



A deep learning-based approach for defect detection in powder bed fusion additive manufacturing using transfer learning

Burhan Duman¹ , Koray Özsoy^{2*} 

¹Computer Engineering Department, Isparta University of Applied Sciences, Isparta, 32100, Turkey

²Electric and Energy Department, Isparta University of Applied Sciences, Isparta, 32400, Turkey

Highlights:

- In-situ monitoring of images in the powder bed
- Learning transfer deep learning for defect detection
- Detection and classification of the defect using a convolutional neural network

Keywords:

- Additive Manufacturing
- Powder Bed Fusion
- Deep Learning
- Detection Defect
- Transfer Learning

Graphical/Tabular Abstract

Metal alloys are manufactured using powder bed fusion, a camera captures each layer of the manufactured part, and the normal or defect of the manufacturing on the layer is detected using the learning transfer.

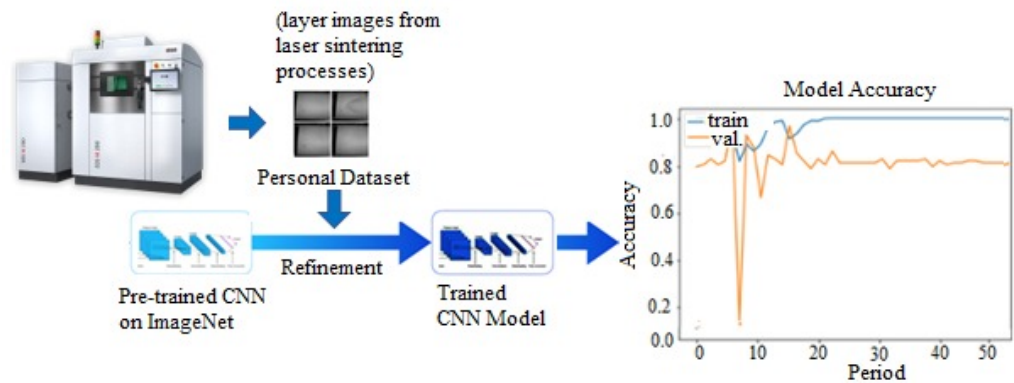


Figure A. Schematic diagram of the defect detection in powder bed fusion using transfer learning

Article Info:

Research Article
Received: 29.01.2021
Accepted: 06.06.2021

DOI:

10.17341/gazimmfd.870436

Correspondence:

Author: Koray Özsoy
e-mail:
korayozsoy@isparta.edu.tr
phone: +90 246 211 1749

Purpose: The learning transfer method is a deep learning method applied in models trained with lower image data sets. The powder bed fusion (PBF) additive manufacturing is the technology that enables directly physical models to be obtained using metal alloy materials. In the study, images were captured using each layer by a camera in PBF additive manufacturing, and a dataset was obtained. Later, defect control was performed using deep learning algorithms.

Theory and Methods:

A total of 1484 images were captured in powder bed fusion EOS M290 device at 1280x1024 pixels, as before and after exposure. Images are divided into two classifications as normal and defect in the layer. The 793 of the images captured are normal, and 691 are defect images. In the learning transfer method, pre-trained VGG16, DenseNet and Inception V3 pre-learning CNN models on ImageNet database were tested respectively. The performance of the trained models with the dataset explicitly used was also compared with the test dataset.

Results:

In the classification performed according to normal or defect in the manufacturing layer, the performance values was obtained the Inception V3 model with 64%, the DenseNet model with 74% and the VGG-16 model with 88,3% highest accuracy. The results show that the loss and classification accuracy values of the VGG-16 model, the model has a successful classification performance and is suitable for error detection.

Conclusion:

In this study, the deep learning method is a novel application in powder bed fusion additive manufacturing. It is concluded that the learning transfer method can be used in the detection of defect powder bed fusion manufacturing processes.



Toz yatak füzyon birleştirme eklemeli imalatta kusur tespiti için öğrenme aktarımı kullanan derin öğrenme tabanlı bir yaklaşım

Burhan Duman¹, Koray Özsoy^{2*}

¹Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, 32100 Çünür Isparta, Türkiye

²Isparta Uygulamalı Bilimler Üniversitesi, Senirkent MYO, Elektrik ve Enerji Bölümü, 32400 Senirkent Isparta, Türkiye

Ö N E Ç İ K A N L A R

- Toz yatağında görüntülerin yerinde izlenmesi
- Kusur tespiti için öğrenme aktarımlı derin öğrenme
- Evrimsel sinir ağı kullanarak kusurun tespiti ve sınıflandırılması

Makale Bilgileri

Araştırma Makalesi
Geliş: 29.01.2021
Kabul: 06.06.2021

DOI:

10.17341/gazimmfd.870436

Anahtar Kelimeler:

Eklemeli imalat,
toz yatak füzyon,
derin öğrenme,
kusur tespiti,
öğrenme aktarımı

ÖZ

Günümüzde toz yatak füzyon birleştirme (TYB) metal eklemeli imalat, karmaşık geometri parça imalatında sıklıkla tercih edilmesine rağmen, parça imalat süreçlerinin gerçek zamanlı izlenmesi yeterli düzeyde değildir. Bu nedenle makine kontrol sistemi büyük ölçüde açık döngü olarak kalmaktadır. Bazı metal eklemeli imalat makineleri toz yatağının izlenmesini görüntülerle sunarken, toz yatağı katmanında oluşabilecek kusurların otomatik tespiti ve kontrol sistemini uyarıcı yeteneğinin olduğuna rastlanmamıştır. Çalışmada, herhangi bir TYB metal eklemeli imalat makinesinde gerçek zamanlı kontrol sisteminin bir bileşeni olma potansiyeline sahip toz yatağı görüntülerinin yerinde izlenmesi ve kusurların tespiti için makine öğrenmesi temelli örnek bir yaklaşım sunulmuştur. Makine öğrenmesinin alt alanlarından olan derin öğrenme yöntemi kullanılarak, işlemin bir katmanının oluşturulmasında meydana gelebilecek kusurları tespitine yönelik sınıflandırma yapılmıştır. Kusurları algılama ve sınıflandırma işlemi evrimsel sinir ağı modeli kullanılarak yerine getirilmiştir. Modelin eğitimi ve performansı için veri seti, EOS M290 makinesinde imal edilmiş örnek bir üç boyutlu yapının fotoğrafları ile oluşturulmuştur. VGG-16, InceptionV3 ve DenseNet ön öğrenmeli modellerinden transfer öğrenimi yapılarak en iyi performans %88,3 doğruluk değeri ile VGG-16 modelinde elde edilmiştir.

A deep learning-based approach for defect detection in powder bed fusion additive manufacturing using transfer learning

H I G H L I G H T S

- In-situ monitoring of images in the powder bed
- Learning transfer deep learning for defect detection
- Detection and classification of the defect using convolutional neural network

Article Info

Research Article
Received: 29.01.2021
Accepted: 06.06.2021

DOI:

10.17341/gazimmfd.870436

Keywords:

Additive manufacturing,
powder bed fusion,
deep learning,
detection defect,
transfer learning

ABSTRACT

Although powder bed fusion joining (TYB) metal additive manufacturing is frequently preferred in the production of complex geometry parts today, real-time monitoring of part manufacturing processes is insufficient. Therefore, the machine control system remains largely open loop. While some metal additive manufacturing machines present the powder bed monitoring with images, it has not been found that they can automatically detect the defects that may occur in the powder bed layer and stimulate the control system. In the study, an exemplary machine learning-based approach is presented for on-site monitoring and defect detection of powder bed images, which can be a component of a real-time control system in any TYB metal additive manufacturing machine. Using the deep learning method, which is one of the subfields of machine learning, a classification was made to detect the defects that may occur in creating a layer of the process. Detection and classification of defects were carried out using the convolutional neural networks model. The data set for training and performance of the model was created with photographs of a three-dimensional sample structure manufactured on the EOS M290 machine. The best performance was obtained in the VGG-16 model with 88.3% accuracy by performing transfer learning from VGG-16, Inception V3, and DenseNet pre-learning models.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : burhanduman@isparta.edu.tr, *korayozsoy@isparta.edu.tr /

Tel: +90 246 211 1749


1. GİRİŞ (INTRODUCTION)

Günümüzde eklemeli imalat (Eİ) yöntemlerinin endüstriyel uygulamalarda artan üretim etkisi gözlenmiştir [1]. Başlangıçta prototip imal etmek için ortaya çıkan bu teknoloji daha sonraları son kullanım parçaları imal etmek için kullanılmıştır. En yaygın eklemeli imalat yöntemleri; Stereolitografi (SLA), Ergiterek Yığılma ile Modelleme (FDM), Üç Boyutlu Yazıcı (3DP), Seçmeli Lazer Sinterleme (SLS) ve Seçmeli Lazer Ergitme (SLM), Elektron Işınli Ergitme (EBM) gibi yöntemlerdir. Bu teknikler ile sıvı reçineden, polimerlerden, polimer tozlarından ve metal tozlarından 3 Boyutlu(3B) fiziksel parçalar imal edilebilmektedir [2, 3]. Eklemeli imalat alandaki güncel gelişmeler ile birlikte tıp, otomotiv, havacılık ve savunma sanayisi gibi endüstrinin önde gelen dalları için yeni perspektifler sunan eklemeli imalat tekniklerine olan ilgi artmaktadır [4, 5]. “Katman katman” üretim yöntemi sayesinde seçici lazer sinterleme/ergitme ve elektron ışınli ergitme gibi Toz Yatak Füzyon Besleme (TYB) yöntemini kullanan cihazların, geleneksel yöntemler ile üretilemeyen karmaşık şekiller ve geometrileri üretilebilir kılması ile tasarım serbestliği kazanılmıştır [4, 6].

TYB eklemeli imalat sürecinin büyük gelişimine rağmen son yıllarda sektörde büyük bir atılım henüz gerçekleştirilmemiştir. Bunun sebebi, eklemeli imalat teknolojilerinde yetişmiş insan gücünün yetersiz olması, standartlaşmış tasarım, analiz ve test metodlarının yetersizliği, kazanım maliyetlerinin yüksek olmasıdır [7]. TYB eklemeli imalat sürecinde, ürünün kalitesini etkileyen birçok girdi parametresi bulunmaktadır [8]. Eklemeli imalat sürecinde parça kalitesini etkileyebilecek 50'den fazla

parametre belirlenmiştir. Eklemeli imalat sürecinde, kalıntı gerilme, toz besleme eksikliği, topaklanma, gözeneklilik, çatlama gibi kusurlar parçanın mekanik özelliklerini olumsuz yönde etkilemektedir [9]. Kusurlar genellikle parça imalatı işleminden sonra incelenmektedir. Örneğin; parçadaki gözeneklilik, bilgisayarlı tomografi (BT), Arşimet yöntemi veya metalografik görüntüleme kullanılarak ölçülmektedir. Bununla birlikte katmanlara ayrılma, sarkan yapılar, uygun olmayan destekler ve artık gerilmeler, süreç sırasında kritik kusurlardır ve bu nedenle izlenmesi önem arz etmektedir [10, 11]. Gerçek zamanlı süreçlerin yerinde izleme uygulamaları, özellikle metal alaşımlı malzeme ile yüksek kalite parça üretiminde oldukça gereklidir. Bu nedenle, eklemeli imalat uygulamalarında her bir katmandaki ısıl ve yüzey kusur ile ilgili sorunların çözümüne yönelik zamana bağlı değişimlerin gerçek zamanlı izlenmesi yenilikçi bir yaklaşımdır.

Parça imal edildikten sonra kalite kontrol, imalat sektöründe çok önemli bir husustur. Günümüzde bir ürünün kalitesini veya bir sürecin sonucunu değerlendirmek için çeşitli yaklaşımlar kullanılmaktadır. Bu yaklaşımlardan birisi de muayenedir. Bir yüzeydeki/hacimdeki bir kusuru tanımlamak için tahribatlı veya tahribatsız olarak muayene yapılmaktadır. Görsel tabanlı yöntem, boya penetrant muayenesi, radyografi, ultrasonik test, girdap akımı yaklaşımı ve termografi tahribatsız muayeneler sınıfına girmektedir. Görsel tabanlı yaklaşım kusur tespiti için endüstrideki en yaygın prosedürlere biridir. Endüstriyel uygulamalarda uygun bir sınıflandırma için, olası hata türlerinin iyi tasarlanmış veri tabanlarına ihtiyaç duyulmaktadır. Ancak, bir sınıflandırıcı için bu kadar genel ve kapsamlı bir veri tabanı oluşturmak, operasyon



Şekil 1. Kusur türlerin görüntüsü a) görünebilir kusurlar b) belirgin kusurlar
(Image of the defective types a) visible defects b) obvious defects)

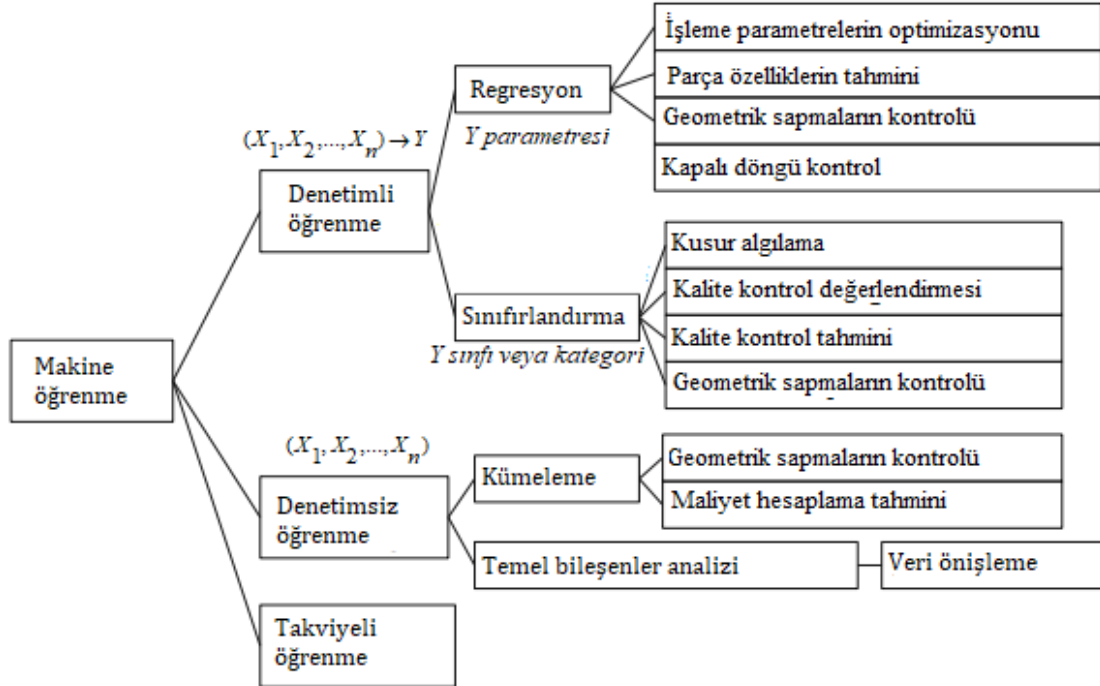
senaryolarında meydana gelebilecek kusurların rastgeleliği ve benzersizliği nedeniyle zordur. Şekil 1'de belirtildiği gibi, kusur türleri için düşük seviyeli, birleşik bir sınıflandırma yapılabilir. Şekil 1a'da görünür ve Şekil 1b'de belirgin olmak üzere iki tip yüzey kusurları sınıflandırması yapılmıştır. Bu yaklaşım yapay zekâ sistemi ile bir sınıflandırma için güçlü ve güvenilir bir temel veri tabanı sağlamaktadır.

Yapay zeka şu anda akıllı, verimli, yüksek kaliteli, kitlesel olarak özelleştirilmiş ve hizmet odaklı bir üretim süreci için eklemeli imalata yönelik geniş uygulamalar bulmaktadır. Parça kalitesini ve işlem güvenilirliğini sağlamanın bir başka yöntemi, yerinde izleme sistemlerinin uygulanmasıdır. Yerinde izleme metotları ile kusurların tespitine ilişkin literatür genellikle, olası kusurların başlangıcını tespit etmek için şekil, biçim, sıcaklık gibi eriyik havuzu [11, 12], tarama hızı [13], tarama mesafesi [14] ve katman görüntüsüne [15] odaklanmaktadır. Ancak yerinde uygulamalar için veri seti olarak görüntü verileri kullanan verimli bir hata tespit yöntemi gerekliliği doğmaktadır. Yerinde uygulama ve hata tespit yönteminde veri analizi ve veri madenciliği için etkili ve verimli bir araca ihtiyaç vardır. Bu ihtiyaç, Makine öğrenmesi (Machine Learning-ML) olarak bilinen yapay zekanın alt kümesi tarafından ele alınmaktadır. Son zamanlarda, ML modelleri tarafından yönlendirilen modern Bilgisayarla Görme (Computer Vision-CV) teknikleri toz yatağı anormallik tespiti için popüler hale gelmiştir [16]. Şekil 2'de eklemeli imalat teknolojisinde ML tekniklerin türüne göre sınıflandırılması gösterilmiştir. Bu çalışmada da toz yatak füzyon birleştirme, eklemeli imalatta kusur tespiti için makine öğrenmesi kapsamına giren derin öğrenme

tabanlı bir yaklaşım geliştirilmiştir. Çalışmada, EOS M290 metal eklemeli imalat cihazı ile yüzey kusuru kontrol modeli oluşturmak için metal parça imalatı gerçekleştirilmiştir. Toz yatak füzyon birleştirme eklemeli imalatta, hatalı imalatı muhtemel geometride, küçük bir parçanın 3B modeli kullanılmıştır. Parça katman kalınlığı 0,04 mm olup parça dilim sayısı 742'dir. UI154xSE-M kamera ile her bir katman görüntüleri çekilmiştir. Çalışmada, öğrenme aktarımı kullanan bir derin öğrenme yöntemi ile sınıflandırmak için imalat katmanları üzerinden çekilen görüntüler ile çalışmaya özgü veri seti oluşturulmuştur. Elde edilen veri seti üç farklı derin öğrenme algoritması kullanılarak kusur tespitinde %64, %74 ve %88,3 doğruluk oranında sınıflandırma başarısı elde edilmiştir. Elde edilen bu doğruluk oranı kullanılan derin öğrenme modelleri ve veri seti için uyumlu olduğunu göstermektedir. Çalışma, toz yatak füzyon birleştirmeli cihazlarda parça üretimi sırasında katman görüntüsünden derin öğrenme algoritmaları kullanarak en uygun kusur tespitinin VGG-16 algoritması ile %88,3 doğruluk oranında belirlenebileceğini göstermiştir.

2. KAYNAK ARAŞTIRMASI (RELATED WORKS)

Eklemeli imalat teknolojisinde yerinde süreç izlemenin uygulanmasıyla, süreç boyunca kusurların izlenmesi mümkün hale gelmektedir. Genel olarak, süreç izleme üç gruba ayrılabilir [17]. İlk grup, eriyik havuzunu ve çevresini karakterize etmek için eriyik havuzu izlemesidir [10]. İkinci grup, her katmanın farklı alanlarındaki hataları tespit etmek için tüm katmanın analiz edilmesidir. Elde edilen analiz sonuçlarına göre parçanın tüm yapısı boyunca her katman için tekrar tekrar kullanılabilir. Üçüncü grup, parça yapısının



Şekil 2. Eklemeli imalat teknolojisinde uygulamaların makine öğrenme teknikleri ile sınıflandırılması
(Classification of applications in additive manufacturing technology using machine learning techniques)

geometrik büyümesini ele alır. Yapay zekâ tekniklerinden makine öğrenme algoritmaları, eklemeli imalat süreci boyunca farklı hata tespit senaryolarında başarıyla kullanılmıştır. Fathizadan vd. [18], çalışmasında FLIR termal kamera ile baskı yüzeyindeki sıcaklık ile ilişkili katman görüntüsü çekmiştir. İlgili katman üzerinde, görüntü işleme teknikleri ile yapay zekâ yöntemleri ile regresyon modelleri oluşturmuştur. Daha sonra tahminleri göz önüne alarak bir sonraki katmanın yazdırması için en iyi kontrol yöntemini önermiştir. Böylece toplam baskı süresini azaltarak verimliliği önemli ölçüde arttırmıştır. Gobert vd. [19], TYB işlemi sırasında denetimli ML kusur tespiti için görüntü çekmek için tek lensli refleks kamerayla yerinde katman görüntü çekmiştir. Elde edilen sonuçları değerlendirmek için Bilgisayarlı Tomografi (BT) taramaları kullanmıştır. Parça işleme sırasında ortaya çıkan hata tespiti doğruluğunu %85 elde etmiştir. Scime vd. [20] toz yatağı anomaly (aykırılık) tiplerini sınıflandırmak için görsel aralıkta gri tonlamalı görüntüleme teknikleri uygulamıştır. Bu sınıflar, yerinde parça işleme durumunu izleme için bir makine öğrenimi algoritması modeli geliştirmek için kullanılmıştır. Önerilen algoritma çalışmaktadır ancak yerinde izleme olarak kullanılmadan önce, sınıflandırma doğruluğunun iyileştirilmesi gerekmektedir. Okaro vd. [21], yarı denetimli bir makine öğrenimi algoritması geliştirmek için foto diyet ölçümlerini kullanmıştır. Algoritmanın doğruluğu %77 elde etmiştir ve denetimli makine öğrenimi ile karşılaştırıldığında eğitim için daha az deneysel veri kullanmıştır. Makine öğrenme ile kusur tespiti için akustik sinyaller kullanmıştır [22, 23]. Akustik sinyaller, algoritmada kullanılmadan önce daha fazla veri hazırlığına ihtiyaç duymuştur. Ham verileri kullanarak elde edilen doğruluk %70'tir ve hızlı bir Fourier dönüşümü gerçekleştirdikten sonra %93'e çıkmıştır. Khanzadeh vd., [24] farklı denetimli makine öğrenimi teknikleri için karşılaştırma kaynağı olarak eriyik havuzu izleme görüntülerini kullanmıştır. Test edilen en iyi k-en yakın komşu (k-nearest neighbor) algoritması ile eriyik havuzu anomalliklerinin ve potansiyel olarak mikro yapı

anomalliklerinin gerçek zamanlı olarak tespiti için yaklaşık %98'lik bir doğruluk elde etmiştir.


Baumgart vd. [25], baskı kusurlarını tespit etmek için veri kaynağı olarak termografik eksen görüntüleme ve derin öğrenme tabanlı sinir ağı mimarilerinin bir kombinasyonunu kullanmıştır. Ağ eğitimi için, k kat çapraz doğrulama ve uzatmalı çapraz doğrulama kullanmıştır. Bu tekniklerle delaminasyon ve sıçrama gibi kusurlar %96,80'lik bir doğrulukla tanımlanmıştır. Ayrıca, model hesaplama sınıfı aktivasyon ısı haritaları ile değerlendirilmiştir. Gobert vd. [19] denetimli makine öğrenimi kullanılarak toz yatak füzyon birleştirme eklemeli imalat için yerinde hata tespit stratejisinin geliştirilmesini ve uygulanmasını açıklamıştır. Parça imalatı sırasında, yüksek çözünürlüklü dijital tek lensli refleks (DSLR) kamera kullanılarak her yapı katmanında birden çok görüntü elde etmiştir. Sınıflandırma uygun şekilde eğitildikten sonra, çapraz doğrulama deneyleri sırasında %80'den fazla yerinde kusur tespit doğruluğunu ispatlamıştır.

3. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

Çalışmada materyal olarak maraging steel metal toz malzemesi ile yüzey kontrol edilecek örnek parça, EOS M290 DMLS tezgâhında imal edilmiştir. Parça imalatında her bir katman UI154xSE-M kamera kullanılarak ve görüntüler elde edilerek veri seti oluşturulmuştur. Yöntem bölümünde ise parça tasarımı, imalatı ve derin öğrenme algoritmaları ile ilgili bilgiler verilmiştir. Daha sonra derin öğrenme algoritmaları ile yüzey kusur kontrolü gerçekleştirilmiştir.

3.1. Materyal (Material)

Çalışmada, Şekil 3a'da gösterildiği gibi örnek parça katı modeli 20x20x50 mm boyutlarındadır. Daha sonra parçanın CAD modeli, takım yolu için EOS M290 Direkt Metal Lazer Sinterleme (Direkt Metal Lazer Sintering-DMLS)



Şekil 3. Örnek parça a) katı model b) STL görünümü, c) imalat tabla görüntüsü
(Sample part a) solid model b) STL view, c) manufacturing table view)

makinesine giriş için standart dilimleme (.stl) formatına dönüştürülmüştür (Şekil 3b). DMLS makinesinde Tablo 1’de verilen deney şartları ve işleme parametreleri ile örnek parça imalatı gerçekleştirilmiştir.

Tablo 1. Parça imalat deney şartları ve işleme parametreleri (Experiment conditions and processing parameters of the manufactured part)

DMLS Sistem	EOS M290
Malzeme	Maraging Çeliği (MS1)
Toz üretim yöntemi	Gaz Atomizasyon
Ortalama tane çapı	50 µm
Toz katman kalınlığı	40 µm
Lazer benek çapı	100 µm
Lazer gücü	280W
Tarama hızı	960 mm/sn
Tarama mesafesi	0,1 mm
Enerji Yoğunluğu	67,47 J/mm ³
İmalat hacmi	250x250x325 mm ³
Koruyucu gaz tipi	Saf nitrojen gaz
Oksijen seviyesi	500 ppm

Metal eklemeli imalatın doğası gereği imalat katman katman birbiri üzerine birleştirilerek gerçekleştirilmektedir. Şekil 3c’de gösterildiği gibi EOS DMLS makine içinde gömülü olan IDS UI154xSE-M marka modeli, 1.3 MP (1280x1024 piksel) çözünürlükte, renk derinliği 32 bpp olan, pozlama süresi (exposure) 78,03 ms özelliklerine sahip CMOS kamera ile her bir katman görüntüleri çekilmiştir.

3.2. Derin Öğrenme (Deep Learning)

Temeli yapay sinir ağlarına dayanan derin öğrenme, makine öğreniminin bir alt kümesidir. Klasik makine öğrenimi yöntemleri yalnızca bir bilgi işlem katmanı kullanmaktayken derin öğrenme; denetimli veya denetimsiz özellik çıkarımı, dönüşüm, desen analizi ve sınıflandırma için doğrusal olmayan bilgi işlemenin birçok katmanını kullanan tekniklerdir. Bu teknik her ardışık gizli katmanda, önceki katmandaki çıktıyı girdi olarak alarak son katmana kadar hiyerarşi içerisinde işletmektedir [26, 27]. Derin öğrenme görüntü, ses ve metin gibi verileri anlamlandırmaya yardımcı olan birden çok temsil ve soyutlama düzeyini öğrenmekle ilgili olan bir tekniktir [28].

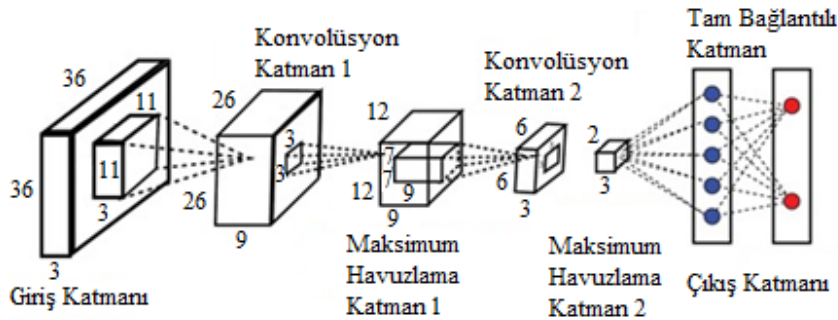
Derin öğrenme tekniğinde çok çeşitli mimariler bulunmakla beraber en sık kullanılanları; Konvolüsyonel Sinir Ağları (Convolutional Neural Network-CNN), Derin Oto-kodlayıcılar (Autoencoder), Uzun Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM), Sınırlı Boltzman Makineleri (Restricted Boltzmann Machines-RBM)’dir [29, 30]. Derin öğrenmenin temelleri çok öncelere uzanmasına rağmen, donanım hızlarının artması, grafik işlemcilerinin de ağ eğitiminde kullanılması ile beraber 2000’li yıllarda popülerlik kazanmaya başlamış [31-33] ve başarılı yeni ağ modelleri geliştirilmiştir [34].

Bilgisayarlı görü [35], görüntü işleme [36], doğal dil işleme [37], siber güvenlik [38, 39], biyomedikal [40] gibi çeşitli alanlarda kullanımı bulunmaktadır. Derin öğrenme ile belirtilen alanlarda; nesne algılama, yüz tanıma, görüntü rekonstrüksiyonu, makine çevirisi, görüntü açıklaması, kötü amaçlı yazılım algılama, spam algılama, bilgisayar destekli görüntü yorumlama ve analizi uygulamaları gerçekleştirilmektedir. Özellikle bilgisayarlı görü ve görüntü işlemede CNN mimarisine sahip algoritmalar ile daha iyi performans ve başarılı sonuçlar elde edilmektedir [41, 42].

CNN (Konvolüsyonel Sinir Ağları), geleneksel sinir ağlarına benzer şekilde giriş katmanı, çıkış katmanı ve çok sayıda gizli katmanlardan meydana gelmektedir (Şekil 4). Bu gizli katmanlar genellikle bir veya daha fazla konvolüsyonel katman, havuzlama katmanları ve tam-bağlantılı katmanları içerir. Bahsi geçen katmanlarda yapılan işlemler ile özellik haritaları olarak ifade edilen bir dizi özellik çıkarımı gerçekleştirilir. Bir katmandaki değişik özellik haritaları, farklı filtre kümeleri kullanır. Çıkış katmanı, sınıf puanlarını hesaplar ve bir sınıflandırıcı gibi işlev yapar [39, 41]. CNN’nin her bir katmanı, çıkış değerlerini, rektifiye doğrusal birim (Rectified Linear Unit-ReLU) gibi sık kullanılan bir aktivasyon fonksiyonundan geçirecek sonraki katmana yaymaktadır. Çıkış katmanında genellikle olasılıklı çıktılar elde etmek için soft-max fonksiyonu kullanılır. Böylece CNN, nesne sınıflandırma problemleri için olasılık tahmin etme gibi bir rol oynamaktadır [44].

3.3. Veri Seti (Data Set)

Çalışmada veri setini oluşturan görüntüler, parça imalatı esnasında özel olarak elde edilmiştir. İmalat makinesinden



Şekil 4. Tipik bir CNN mimari yapısı [43] (Typical CNN architectural structure)

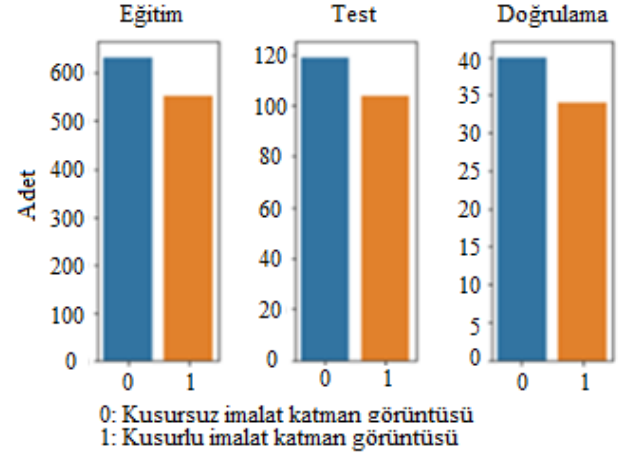
1280x1024 piksel boyutunda, yakma öncesi ve yakma sonrası olmak üzere, toplam 1484 görüntü alınmıştır. Her bir katmanın görüntüsü toz yayılımı ve geometrik olarak incelenmiştir. Şekil 5a'da gösterilen katmanın görüntüsü ile Şekil 5b'de gösterilen STL dosyasındaki katman geometrisi karşılaştırılmıştır. Karşılaştırma sonucuna göre katman görüntüsünün kusurlu olup olmadığına karar verilmiş ve bu duruma göre kategorize edilmiştir.

Görüntüler katmanda imalat hatası olmayan (kusursuz) ve katman imalat hatası olan (kusurlu) olmak üzere iki sınıfa ayrılarak etiketlenmiştir. Şekil 6'da bu görüntülerden kusurlu ve kusursuz kabul edilenlere birer örnek verilmiştir. Alman görüntülerin 793 adedi kusursuz, 691 adedi kusurlu görüntülerdir. Görüntülerin %80'i (553 kusurlu, 634 kusursuz) eğitim verisi olarak, %5'i (34 kusurlu, 40 kusursuz) doğrulama (validasyon) verisi olarak rastgele ve %15'i (104 kusurlu, 119 kusursuz) test verisi olarak ayrılmıştır. Şekil 7'de veri setine ilişkin sayısal bilgiler verilmiştir.

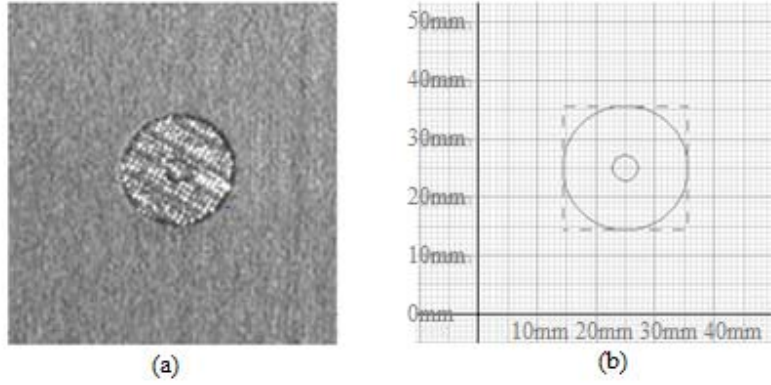
3.4. Öğrenme Aktarım Yöntemi (Transfer Learning Method)

Denetimli derin öğrenme modelleri genellikle çok miktarda veriyi içeren veri setleri ile eğitilmektedir. Fakat çeşitli nedenlerle veri setinin göreceli olarak az veriyi içermesi durumunda öğrenme aktarımı yöntemi kullanılabilir.

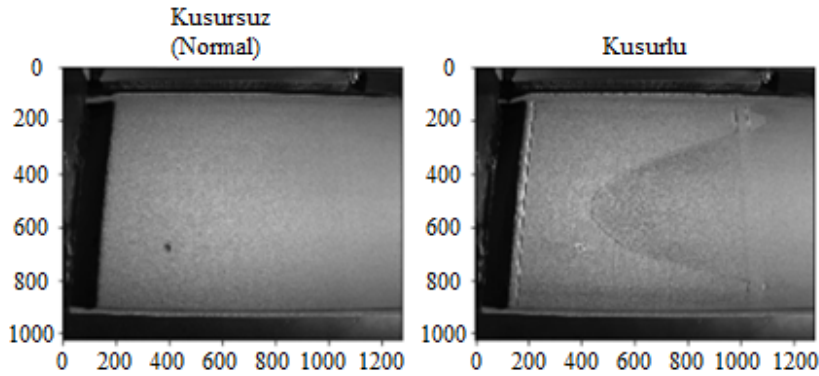
TYB eklemeli imalat, daha özel bir imalat yöntemi olduğu için on binlerce kusurlu-kusursuz görüntü verisi elde etmek çok zahmetli ve maliyetlidir. Bu bakımdan daha az görüntü veri seti ile eğitilecek modelleri içeren tekniklere ihtiyaç duyulmaktadır. Kısıtlı miktardaki görüntü verileri ile eğitilerek göreceli olarak başarılı sonuçlar elde edilmesinde karşımıza öğrenme aktarımı (transfer learning) yöntemi çıkmaktadır.



Şekil 7. Veri seti bölümlenmesine ait sayısal bilgiler (Numerical information of data set segmentation)



Şekil 5. Veri seti sınıflandırma süreci, a) imalat katmanı, b) STL dosya katman görüntüsü (Dataset classification process, a) building layer, b) image of STL file layer)



Şekil 6. Veri seti örnek görüntüleri (Sample images of dataset)

Öğrenme aktarımında, daha önceden çok miktarda görüntü verisi ile eğitilmiş konvolüsyonel sinir ağları (CNN) kazanılmış öğrenimler oluşturulacak yeni modele aktarılabilir. Bu yöntemi kullanmanın avantajı, ağı daha önceden çok fazla görüntü verisi (örn. ImageNet) ile eğitilmesinden dolayı ağı şekli, görüntünün kenar tanıma vb. gibi temel özelliklerinin zaten öğrenilmesi olarak karşımıza çıkmaktadır. Böylece, önceden eğitilmiş model, mevcut veri tabanından görüntülerin temel özelliklerini öğrenme şeklinde edinilen bilgilerden faydalanarak daha az veriye sahip kişisel veri seti ile derin sinir ağı eğitilir (Şekil 8). Yalnızca son katmanlar eğitildiğinden süreç kısalmış olur [45]. Öğrenme aktarımında VGG16-19, DenseNet ve InceptionV3 gibi ImageNet [46] görüntü tanıma yarışmalarında (ImageNet Large Scale Visual Recognition Challenge-ILSVRC) önceden performansları tecrübe edilmiş çeşitli ön eğitilmiş mimariler/modeller yaygın olarak kullanılmaktadır [47]. Çalışmada değerlendirilen mimariler aşağıda özetlenmiştir.

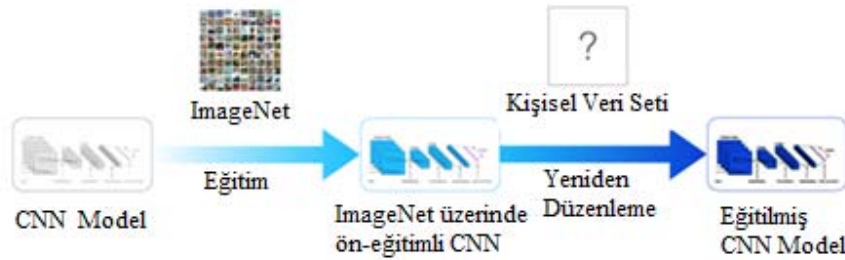
VGG (Visual Geometry Group): Simonyan ve Zisserman [48], tarafından geliştirilen bir mimaridir (Şekil 9). CNN' in girdisi sabit boyutlu 224×224 RGB görüntüdür. Çok küçük (3×3) evrişim filtrelerine sahip bir mimari kullanarak büyük derinlikli CNN ağları için önemli ölçüde doğruluk elde etmişlerdir. Büyük genişlikte konvolüsyon (evrişim) katmanları nedeniyle çok sayıda parametre içermesi, önceki yapılandırmalarına kıyasla yüksek bir hesaplama maliyeti oluşturmaktadır. Model mimarisinde evrişimsel katman yığını üç tam bağlı (fully connected-FC) katman izler. İlk ikisinin her biri 4096 kanala sahiptir ve üçüncüsü 1000 kanal içerir. Son katman soft-max katmandır. Tüm gizli katmanlarda ReLU aktivasyon fonksiyonu uygulanmıştır [48, 49]. ILSVRC 2014 sınıflandırma yarışmasında ikinci sırayı almıştır. Yarışmaya sırasıyla 11, 16 ve 19 katmandan oluşan VGG-11, VGG-16 ve VGG-19 isiminde 3 farklı ağ ile katılmıştır [50].

InceptionV3: ILSVRC sırasında tanıtılan Google'ın Inception CNN'inin üçüncü sürümüdür. Inception-v3, 48 katman derinliğinde konvolüsyonel bir sinir ağıdır. Ağı giriş alan boyutu, ortalama çıkarma ile RGB renk kanallarını olarak 224×224 'tür. Inception modüllerinin içindekiler de dahil tüm konvolüsyon katmanları ReLU aktivasyonu kullanır. 3×3 küçültme ve 5×5 küçültme, 3×3 ve 5×5 konvolüsyonlardan önce kullanılan indirgeme katmanındaki 1×1 filtrelerin sayısını ifade etmektedir. Havuz projeksiyon sütununda, yerleşik maksimum havuzlamadan sonra katmandaki 1×1 filtrelerin sayısı görülebilir. Tüm bu indirgeme/projeksiyon katmanları ReLU aktivasyonu kullanır. ILSVRC 2012 sınıflandırma yarışmasında, Top-5 ve Top-1 hata oranı en iyi tek model çıkarım sonuçları elde etmiştir [35, 52].


DenseNet: Yoğun Evrişimsel Ağ (DenseNet), her katmanı diğer her bir katmana ileri beslemeli olarak bağlama özelliğine sahip bir mimaridir. Geleneksel evrişimsel ağlarda bir katmandan sonraki katmana bir adet ve toplamda katman sayısı kadar(n) bağlantı varken, DenseNet ağında $n(n+1)/2$ bağlantısı bulunmaktadır. Her katman için, önceki tüm katmanların özellik haritaları girdi olarak kullanılmaktadır. DenseNet' in kaybolan gradyan problemini hafifletme, özellik yayılımını güçlendirme, özelliğin yeniden kullanımını teşvik etme, parametre sayısını önemli ölçüde azaltma, yüksek performansa ulaşmak için daha az bellek ve hesaplama gereksinimi gibi avantajları vardır [53]. DenseNet, büyük ölçekli ILSVRC 2012 veri setinde (ImageNet) ResNet [54] parametrelerinin ve FLOP sayısının yaklaşık yarısını kullanarak benzer bir doğruluk oranı elde etmiştir.

3.5. Performans Ölçütleri (Performance Criteria)

Derin öğrenmede iki veya daha fazla sınıflandırma modellerinin performansının ölçümünde sıklıkla hata matrisinden yola çıkılarak doğruluk, kesinlik duyarlılık, f-



Şekil 8. Eğitilmiş derin ağ modeli (Trained deep network model)




Şekil 9. VGG-16 Modelinin genel mimari yapı haritası [51] (Base map architecture of VGG-16)

puanı ve alıcı çalışma karakteristik (Receiver Operating Characteristic-ROC) eğrisi kullanılmaktadır. Hata matrisi, gerçek ve tahmin sınıfının dört farklı durumunu içeren bir tablodur (Şekil 10). Doğru pozitif ve negatif, yanlış pozitif ve negatif gibi dört farklı hata matris durumları Tablo 2’de verilmiştir.

Tablo 2. Hata matrisi durumları (Confusion matrix states)

Doğru Pozitif (DP, ing. True positive TP)	Doğru olarak belirlenen pozitif sınıfların tahmin sayısı
Doğru Negatif (DN, ing. True negative TN)	Doğru olarak belirlenen negatif sınıfların tahmin sayısı
Yanlış Pozitif (YP, ing. False positive FP)	Yanlış olarak belirlenen pozitif sınıfların tahmin sayısı
Yanlış Negatif (YN, ing. False negative FN)	Yanlış olarak belirlenen negatif sınıfların tahmin sayısı



Şekil 10. Hata matrisi (Confusion matrix)

Hata matrisindeki durumlara göre; doğruluk Eş. 1, kesinlik Eş. 2, duyarlılık Eş. 3 ve f-puanı Eş. 4 hesaplanabilmektedir [47].

$$\text{Doğruluk (Accuracy)} = \frac{DP(TP) + DN(TN)}{DP(TP) + DN(TN) + YP(FP) + YN(FN)} \quad (1)$$

$$\text{Kesinlik (Precision)} = \frac{DP(TP)}{DP(TP) + YP(FP)} \quad (2)$$

$$\text{Duyarlılık (Recall)} = \frac{DP(TP)}{DP(TP) + YN(FN)} \quad (3)$$

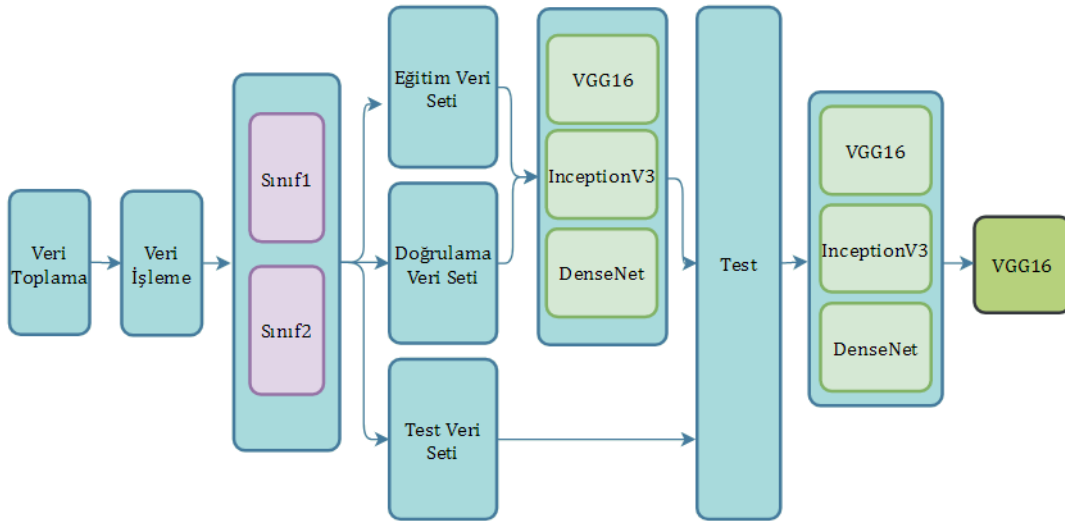
$$F1 - \text{puan (score)} = \frac{2 \times \text{duyarlılık} \times \text{kesinlik}}{\text{duyarlılık} + \text{kesinlik}} \quad (4)$$

Bir başka performans ölçümü, ROC eğrisi ile duyarlılık ve seçicilik arasındaki ilişkinin grafiksel ifadesi olarak yapılabilmektedir. ROC eğrisi, duyarlılığın y ekseninde ve 1-özgüllüğün (seçicilik) x ekseninde olduğu değerlere karşılık çizilir. ROC analizi, sınıflandırma başarısı değerlendirilen bir modelin ayırt ediciliğini göstermektedir [47, 55].

4. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Çalışmaya özgü görüntü verilerini eğitmek için derin öğrenme yöntemlerinden evrimsel sinir ağı (CNN) tabanlı öğrenme aktarım yöntemi kullanılmıştır. Öğrenme aktarım yönteminde, ImageNet veri tabanı üzerinde önceden eğitilmiş VGG16, DenseNet ve InceptionV3 ön öğrenmeli CNN modelleri ayrı ayrı denenmiştir. Çalışma Kaggle notebook [56] ortamında Python programlama dili ile ve önceden eğitilmiş derin öğrenme modellerini ağırlıklarıyla birlikte içeren Keras kütüphanesi kullanılarak gerçekleştirilmiştir.

Deneysel çalışmayı özetleyen akış şeması Şekil 11’de verilmiştir. EOS M290 DMLS makinesinden imalat esnasında çekilen görüntüler toplanmış ve “kusurlu,



Şekil 11. Deneysel çalışma akış diyagramı (Flow chart of experimental study)

kusursuz” olarak iki sınıfa ayrılmıştır. Görüntü verileri, ikinci konu başlığında verilen oranlar ile eğitim, doğrulama ve test veri setine bölünmüştür. Eğitim ve doğrulama veri seti kullanılarak VGG16, DenseNet ve InceptionV3 modelleri ayrı ayrı eğitilmiştir. Çalışmaya özgü kullanılan veri seti ile eğitilmiş modeller Test veri seti ile de performansları kıyaslanmıştır. Çalışmada test edilen bütün modellerde giriş görüntü boyutu 150x150 alınmış ve siyah-beyaz görüntü kullanılmıştır. En yüksek performans/başarı VGG16 modeli ile elde edilmiştir.

Karşılaştırılan ön öğrenmeli modellerin doğruluk metriğine göre sınıflandırma performansı Tablo 3’de verilmektedir. Elde edilen performans değerlerine bakıldığında en iyi performansı VGG-16 modeli vermiştir. InceptionV3 ve DenseNet modelleri daha düşük bir performans göstermişlerdir.

Tablo 3. Kıyaslanan modellerin sınıflandırma performansı (Classification performance of compared models)

Model	Doğruluk oranı (%)	Kayıp
1 VGG-16	88,3	0,301
2 InceptionV3	64	6,20
3 DenseNet	74	5,37

4.1. VGG-16 Modelinin Sınıflandırma Performans Değerleri (VGG-16 model classification performance)

Çalışmada standart VGG-16 modeli mimari yapısı Tablo 4’de verildiği şekli ile düzenlenmiştir. Çalışmaya özgü veri seti ile modelin eğitim ve testi gerçekleştirilmiştir. Performans ölçümü için kayıp ve sınıflandırma doğruluk değerleri

python dili ile hesaplatılmıştır. Modelde en iyi performans için eğitim değişkenleri (hiper parametreler) farklı değerler ile denenmiş, adam optimizatörü (adam optimizer) için öğrenme oranı (learning rate) 0.0001, periyot (epoch) 60 ve grup boyutu (batch size) 24 değerlerinde en yüksek doğruluk elde edilmiştir.

4.1.1. Modelin kayıp ve sınıflandırma doğruluğu (Loss and classification performance)

Çalışmada, önerilen modelin sonuçlarının güvenilir olması ve geliştirilebileceğini ispatlamak açısından 5-kat ve 10-kat çapraz doğrulama yöntemi ile eğitilmiştir. Çapraz doğrulamalar sonucunda, %83 ile %88,3 arasında değişen doğruluk değerleri gözlemlenmiştir. Modelin öğrenme veri seti üzerinde ölçülen kayıp ve doğruluk grafiği Şekil 12’de gösterilmiştir. Model test veri seti üzerinde ölçülen kayıp değeri 0,301, doğruluk değeri ise 0,883 elde edilmiştir.

4.1.2. Modelin sınıflandırma başarısının değerlendirilmesi (Evaluation classification performance)

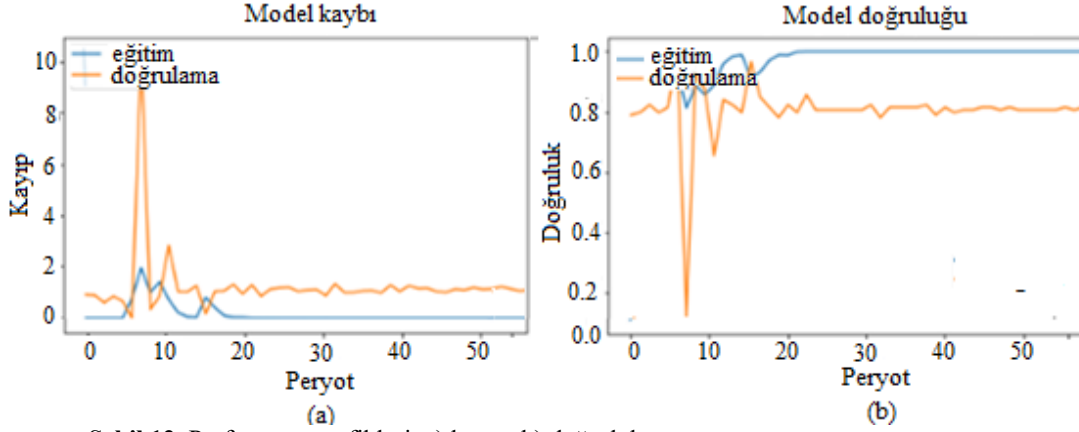
Önerilen VGG-16 modelinin doğrulanmasına katkıda bulunan test veri seti sınıflandırma hata matrisi Şekil 13’te gösterilmektedir. Gösterilen hata matrisinde 107 adet görüntü gerçek kusursuz, 90 görüntü gerçek kusurlu olarak; 12 görüntü yanlış kusursuz, 14 numune de yanlış kusurlu olarak sınıflandırılmıştır. Bu durum modelin göreceli olarak düşük bir hata oranına sahip olduğu anlaşılmaktadır. Modelin test aşamasında sınıflandırma doğruluğunun %88,3 olduğu hesaplanmıştır. Kullanılan modelin başarılı bir sınıflandırma performansı gösterdiği ve hata tespitine uygun olduğu ifade edilebilir.

Tablo 4. Yeniden düzenlenmiş VGG-16 model yapısı (Fine tuning VGG-16 model structure)

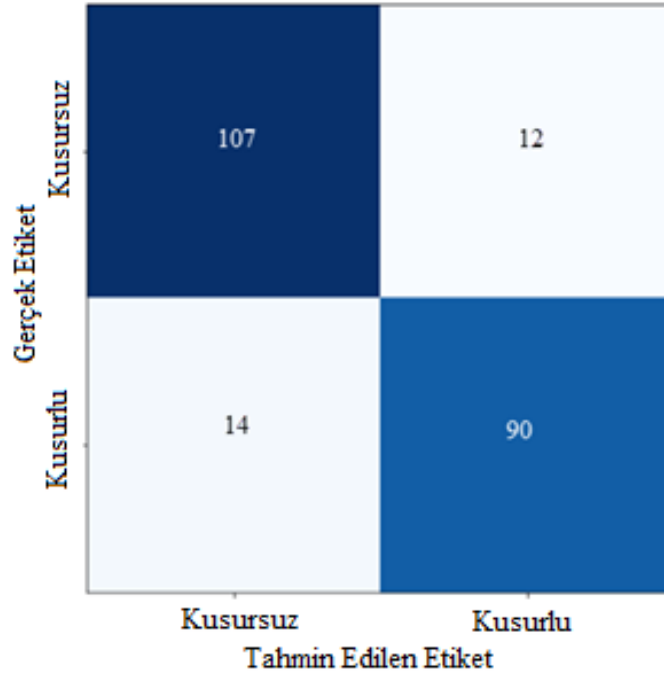
	Katman-Tür (Layer)	Çıkış Şekli (Output Shape)	Parametre Sayısı (Parameters)
Blok1	Giriş (Input Layer)	(150x150x3)	
	Konv1-64(Conv2D)	(150x150x64)	1792
	Konv2-64(Conv2D)	(150x150x64)	36928
	Maksimum havuzlama(MaxPooling2D)	(75x75x64)	
Blok2	Konv1-128(Conv2D)	(75x75x128)	73856
	Konv2-128(Conv2D)	(75x75x128)	147584
	Maksimum havuzlama(MaxPooling2D)	(37x37x128)	
Blok3	Konv1-256(Conv2D)	(37x37x256)	295168
	Konv2-256(Conv2D)	(37x37x256)	590080
	Konv3-256(Conv2D)	(37x37x256)	590080
	Maksimum havuzlama(MaxPooling2D)	(18x18x256)	
Blok4	Konv1-512(Conv2D)	(18x18x512)	1180160
	Konv2-512(Conv2D)	(18x18x512)	2359808
	Konv3-512(Conv2D)	(18x18x512)	2359808
	Maksimum havuzlama(MaxPooling2D)	(9x9x512)	
Blok5	Konv1-512(Conv2D)	(9x9x512)	2359808
	Konv2-512(Conv2D)	(9x9x512)	2359808
	Konv3-512(Conv2D)	(9x9x512)	2359808
	Maksimum havuzlama(MaxPooling2D)	(4x4x512)	
	Düzleştirme(Flatten)	8192	
	Yoğun (Dense)	2	16386
	Normalleştirilmiş üstel fonksiyon (soft-max)		

ROC eğrisinden de görüldüğü üzere (Şekil 14) sınıflandırma başarısı oldukça iyidir. Eğri altında kalan alanlar 1 değerine çok yakındır. Bu durum, kusurlu ve kusursuz görüntülerin sınıflarının doğru olarak tahmin edilme başarısının yüksek olduğunu göstermektedir.

Çalışmada, modelin hesaplanan diğer performans ölçütleri Tablo 5’de verilmiştir. Burada test verileri üzerinde kesinlik, duyarlılık ve f1 puanı ortalaması 0.88 değeri bulunmuştur. Bu değerler öğrenme aktarımı modeli için göreceli olarak yüksek bir başarı oranıdır.



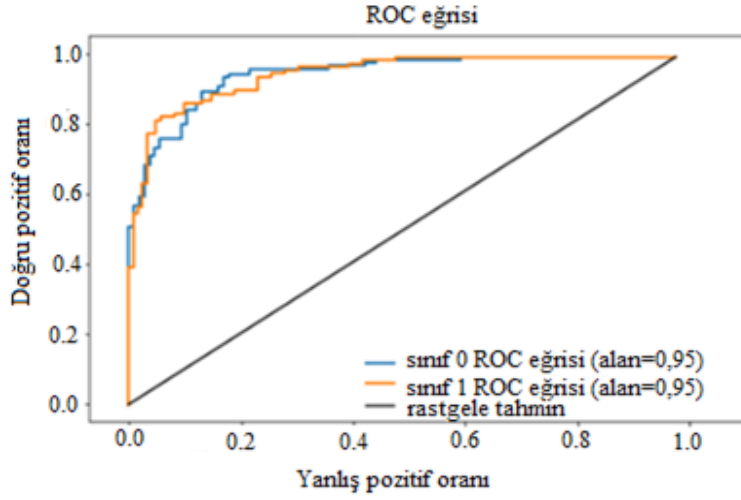
Şekil 12. Performans grafikleri, a) kayıp, b) doğruluk (Performance graphics, a) loss, b) accuracy)



Şekil 13. Model hata matrisi (confusion matrix of the model)

Tablo 5. Model performans ölçütleri (Model performance metrics)

	Kesinlik	Duyarlılık	F1-puan	Test Sayısı	Doğruluk
0 (Kusursuz)	0,87	0,92	0,89	119	0,899
1 (Kusurlu)	0,90	0,84	0,87	104	0,865
Mikro Ortalama	0,88	0,88	0,88	223	0,883
Makro Ortalama	0,88	0,88	0,88	223	0,883
Ağırlıklı Ortalama	0,88	0,88	0,88	223	0,883



Şekil 14. Model ROC eğrisi (ROC curve of model)

5. SONUÇ VE TARTIŞMALAR (RESULT AND DISCUSSIONS)

Çalışmada kullanılan derin öğrenme yöntemi, TYB ile eklemeli imalata yönelik yenilikçi bir uygulama niteliğindedir. TYB makinesinde parça imalatında katmanındaki kusur durumlarının tespiti için kameralı bir sistem kullanılmıştır. Çalışmaya özgü veri seti kullanılarak TYB eklemeli imalat için, imalat katmanlarındaki kusurları tespit etmeye yönelik öğrenme aktarımı kullanan derin öğrenme modeli önerilmiştir. Parça imalatı sırasında elde edilen görüntülerden oluşturulan veri seti, üç farklı ön öğrenmeli modelin eğitim ve testi için kullanılmıştır. Görüntülerden, imalat katmanında kusurun olup olmasına göre yapılan sınıflandırmada InceptionV3 modelinden %64, DenseNet modelinden %74 ve VGG-16 modelinden ise %88,3 doğruluk oranı ile en yüksek performans elde edilmiştir. Oldukça yüksek işlem maliyetlerine sahip TYB eklemeli imalatta, çok fazla imalat görüntüsü almak maliyet açısından zordur. Bu şartlarda sınırlı sayıda görüntü verileri ile kusur tespiti yapabilmek için derin öğrenme yöntemlerinden öğrenme aktarımı kullanılarak göreceli olarak yüksek doğruluk oranı elde edilmiştir. Elde edilen bulgulara göre öğrenme aktarımı yönteminin bu alanda kusurlu imalat işlemlerinin tespit edilmesinde kullanılabileceği gösterilmiştir.

Literatür incelendiğinde Scime vd. [20] çalışmasında, görüntü işleme ve makine öğrenme algoritma kullanarak, EOS M290 makinesinde toz serme işlemiyle ilgili ortaya çıkan anormallikleri sınıflandırabilen algoritma geliştirilmiştir. Makine öğrenimi için eğitim veri tabanı, 1040 anormallik içermeyen yama ile 1362 anormallik yamasından oluşan toplam 2402 görüntü yaması içermektedir. Çalışmada, test edilen piksellerin çok büyük çoğunluğunun anormal olmayışı nedeniyle modelin ikili sınıflandırma doğruluğu %95 değeri elde edilmiştir. Literatürde transfer öğrenimi ile ikili sınıflandırma için CNN model tabanlı GoogleNet, AlexNet, VGG16, ResNet-50 gibi popüler mimari modellerin kıyaslandığı çalışmalar

bulunmaktadır. Oyelade vd. [57] çalışmasında, CBIS-DDSM hazır veri seti üzerinden popüler modeller eğitilerek GoogleNet %59,80, AlexNet %65,60, ResNet-50 %62,7 ve VGG16 %58 doğruluk oranlarına ulaşılmıştır. Liang ve Zheng [58] çalışmalarında, CNN ile öğrenme aktarımı içeren ikili sınıflandırmanın yapıldığı bir model önermişlerdir. Önerilen model için %90, Xception %87,8, InceptionV3 %0,85, DenseNet121 %81 ve VGG16 %74 doğruluk oranları elde edilmiştir. Deniz vd., [59] çalışmalarında transfer öğrenmeye dayalı ikili sınıflandırma gerçekleştirmişlerdir. Çalışmada özellik çıkarımı için AlexNet ve VGG16 modelleri kullanılmış, elde edilen özellikler daha sonra destek vektör makineleri (SVM) ile sınıflandırılmıştır. Modellerin eğitiminde 5-kat çapraz doğrulama kullanılmıştır. AlexNet ve VGG16 modellerinin birleşiminden oluşan doğruluklar %79,80 ile %93,02 arasında elde edilmiştir. Yukarıdaki çalışmalar incelendiğinde, transfer öğrenimi için CNN tabanlı InceptionV3, DenseNet ve VGG-16 modelinden elde edilen doğruluk oranları sırasıyla %64, %74 ve %88,3 elde edilmesi literatür ile benzerliğini ortaya koymuştur. Çalışmada, VGG-16 modeli %88,3 doğruluk değeri ile literatürdeki diğer çalışmalardan daha yüksek başarı oranı elde edilmiştir. Literatür çalışmaları incelendiğinde araştırmacıların kullandıkları veri kümesi üzerindeki çıkarımların farklı derin öğrenme modelleri ile aynı şartlarda eğitildiği, tüm modellerin farklı doğruluk ve performans gösterdiği görülmektedir [60-62]. Performansı en yüksek model, veri kümesindeki problemi çözmek için kullanılmaktadır.

Çalışmada toz yatağının bir katmanı üzerindeki imalatın kusurlu ve kusursuz durumunun tespiti yapılmıştır. Fakat kusurun ne olduğu sınıflandırılmamıştır. Çok miktarda imalat verisi kullanılarak kusurlu yapının da ne olduğu sonraki çalışmalar için değerlendirilebilir. Ayrıca, veri çoğaltma yöntemi ile veri setinin zenginleştirilerek modelin eğitilmesi sonucunda sınıflandırma başarısının artıp artmadığı gözlemlenebilir. İlerleyen çalışmalarda, tek bir malzeme üzerinden farklı işleme parametreleri ve parça geometrileri uygulanarak parça imalatında katman imalat

görüntüleri ile veri sayısı artırılıp öğrenme aktarımlı evrişimsel sinir ağı modelin başarımları incelenilebilir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Yazarlar, çalışma için imalat ve görüntüleme işlemlerindeki yardımlarından dolayı 3DDT firmasına teşekkür eder.

KAYNAKLAR (REFERENCES)

1. Suat Y. A., Koc B., Yılmaz O. Building strategy effect on mechanical properties of high strength low alloy steel in wire+ arc additive manufacturing. *Zavarivanje i zavarene konstrukcije*, 65 (3), 125-136, 2020.
2. Ülkir O., Ertugrul İ., Akkuş N., Characterization of electrothermal micro-actuator using image processing algorithm, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2), 1159-1170, 2021.
3. Dilberoglu U.M., Simsek S., Yaman U. Shrinkage compensation approach proposed for ABS material in FDM process. *Materials and Manufacturing Processes*, 34 (9), 993-998, 2019.
4. DebRoy T., Wei H.L., Zuback J.S., Mukherjee T., Elmer J.W., Milewski J.O., Beese A.M., Wilson-Heid A., De, A., Zhang W. Additive Manufacturing of Metallic Components – Process, Structure And Properties. *Prog. Mater. Sci.*, 92, 112–224, 2018.
5. Dilberoglu U.M., Gharehpagh B., Yaman U., Dolen M. Current trends and research opportunities in hybrid additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, 113, 1-26. 2021.
6. Chen Y., Li T., Jia Z., Scarpa F., Yao C.W., Wang L. 3D Printed Hierarchical Honeycombs With Shape Integrity Under Large Compressive Deformations. *Material Design*. 137, 226–234, 2018.
7. OTAG, 2020. T.C Cumhurbaşkanlığı Savunma Sanayi Başkanlığı Eklemeli İmalat Teknolojileri Yol Haritaları, https://arge.ssb.gov.tr/Documents/Eklemeli_Imalat%20_Teknolojileri_OTAG_Sonuc_Raporu_.pdf, Erişim Tarihi: 15.12.2020.
8. Poyraz Ö., Kuşhan M.C., Investigation of the effect of different process parameters for laser additive manufacturing of metals, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 33 (2), 729-742, 2018.
9. Sames WJ, List FA, Pannala S., The Metallurgy And Processing Science of Metal Additive Manufacturing. *Int Mater Rev* 61 (5), 315–360, 2016.
10. Tapia, G., Elwany, A., A Review on Process Monitoring And Control In Metal-Based Additive Manufacturing. *J Manuf Sci Eng*, 136 (6), 60801, 2014.
11. Clijsters S., Craeghs T., Buls S, In Situ Quality Control of The Selective Laser Melting Process Using A High-Speed, Realtime Melt Pool Monitoring System, *Int J Adv Manuf Technol*, 75 (5), 1089–1101, 2014.
12. Doubenskaia M.A., Zhirnov I.V., Teleshevskiy V.I., Bertrand P., Smurov I.Y., Determination Of True Temperature In Selective Laser Melting of Metal Powder Using İnfrared Camera, *Mater. Sci. Forum*, 834, 93-102, 2015.
13. Grasso M.V., Laguzza Q. Semeraro B.M., Colosimo-Process Monitoring of Selective Laser Melting: Spatial Detection of Defects Via İmage Data Analysis. *J. Manuf. Sci. Eng.*, 139 (5), 051001, 2017.
14. Kanko J.A., A.P. Sibley, J.M., Fraserin Situ Morphology-Based Defect Detection Of Selective Laser Melting Through Inline Coherent Imaging, *J. Mater. Process. Technol.*, 231, 488-500, 2016.
15. Zhang B., J. Ziegert F., Farahi A., Davies In Situ Surface Topography Of Laser Powder Bed Fusion Using Fringe Projection Addit. *Manuf.*, 12, 100-107, 2016.
16. Meng L., McWilliams B., Jarosinski W., Park H.Y., Jung Y.G., Lee J., Zhang J., Machine Learning in Additive Manufacturing: A Review, *JOM*, 1-15, 2020.
17. Everton S.K., Hirsch M., Stravroulakis, P., Review of Insitu Process Monitoring And In-Situ Metrology For Metal Additive Manufacturing. *Mater Des*, 95, 431–445, 2016.
18. Fathizadan S. A Novel Real-Time Thermal Analysis and Layer Time Control Framework for Large-Scale Additive Manufacturing, *Journal of Manufacturing Science and Engineering*, 143, 1, 2020.
19. Gobert C., Reutzel E.W., Petrich J., Nassar A.R., Phoha S. Application of Supervised Machine Learning For Defect Detection During Metallic Powder Bed Fusion Additive Manufacturing Using High Resolution Imaging, *Additive Manufacturing*, 21, 517-528, 2018.
20. Scime L., Beuth J., Anomaly Detection And Classification In A Laser Powder Bed Additive Manufacturing Process Using A Trained Computer Vision Algorithm. *Addit Manuf.*, 19, 114–126, 2018.
21. Okaro IA, Jayasinghe S, Sutcliffe C., Automatic Fault Detection For Laser Powder-Bed Fusion Using Semi-Supervised Machine Learning, *Addit Manuf.*, 27, 42–53, 2019.
22. Shevchik SA, Kenel C, Leinenbach C., Acoustic Emission For İn Situ Quality Monitoring İn Additive Manufacturing Using Spectral Convolutional Neural Networks. *Addit Manuf*, 21, 598–604, 2018.
23. Ye D., Hong G.S., Zhang Y., Defect Detection In Selective Laser Melting Technology By Acoustic Signals With Deep Belief Networks. *Int J Adv Manuf Technol*, 96 (5), 2791–2801, 2018.
24. Khanzadeh M, Chowdhury S., Marufuzzaman M. Porosity Prediction: Supervised-Learning Of Thermal History For Direct Laser Deposition. *J Manuf Syst*, 47, 69–82, 2018.
25. Baumgartl H., Tomas J., Buettner R., Merkel M. A Deep Learning-Based Model For Defect Detection In Laser-Powder Bed Fusion Using In-Situ Thermographic Monitoring, *Progress in Additive Manufacturing*, 5, 277-285, 2020.
26. Deng L., Yu D., Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*, 7 (3–4), 197–387, 2014.
27. Süzen A.A., Duman B., Şen B., Benchmark Analysis of Jetson TX2, Jetson Nano and Raspberry PI using Deep

- CNN. In 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), IEEE, 1-5, 2020.
28. LisaLab, 2020., <https://github.com/lisalab/DeepLearningTutorials>, Erişim Tarihi: 15.12.2020.
 29. Shrestha A., Mahmood A., Review of Deep Learning Algorithms And Architectures. IEEE Access, 7, 53040-53065, 2019.
 30. Aksoy B., Köse U., Optimization of real-time wireless sensor based big data with deep autoencoder network: a tourism sector application with distributed computing. Turkish Journal of Electrical Engineering and Computer Sciences, 28 (6), 2020.
 31. Hinton G.E., Salakhutdinov R.R., Reducing The Dimensionality of Data With Neural Networks. Science, 313 (5786), 504-507, 2006.
 32. Krizhevsky A., Sutskever I., Hinton G.E., ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, 25 (2), 2012.
 33. Taigman Y., Yang M., Ranzato M.A., Wolf L., Deepface: Closing The Gap To Human-Level Performance In Face Verification, In Proceedings of the IEEE Conference on Computer Vision And Pattern Recognition, 1701-1708, 2014.
 34. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Rabinovich A., Going Deeper With Convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9, 2015.
 35. Voulodimos A., Doulamis N., Doulamis A., Protopapadakis E., Deep Learning For Computer Vision: A Brief Review. Computational intelligence and neuroscience, 2018, 1-13, 2018.
 36. Hatt M., Parmar C., Qi J., El Naqa I., Machine (Deep) Learning Methods For Image Processing And Radiomics. IEEE Transactions on Radiation and Plasma Medical Sciences, 3 (2), 104-108, 2019.
 37. Yang H., Luo L., Chueng L. P., Ling D., Chin F., Deep Learning And its Applications To Natural Language Processing. In Deep learning: Fundamentals, theory and applications, Springer, Cham, 89-109, 2019.
 38. Mahdavi S., Ghorbani A.A., Application of Deep Learning To Cybersecurity: A Survey, Neurocomputing, 347, 149-176, 2019.
 39. Süzen, A.A., Developing A Multi-Level Intrusion Detection System Using Hybrid-Dbn. Journal Of Ambient Intelligence And Humanized Computing, 1-11, 2020.
 40. Zemouri R., Zerhouni N., Racoceanu D., Deep Learning in The Biomedical Applications: Recent And Future Status. Applied Sciences, 9 (8), 1526, 2019.
 41. LeCun Y., Bengio Y., Hinton G. Deep Learning. Nature, 521, 436-444, 2015.
 42. Karaali İ., Eminağaoğlu M., A convolutional neural network model for marble quality classification, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (1), 347-358, 2021.
 43. Analyticssteps, 2020, <https://www.analyticssteps.com/blogs/convolutional-neural-network-cnn-graphical-visualization-code-explanation>, Erişim Tarihi: 22.12.2020.
 44. Hidaka A., Kurita T., Consecutive Dimensionality Reduction By Canonical Correlation Analysis for Visualization of Convolutional Neural Networks. In Proceedings of the ISCIE International Symposium on Stochastic Systems Theory and its Applications, 160-167. The ISCIE Symposium on Stochastic Systems Theory and Its Applications, 2017.
 45. Jain G., Mittal D., Thakur D., Mittal M.K., A Deep Learning Approach To Detect Covid-19 Coronavirus With X-Ray Images. Biocybernetics and Biomedical Engineering, 40 (4), 1391-1405, 2020.
 46. ImageNet, 2021, <http://www.image-net.org/>, Erişim Tarihi: 22.02.2021.
 47. Yıldız O., Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study, Journal of the Faculty of Engineering and Architecture of Gazi University, 34 (4), 2241-2260, 2019.
 48. Simonyan K., Zisserman A., Very Deep Convolutional Networks for Large-Scale Image Recognition. Arxiv Preprint Arxiv: 1409, 1556, 2014.
 49. Coşkun M., Yıldırım Ö., Uçar A., Demir Y., An Overview of Popular Deep Learning Methods. European Journal of Technique(EJT), 7 (2), 165-176, 2017.
 50. Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Berg AC., Imagenet Large Scale Visual Recognition Challenge. International journal of computer vision, 115 (3), 211-252, 2015.
 51. Vgg16, 2020 Popular networks, <https://neurohive.io/en/popular-networks/vgg16/>, Erişim Tarihi: 15.12.2020.
 52. Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z., Rethinking The Inception Architecture For Computer Vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, 2818-2826, 2016.
 53. Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q., Densely Connected Convolutional Networks. In Proceedings of the IEEE conference on computer vision and pattern recognition, 4700-4708, 2017.
 54. He K., Zhang X., Ren S., Sun J., Deep Residual Learning For Image Recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, 770-778, 2016.
 55. Mardani R., Vasmehjani A.A., Zali F., Gholami A., Nasab S.D.M., Kaghazian H., Ahmadi N., Laboratory parameters in detection of COVID-19 patients with positive RT-PCR; a diagnostic accuracy study. Archives of academic emergency medicine, 8 (1), 2020.
 56. Kaggle, 2021, <https://www.kaggle.com/>, Erişim Tarihi: 22.02.2021.
 57. Oyelade O.N., Ezugwu A.E., A Deep Learning Model Using Data Augmentation for Detection of Architectural Distortion in Whole and Patches of Images. Biomedical Signal Processing and Control, 65, 102366, 2021.

58. Liang G., Zheng L. A Transfer Learning Method with Deep Residual Network for Pediatric Pneumonia Diagnosis. *Computer methods and programs in biomedicine*, 187, 104964, 2020.
59. Deniz E., Şengür A., Kadiroğlu Z., Guo Y., Bajaj V., Budak Ü., Transfer Learning Based Histopathologic Image Classification for Breast Cancer Detection. *Health information science and systems*, 6 (1), 1-7, 2018.
60. Jaiswal A., Gianchandani N., Singh D., Kumar V., Kaur M., Classification of the COVID-19 Infected Patients Using DenseNet201 Based Deep Transfer Learning. *Journal of Biomolecular Structure and Dynamics*, 1-8, 2020.
61. Pires de Lima R., Marfurt K., Convolutional Neural Network for Remote-Sensing Scene Classification: Transfer learning analysis. *Remote Sensing*, 12 (1), 86, 2020.
62. Pan H., Pang Z., Wang Y., Wang Y., Chen L., A new image recognition and classification method combining transfer learning algorithm and mobilenet model for welding defects. *IEEE Access*, 8, 119951-119960, 2020.

