiyle kısıtlı sayıda görüntü elde edilebilmiştir. Transfer öğrenimi yöntemiyle hazır eğitilmiş modellerin karar katmanlarını kesip kendi eğitim modelimizi de modele ekleyerek yeni karar katmanını oluşturup az sayıdaki verinin eğitilmesi sağlanmıştır.



Şekil 2.13. Öğrenme yöntemlerinde veri boyutuna karşı performans (Cao ve ark., 2018).

2.4. Literatürde Havacılık Malzemelerinde Hasar Tespiti Yapılması Amacıyla Görüntü İşleme Teknikleri Kullanan Bazı Çalışmalar

Literatürde görüntü işleme tekniklerinin çatlak analizi yapılması bakımından özellikle İnşaat Mühendisliği alanında geliştirildiği görülmektedir. Bu alandaki beton çatlakları (bina, köprü ya da borularda) ve yoldaki asfalt yüzeylerde oluşan çatlakların analizi görüntü işleme ve makine öğrenmesi teknikleriyle geliştirilmeye devam edilmektedir (Koch ve ark, 2015). Dahası çatlaklarla alakalı algoritma geliştirmek isteyenler için veri seti arandığında, internette açık veri kaynaklı olarak bulunan ve eski bir ODTÜ öğretim üyesi olan Dr. Çağlar Fırat Özgenel tarafından sağlanan veri seti (20 bin çatlak içeren görüntü ve 20 bin çatlak olmayan görüntü) öğrenciler ve araştırmacılar tarafından eğitim ve akademik amaçlı kullanılmaktadır (Özgenel, 2019).

Radyografik görüntüler ise 1990lı yıllardan itibaren dijitalize edilerek görüntü işleme teknikleriyle işlenmeye çalışılmaktadır. Birçok farklı endüstriyel alanda (havacılık, inşaat, araç üretimi, demiryolu, petrokimya gibi) yaygın olarak kullanılan metal kaynaklama esnasında meydana gelen kaynak hatalarının ortaya çıkartılmasında sık olarak kullanılan radyografi analizleri, uzman yetkililerin kontrolüne ve yorumuna dayanmaktadır. Bu analiz, radyografilerin kalitesi ve kontrastının düşük olması, kaynak kalınlığı, uzman kişilerin eğitilmesi ve tecrübe kazanması gerekliliği, tecrübeli uzmanların bile küçük boyuttaki hasarları belirleyememesi gibi dezavantajlara sahiptir. Dahası insan kaynaklı yorumların öznelliğe açık olması ve çok sayıda görüntünün analizinin getirdiği iş yükü de insan kaynaklı analiz yöntemini zorlaştırmaktadır (Hou ve ark., 2020). Bu nedenlerle metal kaynaklarının radyografilerinde bilgisayarlı görünüm kullanılmak istenmesiyle algoritmalar geliştirilmeye başlanmıştır (Gayer ve ark., 1990, Liao ve Ni, 1996, Liao ve Li, 1998, Mery ve Berti, 2003, Shafeek ve ark., 2004).

Önceleri sadece film üzerinde görüntülenebilen X-ışını radyografileri bilgisayarlı görüde kullanılmak üzere dijitalleştirilmek zorundaydı. Günümüzde ise görüntüleme tekniklerinin de gelişmesiyle birlikte detektörlerden dijital olarak elde edilen uçak parçalarının görüntüleri direkt olarak algoritmalarda işlenebilmektedir (Wang ve ark., 2008). Bu tezdeki çalışmada ise askeri uçak parçalarının film olarak elde edilebilmiş X-ışını radyografileri dijitalleştirilerek kullanılmıştır. İleride imkan olduğunda dijital X-ışını radyografileri kullanılabilirse, bunun sağladığı arşivleme ve düzenleme kolaylığı, görüntülerin yüksek duyarlılıkta elde edilmesi ve filmde dijital ortama geçirilmesi zorunluğunun olmaması gibi avantajlardan yararlanılarak sürecin verimliliği arttırılabilir (Wang ve ark., 2008). Bu çalışmanın literatürde havacılık alanındaki muayenelerde elde edilen görüntülerle yapılan diğer çalışmalarla kıyaslanması amacıyla hazırlanan Tablo 2.3'te çalışmaların genel özellikleri görülebilir.

Tablo 2.3. Hasar tespiti için askeri ve sivil uçaklardan alınan görüntülerle yapılan görüntü işleme ve/veya evrimsel sinir ağı tekniklerinin kullanıldığı çalışmalar

Çalışma	Kullanılan yöntem	Görüntü özelliği	Görüntü sayısı	Çalışma sonuçları
Wang ve ark., 2008	Gamma düzeltmesi ve kontrast limitli adaptif histogram eşitlemesi	Dijital radyografi görüntüleri (askeri uçak kanatlarından elde edilmiş)	8	Mevcut değil*
Wang ve ark., 2011	ROI minimizasyonu ve geliştirilmiş Canny kenar belirleme algoritması	Dijital radyografi görüntüleri	8	%100 [#]
Wong ve ark., 2011	ROI minimizasyonu ve geliştirilmiş Canny kenar belirleme algoritması	Dijital radyografi görüntüleri (askeri uçak kanatlarından elde edilmiş)	8	%88,9 (Doğruluk oranı)
Gong ve ark., 2020	Derin yapay sinir ağıyla birlikte transfer öğrenimi	Dijital radyografi görüntüleri (kompozit malzemeden üretilen havacılık/uzay parçalarından elde edilmiş)	100	%96,8 (Doğruluk oranı)
		+	+	%96 (F-skor)
		Veri tabanından alınan kaynak görüntüleri	88	%97,3 (Kesinlik)
Chen ve Juang, 2020	Hızlı bölgesel-evrimsel sinir ağına (Fast R-CNN) dayalı olan AE-RTISNet	Dijital radyografi görüntüleri (sivil uçak ve motor parçalarından elde edilmiş)	6000	%90 (Doğruluk oranı)
Chen ve Juang, 2021	YOLOv4 evrimsel sinir ağı	Dijital radyografi görüntüleri (sivil uçak ve motor parçalarından elde edilmiş)	6100	%90 (Doğruluk Oranı)
Gong ve ark., 2022	Alan adaptif daha hızlı bölgesel-evrimsel sinir ağı (domain adaptive Faster R-CNN) ve transfer öğrenimi	Dijital radyografi görüntüleri (kompozit malzemeden üretilen havacılık/uzay parçalarından elde edilmiş)	200	%80,7
		+	+	(Ort.
		Veri tabanından alınan görüntüleri	1030	Kesinlik)
Tyystjärvi ve ark., 2022	U-net'in (bir tür evrimsel sinir ağı) modifiye edilmiş hali	Dijital radyografi görüntüleri (havacılık malzemelerinde yapılan kaynak muayenesinden alınan)	223	POD** eğrisinde $a_{90/95}$: 0,6

* Otomatik analiz yapılmamış, sadece görüntü kalitesi arttırılmıştır.

2 mm'ye kadar olan çatlaklar için geçerlidir.

Fast R-CNN: Fast Region-based Convolutional Neural Networks

**POD: Probability of detection (tahribatsız muayene yöntemlerinde kullanılabilen ve sistemin güvenilirliğini gösteren hesaplama yöntemi, $a_{90/95}$: 0,6 değeri yüksek bir güvenilirlik ifade eder)

Tablo 2.3.'te de görüldüğü gibi Wong ve ark. son olarak 2011 yılında yayınladıkları makalede askeri uçak kanatlarının muayenesinde kullanılmak üzere otomatik bir çatlak belirleme sistemi geliştirmişlerdir. Çalışmalarında bu tezdeki çalışmadan farklı olarak dijital olarak elde edilmiş radyografi görüntülerini (18 adet çatlak içeren 8 görüntü) kullanmışlardır. Dijital radyografi görüntülerini de geliştirdikleri robot kontrollü tarama sisteminde elde etmişlerdir. ROI minimizasyonu ve geliştirilmiş bir Canny kenar belirleme algoritması ile 2 mm'ye kadar olan çatlakları %88,9 doğruluk oranıyla belirleyebildiklerini göstermişlerdir (Wong ve ark., 2011). Kullandıkları bu algoritma daha önce yine aynı X-ışını görüntüleri kullanılarak yapılan başka bir çalışmadan alınmış olup (Wang ve ark., 2011), burada daha da geliştirilerek kullanılmıştır. Fakat bu geliştirilen algoritma sadece bağlantı elemanı deliklerinin çevresindeki çatlakların görüntü işleme teknikleriyle belirlenmesine özgü geliştirilmiştir ve yapay zeka elemanlarıyla daha ileri düzeye getirilmemiştir (Wong ve ark., 2011). Bu tezdeki çalışmada ise uçaklardaki sadece belirli bölgelerdeki hasarların fotoğrafları değil, uçakların farklı bölgelerinden alınan (gövde, kanat, motor) X-ışını görüntüleri ve görüntülerdeki tüm pikseller görüntü işleme ve yapay sinir ağlarının eğitilmesinde kullanılmıştır (50 adet çatlak içeren ve 50 adet çatlak içermeyen olmak üzere toplam 100 görüntü).

Bu tezdeki çalışmada olduğu gibi X-ışını görüntülerinin kullanıldığı Gong ve arkadaşlarının çalışmasında uçuş güvenliğinin artırılması amacıyla hasar tespiti için yapay zeka elemanlarından transfer öğreniminin kullanıldığı bir model geliştirilmiştir. Özellikle havacılık (uçak ve uzay) sektöründe kullanılan kompozit malzemelerdeki kaynak hatalarını belirlemek için, az sayıdaki X-ışını görüntülerini kullanarak doğru özellik çıkarımı yapabilen derin transfer öğrenimi modeli geliştirmişlerdir. Kullandıkları bu modelde %96'ya varan F-skor elde ettiklerinin belirtirlerken, diğer çalışmalardan farklı olarak görüntüleri bölerek yama görüntüler oluşturmuş ve bu yama görüntüleri modellerinde kullanmışlardır. Böylelikle havacılık malzeme muayenesinden aldıkları 100 adet kompozit malzeme radyografi görüntüsü ve GDXray veri tabanından aldıkları 88 adet kaynak radyografi görüntüsünden sırasıyla 400 adet (200 hasarlı ve 200 hasarsız) ve 400 adet yama görüntüleri oluşturmuşlardır (Gong ve ark., 2020).

Aynı çalışma grubunun 2022’de yaptığı başka bir çalışmada, 2020’deki ilk çalışmalarında kendi veri setlerinden sadece cüruf hatalarını içeren görüntüleri kullanmışken yeni yayınladıkları çalışmalarında hem oyuk hem de cüruf hatalarını içeren görüntüleri kullanmışlardır. İkinci çalışmada veri seti olarak kendi enstitülerinden elde ettikleri 200 adet X-ışını görüntüsüyle GDXray veri tabanından aldıkları 1030 adet radyografi görüntüsü (1000 adet eğitim veri seti ve 30 adet test veri seti olarak kaynak alanda) kullanılmıştır. Daha gelişmiş bir alan adaptif daha hızlı bölgesel-evrişimsel sinir ağı (domain adaptive Faster R-CNN) geliştirdiklerini gösteren ekip, bunu ağ katmalarında özellik çıkarma aşamalarında değişiklikler yaparak elde etmişler ve sonuç olarak daha küçük boyuttaki hataları belirleyebilmişlerdir (Gong ve ark., 2022).

Transfer öğrenimi kullanılarak geliştirilen bir modelin kullanıldığı başka bir çalışmada, Chen ve Juang, X-ışını muayene görüntülerini kullanarak gelişmiş bir hızlı bölgesel-evrişimsel sinir ağı (Fast R-CNN) algoritmasına dayalı olan AE-RTISNet adını verdikleri modeli geliştirmişlerdir. Veri seti olarak toplam 6000 görüntü ve bunların üzerinde belirlenen sekiz çeşit motor hasarlarının kullanıldığı AE-RTISNet, algılama, yer belirleme ve sınıflandırma yapabilmektedir. %90’ın üzerinde bir doğrulukla çalışmış olan bu model, motor parçalarından elde edilen X-ışını görüntülerinden hasar tespiti yapmayı ve hasar çeşidini belirlemeyi başarmıştır. Aynı zamanda da diğer hızlı bölgesel-evrişimsel sinir ağı (orijinal Mask-RCNN, YOLO-V2 ve YOLO-V3) yaklaşımlarına göre daha iyi sonuç vermiştir (Chen ve Juang, 2020).

Yine derin öğrenmeye dayalı geliştirilen otomatik bir hasar belirleme sisteminde, havacılık malzemelerindeki kaynak hatalarının belirlenmesi, bölütlenmesi ve hata derecesinin tahmin edilebilmesi için dijital radyografi görüntülerinden yararlanılmıştır. 223 görüntü (her biri birden fazla kaynak bölgesi içerir) rastgele olarak %60 eğitim, %20 doğrulama ve %20 test veri setleri olarak bölünmüştür. Bir tür evrişimsel sinir ağı yaklaşımı olan U-net’in modifiye edilmiş hali eğitilerek semantik bölütleme maskelerinin (hasarlar ve arka plan için) oluşturulmasında


kullanılmıştır. Bu sistem sonuç olarak yüksek güvenilirlik oranı ve kabul edilebilir bir hata oranıyla hasar belirleme yapmayı başarmıştır (Tyystjärvi ve ark., 2022).



BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Materyal

Bu çalışmada, uçak bakımında hasar analizinde önemli bir yöntem olan radyografi yöntemiyle elde edilen X-ışını fotoğrafları kullanılmıştır. Gizlilik sebebiyle az sayıda elde edilebilen askeri havacılıkta kullanılan uçak parçalarındaki hasar fotoğrafları kullanılarak analizler yapılmıştır. Çalışmada uzman personel tarafından analiz edilmiş olan 50 adet hasarlı, 50 adet hasarsız toplam 100 adet görüntü verisi kullanılmıştır. Filmlerin üzerindeki X-ışını görüntüleri kamera ile dijital hale getirilmiştir. Görüntüler uçakların kanat, gövde, motor gibi farklı kısımlarından alınmıştır. Parçalarda çatlak hasarlarının kontrolü görüntü işlemeyle yapılmıştır. Şekil 3.1.'de aynı parçanın hasarlı ve hasarsız görüntü verisi gösterilmektedir. Şekil 3.1.'deki sol taraftaki görüntü hasarlı sağ taraftaki görüntü hasarsız görüntüdür.



Şekil 3.1. Bir parçaya ait hasarlı ve hasarsız görüntü verisi

Görüntü işlemeyle yapılan çalışmalar, görüntü verileri için insanın görme sistemini taklit eder. Bina yüzeylerinde insan gözüyle görülebilen çatlakların bilgisayarlar tarafından otomatik tanınmaları ve analizleri için görüntü işleme tekniklerine dayalı akıllı bir model oluşturulmuştur (Hoang, 2018). Bu çalışmada da jet uçaklarındaki hasarlı parçaların tespiti için görüntü işleme yöntemi kullanılmıştır. Eldeki verilerin işlenmesi ve sorunun çözümü için önceden eğitilmiş evrimsel sinir ağları yardımıyla derin öğrenme yöntemlerinden yararlanılmıştır.

Görüntü işleme ve derin öğrenme yöntemleriyle hasar tespiti yapmak amacıyla Google Colab platformunda Python programlama dili kullanılmıştır.

Google Colab, makine öğrenimi eğitimi ve araştırmasını yaygınlaştırmak amacıyla oluşturulan bir projedir. Colaboratory, TensorFlow, Matplotlib ve Keras gibi temel makine öğrenimi ve yapay zeka kitaplıklarıyla önceden yapılandırılmış Python 2 ve 3 çalışma zamanları sağlar. Ayrıca bu Google hizmeti, daha önce ana hatları verilen yazılımla tamamen yapılandırılmış, GPU ile hızlandırılmış bir çalışma zamanı sağlar (Alves ve ark., 2020).

Python programlama dili, makine öğrenimi, veri analizi, görüntü işleme, robotik ve daha pek çok alanda kullanılmaktadır. Python 2 ve Python 3 olarak iki versiyonu bulunmaktadır. Bu tezde Python 3 versiyonu kullanılarak çalışmalar yapılmıştır.

Python açık kaynaklı, basit bir yapısı ve tanımlanmış söz dizimi bulunmasından dolayı geniş bir kullanıcıya hitap etmektedir. Görüntü işleme uygulamalarında işlevselliğe ve hıza sahiptir (Raschka ve Mirjalili, 2017). Ayrıca Python geniş kütüphanelere sahiptir. Çok boyutlu dizileri ve matrisleri destekleyen NumPy, veri işleme, analizi ve derin öğrenmeyi destekleyen pandas ve fastai kütüphaneleri sayesinde makine öğrenmesi uygulamaları için oldukça kullanışlıdır. Google Colab üzerinde Python kodları ile yapılan programlama görüntü işleme konusundan dünya üzerinde daha fazla kişinin rahatlıkla çalışabilme imkanı sunmaktadır.

3.2. Yöntem

Eldeki kısıtlı sayıdaki verilerin eğitiminin derinleştirilebilmesi için önceden eğitilmiş evrişimsel sinir ağlarından yararlanılmıştır. Transfer öğrenimi yöntemiyle de çalışmadaki verilerin eğitimi ve analizi tamamlanmıştır. Transfer öğrenimi bir amaç için eğitilen modelin ikinci bir ilgili görevde yeniden kullanılmasının amaçlandığı bir makine öğrenimi tekniğidir. (Goodfellow ve ark., 2017).

Çalışma için ResNet50, AlexNet, VGG19 ve DenseNet169 evrişimsel sinir ağı modelleri seçilmiştir. Bu modeller X-ışını ile yapılan çalışmalarda verimli ve başarısı yüksek sonuçlar vermiştir (Jiménez-Sánchez ve ark., 2020, Er, 2020, Kroguve ve ark., 2020, Polat, Ç. ve ark., 2021).

3.2.1. Veri setinin hazırlanması

Eğitim ve kontrol grubunu oluşturacak veriler Joint Photographic Experts Group (JPEG) dosyası formatında bilgisayara aktarılmıştır. Eldeki X-ışını görüntü verileri hasarlı olanlar ve hasarlı olmayanlar olarak iki gruba ayrılmıştır.


3.2.2. Ön işleme

Hasar tespiti için çekilen X-ışını görüntüleri ön işlemde geçirilerek yeniden boyutlandırılmıştır. Bunun sebebi farklı derin öğrenme modelleri için görüntü girişlerinin farklı olmasıdır. ResNet50, VGG19 ve DenseNet169 için görüntüler 224×224 piksele, AlexNet için ise görüntüler 227×227 piksele ayarlanmıştır.

3.2.3. Verilerin model için seçimi ve çapraz doğrulama


Görüntü verileri derin öğrenme modellerinde kullanılmak üzere eğitim ve kontrol olarak ayrılmaktadır. Oluşturulan modellerinde eldeki verilerinin 90 adedi eğitim için 10 adedi ise kontrol için kullanılmıştır. Modellere seçilen veriler için çapraz doğrulama yöntemi kullanılmıştır.

AlexNet modeli, beş evrişim katmanından ve üç tam bağlantılı katmandan oluşur. 1000 nesne sınıfı sınıflandırma görevi için tasarlanan AlexNet'in ilk evrişim katmanındaki bazı çekirdek görselleştirme örneklerini gösterir. AlexNet, çıktı katmanı, sınıf sayısına karşılık gelen 10 bin birime sahiptir. AlexNet'in yönlü bileşenlerle kenar, doku ve renk bilgilerini çıkaran çeşitli filtreleri otomatik olarak aldığı Şekil 3.3.'te gösterilmektedir (Fujiyoshi ve ark., 2019).



Şekil 3.3. AlexNet ve çekirdeklerin ağ yapısı (Fujiyoshi ve ark., 2019).

Önceden eğitilmiş VGG19 modeli, çoklu bağlı kıvrımlı katmanlardan ve tamamen bağlı katmanlardan oluşan altı ana yapıya sahiptir. Giriş boyutu $224 \times 224 \times 3$. VGG-19 model yapısı Şekil 3.4.'te gösterilmiştir. VGG-19 evrişimsel sinir ağı bir ön işleme modelidir ve geleneksel evrişimsel sinir ağlarına kıyasla ağ derinliğinde geliştirilmiştir. Tek bir evrişime göre daha iyi olan, çoklu evrişimsel katmanların ve doğrusal olmayan etkinleştirme katmanlarının alternatif bir yapısını kullanır. Bu şekildeki katman yapısı görüntü özelliklerini daha iyi seçebilir, alt örnekleme için Maxpooling'i kullanabilir ve aktivasyon işlevi olarak doğrusal birimi değiştirebilir, böylelikle görüntüdeki en büyük değeri toplanmış alan değeri olarak seçebilir (Xiao ark., 2020).



Şekil 3.4. VGG19 ağ modeli (Xiao ark., 2020).

DenseNet169 kaybolan gradyan sorununu azaltır, özellik yayılımını geliştirir, özelliklerin yeniden kullanılmasına yardımcı olur ve parametre sayısını önemli ölçüde azaltır (Isola ark., 2017).

3.2.5. Sınıflandırma işlemi

Önceden eğitilmiş evrişimsel sinir ağları kullanılarak derin özellikler çıkarılmıştır. Çıkarılan özellikler farklı sınıflandırıcılarla kullanılarak modelin seçimi yapılmıştır. Kullanılan sınıflandırıcılar, `linear_model.SGDClassifier`, `ensemble.Bagging`, `neural_network.MultiLayerPerceptron`, `naiveBayes.multinomialNB`, `svm.SVM`, `svm.NuSVC`, `discriminant_analysis.LinearDiscriminantAnalysis`.

`Linear_model.SGDClassifier`, değişken alçalma eğimi (SGD) öğrenimi ile düzenli lineer modeller uygular. Kaybın derecesi, her veride bir defada tahmin edilir ve model, azalan öğrenme oranı ile süreç boyunca güncellenir. SGD, aracılığıyla çevrimiçi öğrenmeye izin verir. Modelin çıktısı, beklenen çıktı ile karşılaştırılır ve bir hata hesaplanır. Bu hata daha sonra her seferinde bir katman olacak şekilde ağ üzerinden geri doğru yayılır ve ağırlıklar, hataya katkıda bulundukları miktara göre güncellenir.

`Ensemble.Bagging`, topluluk öğrenimi birden çok modelin aynı sorunu çözmek için eğitildiği ve daha iyi sonuçlar elde etmek için birleştirildiği bir makine öğrenimi değerler dizisidir. Amaç, zayıf modeller doğru bir şekilde birleştirildiğinde daha doğru ve/veya sağlam modeller elde edebileceğimizdir.

Neural_network.MultiLayerPerceptron, çok katmanlı algılayıcı, doğrusal ve doğrusal olmayan veriler arasındaki ilişkiyi öğrenen yapay sinir ağıdır. Sinir ağlarının tahmin yeteneği, ağların hiyerarşik veya çok katmanlı yapısından gelir. Veri yapısı, farklı ölçeklerdeki veya çözünürlüklerdeki özellikleri seçebilir.


NaiveBayes.multinomialNB, çok terimli Naive Bayes sınıflandırıcısı ayrık özniteliklerle sınıflandırma için uygundur. Çok terimli olarak dağıtılmış veriler için saf Bayes algoritmasını uygular.

Svm.SVM, destek vektör makinesi eğitim verilerinde bir karar sınırı bulan vektör uzayı tabanlı makine öğrenme yöntemidir.

Svm.NuSVC, nu-destek vektör sınıflandırması veri kümesinde ikili ve çok sınıflı sınıflandırma gerçekleştirebilir.

Discriminant_analysis.LinearDiscriminantAnalysis, doğrusal ayırma analizi denetimli bir boyutsallık azaltma tekniğidir. Çıktı sınıflarını ayırt eden bilgileri korurken özellik setinin boyutlarını küçültmeye çalışır. Bir sınıfın her bir kümesinin etrafında bir karar sınırı bulmaya çalışır. Daha sonra kümeler birbirinden mümkün olduğunca ayrı olacak ve küme içindeki bireysel öğeler kümenin merkezine mümkün olduğunca yakın olacak şekilde veri noktalarını yeni boyutlara yansıtır. Yeni boyutlar, kümeler arasındaki mesafeyi en üst düzeye çıkarma ve bir küme içindeki veri noktaları ile bunların merkezleri arasındaki mesafeyi en aza indirmesine göre sıralanır. Bu yeni boyutlar, özellik setinin doğrusal ayırıcılarını oluşturur.

Öğrenme oranı (learning rate) seçimi uygun sonuca ulaşabilmek için önemlidir. Öğrenme oranı iyi seçilmemesi durumunda eğitilmek istenen ağ yapısı en iyi çözümü vermeyebilir veya en iyi çözüme hiçbir zaman yaklaşamaz (Yılmaz ve Kaya, 2021). Şekil 3.5.'te öğrenme oranının seviyelerinin grafik üzerinde gösterilmiştir.



Şekil 3.5. Öğrenme oranı seviyeleri (Yılmaz ve Kaya, 2021).

3.2.6. Hata matrisi (confusion matrix) ve F-skoru

Hata matrisi, bir sınıflandırma algoritmasının performansını tanımlamak için kullanılan değerlerin tablo haline getirilmesidir. Bir hata matrisi, bir sınıflandırma algoritmasının performansını görselleştirir ve özetler (Singh ve ark., 2021). İkili sınıflandırıcı için örnek hata matrisi Şekil 3.6.'da gösterilmiştir. Tez çalışmasının sonucunda elde edilen verilerin yorumlanması için hata matrislerinden yararlanılmıştır.

Gerçek değerler	Hasarsız	Doğru pozitif	Yanlış negatif
	Hasarlı	Yanlış pozitif	Doğru negatif
		Hasarsız	Hasarlı
		Tahmin değerleri	

Şekil 3.6. Hata matrisi

Hata matrisleri dört temel özellikten oluşur. Bu dört özellik sayısal değerler almaktadır ve sayısal değerler ile algoritmanın doğruluğu, kesinliği ve f-skor değerleri hesaplanabilmektedir.

- Doğru pozitifler (DP): Hasarsız sınıfa ait doğru tahmin edilen örnekler.
- Doğru negatifler (DN): Hasarlı sınıfa ait olarak doğru tahmin edilen örnekler.
- Yanlış pozitifler (YP): Hasarlı sınıftan olan, hasarsız olarak tahmin edilen örnekler.
- Yanlış negatifler (YN): Gerçek sınıfı hasarsız olan fakat hasarlı olarak tahmin edilen örnekler.

Doğruluk değeri aşağıdaki eşitlik kullanılarak (Denklem 3.1) ifade edilmiştir.

$$Doğruluk = \frac{DP+DN}{DP+YP+DN+YN} \quad (3.1)$$

Kesinlik değeri aşağıdaki eşitlik kullanılarak (Denklem 3.2) ifade edilmiştir.

$$Kesinlik = \frac{DP}{DP+YP} \quad (3.2)$$

Hassasiyet değeri aşağıdaki eşitlik kullanılarak (Denklem 3.3) ifade edilmiştir.


$$Hassasiyet = \frac{DP}{DP+YN} \quad (3.2)$$

F-skoru değeri aşağıdaki eşitlik kullanılarak (Denklem 3.4) ifade edilmiştir.

$$F - skoru = \frac{2 * Kesinlik * Hassasiyet}{Kesinlik + Hassasiyet} \quad (3.4)$$

Önerilen yöntemin başarımlar kriterleri doğruluk, kesinlik ve F-skoru oranlarına dayalı olarak yapılmıştır.

Şekil 3.7.'de hasarlı hasarsız görüntü tespiti için yapılacak, önceden eğitilmiş evrimsel sinir ağı modelinin seçim aşamaları gösterilmektedir.



Şekil 3.7. Hasarlı hasarsız veri tespiti ve eğitim modelinin seçim aşamaları

BÖLÜM 4. ARAŞTIRMA BULGULARI

4.1. Uygulama Sonuçları

Tez çalışmasının yapıldığı görüntü verilerinin eğitimi için önceden eğitilmiş evrişimsel sinir ağlarından olan ResNet50, AlexNet, VGG19 ve Densenet169 görüntü veri tabanları kullanılmıştır. Bu veri tabanları ve sınıflandırıcılar kullanılarak oluşturulan başarı oranları ve hata matrisleri ayrı ayrı gösterilmiştir.

Her bir ağın çalışması esnasında önceden eğitilmiş evrişimsel sinir ağlarında yedi farklı sınıflandırıcı kullanılmıştır. Her model 10 katlı çapraz doğrulama yapılması için veriler on parçaya ayrılmış ve oluşturulan on veri seti için çıkan sonuçlarda başarı oranları karşılaştırılmıştır. ResNet50, AlexNet, VGG19 ve Densenet169 evrişimsel sinir ağlarında başarı oranı en iyi sınıflandırıcılar için hata matrisleri gösterilmiştir.

Hata matrislerinin değerleriyle kesinlik, hassasiyet ve F-skoru oranları hesaplanarak en iyi eğitim modelini oluşturabilen veri tabanı bulunmuştur. Verilerle elde edilen sonuçlara göre en başarılı evrişimsel sinir ağı linear_model.SGDClassifier sınıflandırıcısında ResNet50'dir.


4.1.1. Eğitim modellerinin uygulama sonuçları

ResNet50, AlexNet, VGG19 ve Densenet169 evrişimsel sinir ağları ve sınıflandırıcılar kullanılarak oluşturulan modellerin başarı oranları Tablo 4.1.'de gösterilmiştir.

Tablo 4.1. Oluşturulan eğitim modellerinin başarı oranları

Model	Sınıflandırıcı	Başarı oranı (%)
AlexNet	discriminant_analysis.LinearDiscriminantAnalysis	62
	ensemble.Bagging	59
	linear_model.SGDClassifier	65
	naiveBayes.multinomialNB	64
	neural_network.MultiLayerPerceptron	45
	svm.NuSVC	67
	svm.SVM	58
DenseNet169	discriminant_analysis.LinearDiscriminantAnalysis	75
	ensemble.Bagging	59
	linear_model.SGDClassifier	62
	naiveBayes.multinomialNB	69
	neural_network.MultiLayerPerceptron	69
	svm.NuSVC	67
	svm.SVM	60
Resnet50	discriminant_analysis.LinearDiscriminantAnalysis	75
	ensemble.Bagging	77
	linear_model.SGDClassifier	78
	naiveBayes.multinomialNB	77
	neural_network.MultiLayerPerceptron	77
	svm.NuSVC	76
	svm.SVM	77
VGG19	discriminant_analysis.LinearDiscriminantAnalysis	66
	ensemble.Bagging	73
	linear_model.SGDClassifier	70
	naiveBayes.multinomialNB	73
	neural_network.MultiLayerPerceptron	74
	svm.NuSVC	73
	svm.SVM	75

ResNet50, AlexNet, VGG19 ve Densenet169 evrişimsel sinir ağıları kullanılarak oluşturulan modellerin sonucunda ortaya çıkan hata matrisleri Şekil 4.1.'de gösterilmiştir.



Şekil 4.1. Eğitim modelleri için hata matrislerinin toplam değerleri

4.2. Uygulama Sonuçlarına Göre F-Skorlarının Hesaplanması

Yapay evrişimsel sinir ağıları kullanılarak oluşturulan hata matrislerinin ortalama değerleri ile kesinlik, hassasiyet ve F-skoru değerleri hesaplanmıştır. Tablo 4.2.'de ResNet50, AlexNet, VGG19 ve Densenet169 modelleri için hesaplanan değerler özetlenmiştir.

Tablo 4.2. Eğitim modeline göre F-skorları

Model	Kesinlik %	Hassasiyet %	F Skoru %
AlexNet	67,35	66,00	66,67
Densenet169	77,78	70,00	73,68
ResNet50	75,93	82,00	78,85
VGG19	70,49	86,00	77,48


Veri tabanında yer alan görüntüye ilişkin sonuçların ortalamaları Tablo 4.5.'te görülmektedir. Elde edilen sonuçlara göre, en başarılı model %78,85 F-skor değeri ile ResNet50 olarak ortaya çıkmıştır. Resnet50 ile elde edilen kesinlik, hassasiyet ve F-skor değerleri sırasıyla %75,93 - %82,00 - %78,85 olarak belirlenmiştir. Aynı değerler AlexNet için %67,35 - %66,00 - %66,67 Densenet169 için %77,78 - %70,00- %73,68 ve VGG19 için %70,49 - %86,00 - %77,48 olarak hesaplanmıştır.

ResNet50 modeli eğitim için seçilmiştir. Yoğunluk haritalarına bakılarak istenilen kararı verirken verinin hangi piksel bölgelerine yoğunlaştığı incelenmiştir.


4.2.1. ResNet50 eğitim modeline göre oluşan yoğunluk haritaları

Seçilen model ile görüntü verilerinde istenilen özelliği çıkarması için görüntünün hangi noktalarına yoğunlaştığını anlayabilmek için en yoğun verilerin sıcak renklerle gösterildiği yoğunluk haritalardan (heat maps) yararlanılmaktadır.

ResNet50 modeli ile eğitilen veriler içindeki gerçek veriler ve yoğunluk haritalarının örnekleri aşağıdaki şekillerde gösterilmektedir. Şekil 4.2.'de hasarsız veri ve yoğunluk haritası örneği, Şekil 4.3.'te hasarlı veri ve aktivasyon haritası örneği gösterilmektedir.



Şekil 4.2. Hasarsız veri örneği ve yoğunluk haritası örneği



Şekil 4.3. Hasarlı veri örneği ve yoğunluk haritası örneği

BÖLÜM 5. TARTIŞMA VE SONUÇ

Uçak parçalarındaki hasar tespitinde yaygın olarak uygulanan ve tahribatsız muayene yöntemlerinden biri olan X-ışını görüntülemesinde parçaların radyografileri elde edilir. Görüntüleme sistemine bağlı olarak film üzerinde ya da dijital olarak elde edilen bu radyografiler, konusunda uzmanlaşan kişiler tarafından incelenerek hasar tespitinin yapılmasında kullanılır. Bu şekilde yapılan hasar tespitinde uzman personel eğitimi ve tecrübe gereksiniminin yanı sıra insan faktöründen kaynaklanan öznellik gibi durumlardan ötürü bu yöntemlerin bilgisayar temelli çözümlerle daha pratik ve hassas düzeye getirilebilmesi amaçlanabilir. Bu çalışmada X-ışını görüntüleri derin öğrenmeyle eğitilen görüntü işleme algoritmaları kullanılarak incelenmiştir. Yapay sinir ağlarının eğitilmesi çok fazla veri ve uzun zaman gerektirdiğinden eldeki verilerin analizi için transfer öğrenmesi methodologyyla daha önceden eğitilmiş ResNet50, AlexNet, DenseNet169 ve VGG19 ağları kullanılmıştır. Bu ağ modellerinde bulunan sonuçlara göre F skorları sırasıyla %78,85, %66,67, %73,68 ve %77,48'dir. Görüntülerde tespit edilmesi istenen hasarları en yüksek başarı oranıyla analiz eden ResNet50 evrimsel sinir ağı modelinin karar sürecinde ağırlık verdiği pikselleri gösteren yoğunluk haritaları da gösterilmiştir. Ayrıca bu çalışma askeri uçaklardaki hasar tespitinde görüntü işleme ve makine öğrenmesi kullanılması bakımından literatürde ulusal olarak yapılan ilk çalışmadır.

Radyografilerin incelenmesinde uzman personelin yetişebilmesi için 3 aşamalı eğitimden geçmesi gerekmektedir. Çalışan personel seviye 1 için 3 ay ilgili görevde çalışmalı ve 60 saat eğitim almalıdır, sonrasında seviye 2 için 9 ay ilgili görevde çalışmalı ve 80 saat eğitim almalıdır, daha sonrasında seviye 3 için 18 ay ilgili görevde çalıştığını belgelemeli ve 40 saat eğitim almalıdır. Bunlarla birlikte istenen fiziksel yeterlilik koşullarını sağlamalıdır (TS EN 9012 Tahribatsız Muayene Personeli Dokümanları, 2022). Ayrıca uzman personelin 15 dakikada incelediği görüntüler için görüntü işleme algoritmaları ile 1 dakikadan kısa sürede sonuca

ulařabilmektedir. Hem eęitim s¼reci hem de alıřma zamanındaki s¼re g¼z ¼n¼ne alındıęında g¼r¼nt¼ iřleme algoritmaları geliřtirilerek daha iyi sonularla kullanılması, hata tespiti iin s¼re ve maliyet aısından b¼y¼k verim saęlayacaktır.

B¼l¼m 2.4'te literat¼rde yapılan benzer alıřmaların detayları ve bu alıřmayla olan benzerlik ve farklılıkları anlatılmıřtır. ¼rneęin Tablo 2.4.'te de g¼sterilen bazı alıřmalara kıyasla bu tezde kullanılan g¼r¼nt¼ sayısı miktar olarak olduka d¼ř¼kt¼r. Herhangi bir derin ¼ęrenme algoritmasını eęitmek iin ise binlerce veri gereklidir. K¼¼k bir veri setiyle evriřimsel sinir aęı geliřtirilemeyecek olmasından dolayı ¼nceden eęitilmiř evriřimsel sinir aęı modelleri (ResNet50, AlexNet, VGG19 ve DenseNet169) bu alıřmadaki hasar bulma amacı doęrultusunda modifiye edilerek transfer ¼ęrenimi yapılmıřtır. B¼ylelikle model geliřtirmek iin gerekli olan ok fazla miktarda veri, zaman, beceri ve teknik kaynaklar olmadan da eldeki k¼¼k veri setiyle de kullanılabilecek ve en iyi sonucu veren model bulunmaya alıřılmıřtır. Bu model gelecekte daha fazla verinin eklenmesi durumunda geliřtirilmeye aıktır ve bu haliyle pratikte kullanıldıęında hasar bulmada tam otomasyon saęlayamasa bile uzman personelin hasar tespiti yapmasına yardımcı olacak bir karar destek sistemi olarak da d¼ř¼n¼lebilir.

KAYNAKLAR

- Alves, F. R. V., Vieira, R. P. M., Catarino, P. M. M. C. 2020. Visualizing the Newtons Fractal from the Recurring Linear Sequence with Google Colab: An Example of Brazil X Portugal Research. *International Electronic Journal of Mathematics Education*, 15(3).
- Anık, S., Anık, E.S. ve Vural, M. 2000. 1000 Soruda Kaynak Teknolojisi El Kitabı, Birsen Yayınevi, 600-629.
- Atalı, G., Özkan, S. S., Karayel, D. 2016. Morfolojik görüntü işleme tekniği ile yapay sinir ağlarında görüntü tahribat analizi. *Akademik Platform Mühendislik Ve Fen Bilimleri Dergisi*, 4(1).
- Cao, P., Zhang, S., Tang, J. 2018. Preprocessing-free gear fault diagnosis using small datasets with deep convolutional neural network-based transfer learning. *Ieee Access*, 6: 26241-26253.
- Caturano, G., Cavaccini, G., Ciliberto, A., Pianese, V., Fazio, R. 2009. Liquid penetrant testing: industrial process. In *Comm. SIMAI Congress*, Vol. 3, 319-1.
- Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C. J., Kadoury, S., Tang, A. 2017. Deep Learning: A Primer for Radiologists. *RadioGraphics*. 37 (7): 2113–31.
- Chen, Z. H., Juang, J. C. 2020. AE-RTISNet: aeronautics engine radiographic testing inspection system net with an improved fast region-based convolutional neural network framework. *Applied Sciences*, 10(23): 8718.
- Chollet, F. 2017. Deep learning with Python, Manning Publications, 1-384.
- Çan, Z. 2021. Otomasyon sistemlerinde görüntü işleme tekniklerini kullanan ürün tanımı uygulaması. *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Bilişim Sistemleri Mühendisliği Bölümü, Yüksek Lisans Tezi*.
- Deng, L., Yu, D. 2014. Deep learning: Methods and Applications. *Foundations and Trends in Signal Processing*, 7(3–4): 197-387.
- Dey, S. 2018. Hands-On Image Processing with Python, Packt, 1-492.
- Doğru, A. 2014. Uçak Gövde ve Kanatlarında Oluşan Hasarların Tahribatsız Muayene Yöntemleri ile Tesbiti. *Celal Bayar Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Bölümü, Yüksek Lisans Tezi*.
- Er, M. B. 2020. Önceden Eğitilmiş Derin Ağlar ile Göğüs Röntgeni Görüntüleri Kullanarak Pnömoni Sınıflandırılması. *Konya Mühendislik Bilimleri Dergisi*, 9(1), 193-204.

- Federal Aviation Administration, 2018. Aviation Maintenance Technician Handbook – General. İçinde: Chapter 10 Inspection Concepts and Techniques, 391-430.
- Fujiyoshi, H., Hirakawa, T., Yamashita, T. 2019. Deep learning-based image recognition for autonomous driving. *IATSS Research*, 43(4): 244-252.
- Fukushima, K. 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4): 193-202.
- Furioso, A. 2022, <https://www.antoniofurioso.com/artificial-intelligence/convolutional-neural-network-what-it-is-and-how-it-works>, Erişim Tarihi: 15.03.2022.
- Hinton, G. E., Osindero, S., Teh, Y. W. 2006. A fast learning algorithm for deep belief nets. *Neural computation*, 18(7): 1527-1554.
- Hoang, N. D. 2018. Detection of surface crack in building structures using image processing technique with an improved Otsu method for image thresholding. *Advances in Civil Engineering*.
- García-Martín, J., Gómez-Gil, J., Vázquez-Sánchez, E. 2011. Non-destructive techniques based on eddy current testing. *Sensors*, 11(3): 2525-2565.
- Gayer, A., Saya, A., Shiloh, A. 1990. Automatic recognition of welding defects in real-time radiography. *Ndt International*, 23(3): 131-136.
- Gollapudi, S. 2016. *Practical Machine Learning*, Packt, 1-468.
- Gong, Y., Shao, H., Luo, J., Li, Z. 2020. A deep transfer learning model for inclusion defect detection of aeronautics composite materials. *Composite structures*, 252: 112681.
- Gong, Y., Luo, J., Shao, H., Li, Z. 2022. A transfer learning object detection model for defects detection in X-ray images of spacecraft composite structures. *Composite Structures*, 284: 115136.
- Gonzalez, R. C., Woods, R. E. 2006. *Digital image processing*, Dorling Kindersley, 1-578.
- Goodfellow, I., Bengio, Y., Courville, A. 2017. *Deep Learning (Adaptive Computation And Machine Learning Series)*. İçinde: Chapter 9 Convolutional Networks. The MIT Press, 321-359.
- Güngörmüş, A. 2020. Görüntü işleme teknikleri kullanarak petek üzerindeki arı larvasının konumunun ve özelliklerinin tespiti. Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Bölümü, Yüksek Lisans Tezi.
- 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.
- Isola, P., Zhu, J. Y., Zhou, T., Efros, A. A. 2017. Image-to-image translation with conditional adversarial networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Hawaii. 1125-1134.

- Jiménez-Sánchez, A., Kazi, A., Albarqouni, S., Kirchhoff, C., Biberthaler, P., Navab, N., ... & Mateus, D. 2020. Precise proximal femur fracture classification for interactive training and surgical planning. *International journal of computer assisted radiology and surgery*, 15(5), 847-857.
- Johnson, S. 2006. *Stephen Johnson on Digital Photography*, O'Reilly & Associates, 1-320.
- Koch, C., Georgieva, K., Kasireddy, V., Akinci, B. and Fieguth, P., 2015. A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Advanced Engineering Informatics*, 29(2): 196-210.
- Korkmaz, Ö. E. 2010. Uçaklarda kullanılan alüminyum malzemelerdeki korozyonun incelenmesi, önlenmesi ve tahribatsız muayene ile tespiti. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Metalürji ve Malzeme Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Kroque, J. D., Cheng, K. V., Hwang, K. M., Toogood, P., Meinberg, E. G., Geiger, E. J., ... & Pedroia, V. 2020. Automatic hip fracture identification and functional subclassification with deep learning. *Radiology. Artificial intelligence*, 2(2).
- 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.
- Lu, Q. Y., Wong, C. H. 2017. Applications of non-destructive testing techniques for post-process control of additively manufactured parts. *Virtual and Physical Prototyping*, 12(4): 301-321.
- Matzkanin, G. A. 2006. Selecting a nondestructive testing method: Visual inspection. *Ammtiac Quarterly*, 1(3): 7-10.
- 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.
- Michie, D., Spiegelhalter, D. J., Taylor, C. C. 1994. *Machine learning, neural and statistical classification*, Ellis Horwood Limited, 1-266.
- Molnar, C., 2020. *Interpretable Machine Learning*, Lulu.com, 1-318.
- Ngiam, J., Chen, Z., Chia, D., Koh, P., Le, Q., Ng, A. 2010. Tiled convolutional neural networks. *Advances in neural information processing systems*, 23.
- Olivas, E. S., Guerrero, J. D. M., Martinez-Sober, M., Magdalena-Benedito, J. R., Serrano, L. (Eds.). 2009. *Handbook of research on machine learning applications and trends: Algorithms, methods, and techniques: Algorithms, methods, and techniques*, IGI global, 1-852.
- Onursal, M. 2010. Uçaklarda kullanılan metal malzemelere uygulanan tahribatsız muayeneler. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Metalürji ve Malzeme Mühendisliği Bölümü, Yüksek Lisans Tezi.

- Özgenel, C.F. 2019. Concrete crack images for classification (Version 2). <https://data.mendeley.com/datasets/5y9wdsg2zt/2>, Erişim Tarihi: 06.05.22
- Öztemel, E. 2003. Yapay Sinir Ağları, 1. Baskı, Papatya Yayıncılık, 1-232.
- Öztürk, G. 2020. Derin evrimsel sinir ağları kullanılarak araç, insan ve trafik işaretlerinin tanınması. Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi.
- Pan, S.J., Yang, Q. 2009. A survey on transfer learning. IEEE Transactions on knowledge and data engineering, 22(10): 1345-1359.
- Petrou, M.M., Petrou, C. 2010. Image processing: The Fundamentals, 2nd Edition, Wiley, 1-44.
- Polat, Ç., Karaman, O., Karaman, C., Korkmaz, G., Balcı, M. C., & Kelek, S. E. 2021. COVID-19 diagnosis from chest X-ray images using transfer learning: Enhanced performance by debiasing dataloader. Journal of X-ray Science and Technology, 29(1), 19-36.
- Raschka, S., Mirjalili, V. 2017. Python machine learning: Machine learning and deep learning with python. Scikit-Learn, and TensorFlow, 2nd Edition, Packt, 10: 3175783.
- Rosenblatt, F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, 65(6): 386-408.
- Ruder, S. 2017. Transfer Learning - Machine Learning's Next Frontier. <https://ruder.io/transfer-learning/> Erişim Tarihi: 10.07.22.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C. 2015. Imagenet large scale visual recognition challenge. International journal of computer vision, 115(3): 211-252.
- Sarkar, D. 2018. A Comprehensive Hands-on Guide to Transfer Learning with Real-World Applications in Deep Learning. <https://towardsdatascience.com/a-comprehensive-hands-on-guide-to-transfer-learning-with-real-world-applications-in-deep-learning-212bf3b2f27a>, Erişim Tarihi: 10.07.22.
- Sarkar, D., Bali, R. and Sharma, T. 2018. Practical machine learning with Python. A Problem-Solvers Guide To Building Real-World Intelligent Systems, 1st ed. Edition, Apress Berkeley, 1-530.
- Sekhar, S.M., Kashyap, G., Bhansali, A., Singh, K. 2021. Dysarthric-speech detection using transfer learning with convolutional neural networks. ICT Express, 8(1): 61-64.
- Sevgi, A. (2020). Batarya elektrikli aracın derin öğrenme ve görüntü işleme ile otonom denetiminin gerçekleştirilmesi. Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Mekatronik Mühendisliği Bölümü, Yüksek Lisans Tezi.
- 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.

- Shull, P.J. 2002. Nondestructive Evaluation: Theory, Techniques, and Applications, 1st Edition, CRC Press, 1-876.
- Singh, K. K., Elhoseny, M., Singh, A., Elngar, A. A. (Eds.). 2021. Machine Learning and the Internet of Medical Things in Healthcare, Academic Press, 1-263.
- Sivakumar, P., Meenakshi, S. 2016. A review on image segmentation techniques. Int. J. Adv. Res. Comput. Eng. Technol, 5(3): 641-647.
- Şahin, M.Ç. 2021. Dijital odyometri görüntülerinin görüntü işleme ile analizi ve yorumlanması. İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Tyystjärvi, T., Virkkunen, I., Fridolf, P., Rosell, A. and Barsoum, Z. 2022. Automated defect detection in digital radiography of aerospace welds using deep learning. Welding in the World, 66(4): 643-671.
- Uçak Bakım - Uçaklarda tahribatsız muayeneler (Kod: 525MT0004), 2012, Milli Eğitim Bakanlığı, Ankara, 1-89.
- Wang, X., Wong, B.S., Tan, C., Tui, C.G. 2011. Automated crack detection for digital radiography aircraft wing inspection. Research in Nondestructive Evaluation, 22(2): 105-127.
- Wang, X., Wong, B.S., Tui, C.G., Khoo, K.P., Foo, F. 2008. Real-time radiographic non-destructive inspection for aircraft maintenance. 17th World Conference on Nondestructive Testing, Shanghai, China, 25: 28.
- Wong, B.S., Wang, X., Koh, C.M., Tui, C.G., Tan, C., Xu, J. 2011. Crack detection using image processing techniques for radiographic inspection of aircraft wing spar. Insight-Non-Destructive Testing and Condition Monitoring, 53(10): 552-556.
- Wu, J. 2017. Introduction to convolutional neural networks. National Key Lab for Novel Software Technology, Nanjing University, China, 5(23): 495.
- Wu, W., Sun, Q. 2018. Applying machine learning to accelerate new materials development. SCIENTIA SINICA Physica, Mechanica & Astronomica, 48(10): 107001.
- Xiao, J., Wang, J., Cao, S., Li, B. 2020. Application of a novel and improved VGG-19 network in the detection of workers wearing masks. Journal of Physics: Conference Series, 1518(1): 012041.
- Yılmaz, A., Kaya, U. 2021. Derin Öğrenme, Kodlab Yayın Dağıtım Yazılım Ltd. Şti., 3.Baskı 1-144.
- Yu, D., Deng, L. 2010. Deep learning and its applications to signal and information processing. IEEE Signal Processing Magazine, 28(1): 145-154.
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., He, Q. 2020. A comprehensive survey on transfer learning. Proceedings of the IEEE, 109(1): 43-76.
- Zou, J., Huss, M., Abid, A., Mohammadi, P., Torkamani, A., Telenti, A. 2019. A primer on deep learning in genomics. Nature Genetics, 51(1): 12-18.

www.tse.org.tr/IcerikDetay?ID=118&ParentID=143, Eriřim Tarihi: 27.09.2022



ÖZGEÇMİŞ

Adı Soyadı : Safa ERDEM

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	Devam ediyor
Lisans	Eskişehir Osmangazi Üniversitesi / Mühendislik-Mimarlık Fakültesi / Endüstri Mühendisliği	2014
Lise	Düzce Anadolu Öğretmen Lisesi	2008

İŞ DENEYİMİ

Yıl	Yer	Görev
2022-Halen	MSB-Tersaneler Genel Müdürlüğü	Endüstri Mühendisi
2019-2022	MSB-1.Hava Bakım Fabrika Müdürlüğü	Endüstri Mühendisi
2016-2019	Anlas Anadolu Lastik A.Ş	Endüstri Mühendisi

YABANCI DİL

İngilizce