

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

**DERİN ÖĞRENME İLE GÖRÜNTÜ İŞLEME: ENDÜSTRİYEL
PARÇA ÜRETİMİNİN DERİN ÖĞRENME SAYESİNDE YÜZEY
HATA TESPİTİ (GÖRÜNTÜLEME ÜZERİNE UYGULAMA)**

Yavuz Selim BALCIOĞLU

DOKTORA TEZİ

İŞLETME ANABİLİM DALI

GEBZE

2023

T.C.

GEBZE TEKNİK ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

**DERİN ÖĞRENME İLE GÖRÜNTÜ
İŞLEME: ENDÜSTRİYEL PARÇA
ÜRETİMİNİN DERİN ÖĞRENME
SAYESİNDE YÜZEY HATA TESPİTİ
(GÖRÜNTÜLEME ÜZERİNE UYGULAMA)**

Yavuz Selim BALCIOĞLU

DOKTORA TEZİ

İŞLETME ANABİLİM DALI

Tez Danışmanı

Prof. Dr. Bülent SEZEN

GEBZE

2023



DOKTORA JÜRİ ONAY FORMU

GTÜ SOSYAL BİLİMLER Enstitüsü Yönetim Kurulu'nun 11/01/2023 tarih ve 2023/02-03 sayılı kararıyla oluşturulan jüri tarafından 20/01/2023 tarihinde tez savunma sınavı yapılan Yavuz Selim BALCIOĞLU'nun tez çalışması İŞLETME Anabilim Dalında DOKTORA tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : PROF.DR. BÜLENT SEZEN

ÜYE

: DOÇ.DR. M. ŞAHİN GÖK

ÜYE

: PROF.DR. ERKUT ALTINDAĞ

ÜYE

: PROF. DR. AYŞE GÜNSEL

ÜYE

: DOÇ. DR. FARİD HUSEYNOV

ONAY

Gebze Teknik Üniversitesi Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Verilerden bilgi türetme, deneyimleme, öğrenme ve karar verme şeklimizin merkezinde yer almaktadır. Makine öğrenimi ve veri bilimi ardışık düzenleri, yüksek enerji, astronomi ve genetik dahil olmak üzere tüm alanlarda sürekli artan miktarda veriden bilgi çıkarmak için kapsamlı bir şekilde uygulanmaktadır. Bu işlem hatları, veriler üzerinde birden çok aşamadan oluşmaktadır. Bunlar, model tasarımı, eğitim ve test aşaması olarak ayrılmaktadır. Farklı aşamaların kendi algoritmaları ve teknikleri bulunmaktadır, ancak ortak bir zorluğu paylaşmaktadırlar. Bu zorluk, büyük veri kümeleri üzerinde tekrarlanan hesaplamaları içermektedir. Bu darboğaz, makine öğrenimini yavaşlatmaktadır. Bu durum yalnızca gecikmeye duyarlı uygulamalar için değil, aynı zamanda bu darboğazın bir sonucu olarak, üretilen verilerin yalnızca bir kısmı işlenebilmekte, bu da daha düşük kaliteli modellere ve daha az kararlı sistemlere yol açmaktadır. Makine öğreniminin bir sonraki evresi derin öğrenme sistemleridir. Bu sistemler, dört kritik aşamada uygulanmaktadır. Bunlar, veri keşfi başta olmak üzere, model tasarımı, model eğitimi, model dağıtımı şeklinde devam etmektedir. Burada belirtilen bu süreçlerin en önemli unsuru, verinin olabilecek en yüksek hızda işlenmesidir. Bu çalışmada, karmaşık kusur modellerini otomatik olarak algılamak için derin öğrenme tabanlı bir görüntü işleme sistemi kullanılmıştır. Kurulan bu sistem ile, on farklı parça yüzeyi üzerinde, binden fazla görüntü ile piksel boyutunda karelere ayrılmış olan yüzey alanlarının, gri renk derinliğinde çözülmesi sağlanmıştır. Bu çözümleme aşamasına kısaca “k” parametresi denmektedir. Görüntülerden gri renk paleti seviyesinde çıkarılan renk değerleri, görüntü analizini oluşturmak için kullanılmıştır. Test aşaması süresince k parametresi, ilk olarak iki faktörlü enterpolasyon olmak üzere, üç faktörlü enterpolasyon yöntemi ile performans testine tabii tutulmuştur. Bir sonraki performans doğrulama aracı olarak, sinyal gürültü oranı değerleri baz alınarak, görüntü kenar pikselizasyon yöntemlerinden farklı on uygulama ile performans testleri tamamlanmıştır.

Anahtar Kelimeler: Derin öğrenme, metal parça, görüntü işleme, pikselizasyon

SUMMARY

Deriving knowledge from data is central to the way we experience, learn, and make decisions. Machine learning and data science pipelines are applied extensively to extract knowledge from an ever-increasing amount of data in all fields, including high energy, astronomy, and genetics. These pipelines consist of multiple stages for the data. These are divided into model design, training, and testing phases. The different stages have their own algorithms and techniques, but they share a common challenge. This challenge involves iterative computations on large datasets. This bottleneck slows down machine learning. This is not only for latency-sensitive applications, but as a result of this bottleneck, only some of the data generated can be processed, leading to lower-quality models and less stable systems. The next phase of machine learning is deep learning systems. These systems are implemented in four critical phases. These continue in the form of model design, model training, model distribution, and especially data exploration. The most important element of these processes mentioned here is the processing of data at the highest possible speed. In this study, a deep learning-based image processing system is used to automatically detect complex defect models. With this system, it has been ensured that the surface areas divided into pixel-sized squares with more than a thousand images on ten different part surfaces are resolved in gray color depth. This analysis step is called the "k" parameter for short. The color values extracted from the images at the grayscale color palette level were used to create the image analysis. During the testing phase, the k parameter was subjected to performance testing with the three-factor interpolation method, first with two-factor interpolation. As the next performance verification tool, performance tests were completed with ten different applications of image edge pixelization methods, based on signal-to-noise ratio values.

Keywords: Deep learning, image processing, pixel based, powder metallurgy

TEŞEKKÜR

Öncelikle tezimin başkanı Prof. Dr. Bülent SEZEN'e, bu çalışmanın gerçekleşmesinde desteğini esirgemeyen hocama sonsuz teşekkürlerimi sunarım. Tüm tez sürecinde benimle görüşlerini paylaştı ve beni sürekli cesaretlendirdi. Tez jürimin diğer üyeleri olan Doç.Dr. M.Şahin GÖK, Prof.Dr. Erkut ALTINDAĞ, Doç.Dr. Farid HÜSEYNOV ve Prof.Dr. Ayşe GÜNSEL hocalarım, çalışmam boyunca beni sabırla destekledi ve cesaretlendirdi. Çok yararlı yorumları için tez komiteme özel bir teşekkür borçluyum.

Akademik sürecimde desteklerini esirgemeyen Prof.Dr. Gökhan ÖZER hocama sonsuz sevgi ve saygılarımı sunarım.

Çalışmamı tamamlamamda desteğini esirgemeyen arkadaşlarım A. Kürşat MERTER ve Melike ARTAR'a sonsuz teşekkürlerimi sunarım.

Hayatımda büyük etkisi olan anne ve babama minnetle teşekkür ederim. Her zaman bana hedeflerime ulaşmamda teşvik ve motivasyon verdiler. Onların desteği akademik kariyerimde beni her zaman cesaretlendirmiştir.

İÇİNDEKİLER

ÖZET	iii
SUMMARY	iii
TEŞEKKÜR	iv
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	x
SİMGELER VE KISALTMALAR LİSTESİ	vii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
3. TOZ METALÜRJİSİ	10
3.1 Toz Metalürjisi Üretim Prosesleri ve Parametreleri	10
3.1.1 Toz Karıştırma	11
3.1.1.a Toz Malzeme Karışımı	12
3.1.1.b Bağlayıcılar	12
3.1.1.c Top-Toz Oranı	12
3.1.2 Presleme	13
3.1.2.a Kalıp Doldurma	14
3.1.2.b Kalıp Basıncı	14
3.1.2.c Kalıp Çıkarma	14
3.1.3 Sinterleme	14
3.1.3.a Sıcaklık	15
3.1.3.b Tutma Zamanı	15
3.1.3.c Nem Dengesi	15
4. DERİN ÖĞRENME	17
4.1. Derin Öğrenme Algoritmaları	22
4.1.a Evrişimli Sinir Ağları	22
5. YÖNTEM VE UYGULAMA	26
5.1. DENEYSEL TASARIM (DOE)	26
5.1.a. Deneysel tasarım: Plackett-Burman Deney Tasarımı	26
5.1.b. Toz Metalurjisinde Kullanılan Proses Parametrelerinin Optimizasyonu: Box-Behnken Deney Tasarımı	28
5.1.c. Risk Analizi: Plackett-Burman Deney Tasarımı	32
5.2. SİSTEM TASARIMI	36
5.3. UYGULAMA TASARIMI	42

5.3.a K detektörü	43
5.3.b Piksel yama boyutu seçimi	44
5.3.c Renk boyutunun değişimi	45
5.3.d Uzamsal olarak alçak piksel görüntüleme	48
5.3.e Boyutsal-Varyant Projeksiyon	48
5.3.f Tanımlanmış benzer kusurlar üzerinden hedef kusurları tahmin etme	51
5.4 DENEYLER VE SONUÇLAR	59
5.4.a Analiz Çalışması	61
5.4.b 2 faktörlü enterpolasyon	62
5.4.c 3 faktörlü enterpolasyon	63
5.4.d Özellik çıkarma modeli	64
5.4.e Sınıflandırma modeli	65
5.4.f Aşırı uyum minimizasyonu	65
5.4.g Sentetik veri artırma	66
5.4.h Eğitim detayları	66
6. SONUÇ VE ÖNERİLER	72
6.1. Teorik çıkarımlar	73
6.2. Yönetimsel çıkarımlar	73
6.3. Kısıtlar ve Gelecek araştırmalar	73
KAYNAKLAR	75
EKLER	89
KİŞİSEL YAYIN VE ESERLER	92
ÖZGEÇMİŞ	88

SİMGELER VE KISALTMALAR LİSTESİ

Simgeler ve Açıklamalar

Kısaltmalar

DESA	:	Derin Evrişimli Sinir Ağları
YZ	:	Yapay Zekâ
YSA	:	Yapay Sinir Ağları
DSA	:	Derin Sinir Ağları
ESA	:	Evrişimli Sinir Ağları
AÖM	:	Kuvvet
ÇKA	:	Aşırı Öğrenme Makinesi
DVM	:	Kilometre
EYKA	:	Çok Katmanlı Algılayıcı
KBA	:	Destek Vektör Makinesi
AOB	:	En Yakın Komşu Algoritması
SA	:	Manyetik alan vektörü
NB	:	Komşu Bileşenleri Analizi
OSA	:	Adres Oluşturma Birimi
TBA	:	Sinir Ağları
YP	:	Naive Bayes
GPU	:	Saniye
DP	:	Olasılıksal Sinir Ağı
KF	:	Temel Bileşenler Analizi
KA	:	Yanlış Pozitif
KY	:	Kenar Yumuşatma
UKSB	:	Uzun Kısa Süreli Bellek

WB	:	Kalman Filtresi
CPU	:	İşlemci
RNN	:	Tekrarlayan Sinir Ağları
DVR	:	Destek Vektör Regresyonu
AMB	:	Aritmetik Mantık Birimi
UPA	:	Uygulama Programlama Arayüzü
BKH	:	Blok Kullanılabilirlik Haritası
İKD	:	İkili Karar Diyagramı
İBN	:	İkili Büyük Nesne
SAH	:	Sabit Açısal Hız
KBÇE	:	Kod Bölmeli Çoklu Erişim
BDM	:	Bilgisayar Destekli Mühendislik
ODÇ	:	Ortak Dil Çalışması
KKA	:	Karakter Kullanıcı Arayüzü
SBKNİ	:	Saniye Başına Kayan Nokta İşlemleri
VSK	:	Veri Soyutlama Katmanı
VKD	:	Veri Kontrol Dili
VKG	:	Veri Kanalı Görüntüleme
DVA	:	Dinamik Veri Alışverişi
VAN	:	Veri Aktarım Nesnesi
VSDK	:	Veri Sistemleri Dilleri Konferansı

ŞEKİL LİSTESİ

<u>Şekil No:</u>	<u>Sayfa</u>
Şekil 1. Toz Metalürjisi Üretim Prosesleri	23
Şekil 2. Evrişimli sinir ağı mimarisi	35
Şekil 3. Değişkenlerin etkisini gösteren S/N grafiği	46
Şekil 4. Üretim kalitesi verimliliği için kritik olan formülasyon ve proses değişkenlerini gösteren Pareto grafiği	47
Şekil 5. TM üretiminde karşılaşılan hatalar	50
Şekil 6. Uygulama sisteminin şeması	51
Şekil 7. Geliştirilen sistemin görüntüsü	52
Şekil 8. Metodoloji akış şeması	53
Şekil 9. Bir görüntü üzerindeki belirlenen noktanın 3x3 şeklinde taranması	55
Şekil 10. Gri tonlamalı görüntüler için seviye dönüşüm fonksiyonları değerleri (a), (b) – Önerilen şeklimiz (c)	56
Şekil 11. Renk paleti üzerinde “k” değerleri	59
Şekil 12. Örnekleme grubunda kullanılan hatalı parçalara ait 3 boyutlu grafik ile kusur tespitleri	60
Şekil 13. (a) - Yüzey görüntüsü alınan metal somun parçasının tespit edilen “k” yüzde değerleri (hatasız ürüne aittir). (b) - Yüzey görüntüsü alınan metal somun parçasının (arızalı ürüne ait) tespit edilen “k” yüzde değerleri	60
Şekil 14. Operatör zinciri	71
Şekil 15. Test parçaları: ID 1’den 10’a kadar	72
Şekil 16. Farklı mimariler için eğitim ve doğrulama sonuçları	80

TABLO LİSTESİ

<u>Tablo No:</u>	<u>Sayfa</u>
Tablo 1. Plackett-Burman deney tasarımlarında kullanılan faktörler ve seviyeler	39
Tablo 2. Plackett-Burman Tasarım Test Matrisi	40
Tablo 3. Box-Behnken Deney Tasarımında Kullanılan Faktörler ve Düzeyler	42
Tablo 4. Box-Behnken Deney Tasarımında belirli bir düzeyde kullanılan formül ve işlem parametreleri	42
Tablo 5. Box-Behnken Tasarım Test Matrisi	43
Tablo 6. Plackett-Burman deney tasarımı sonucunda elde edilen bağımlı değişkene ait değerler	45
Tablo 7. Plackett-Burman deney tasarımı ile elde edilen bağımlı değişken değerlerinin istatistiksel analiz sonuçları	47
Tablo 8. Nicel enterpolasyon analizi	74
Tablo 9. K dedektörü ile Nicel enterpolasyon analizi	75
Tablo 10. Modellerin 2 faktörlü enterpolasyon SGO karşılaştırmaları, koyu kırmızı renkli olan veriler en yüksek SGO skorlarını göstermektedir	77
Tablo 11. Modellerin 3 faktörlü enterpolasyon SGO karşılaştırmaları, koyu kırmızı renkli olan veriler en yüksek SGO skorlarını göstermektedir	77
Tablo 12. Eğitim, doğrulama ve test sonuçları ile DESA model yapılandırmaları ve ayarları	81
Tablo 13. Bu çalışmada daha önceki çalışmalar ile, bu çalışmada oluşturulan model performanslarının karşılaştırılması	83
Tablo 14. DESA mimarisi ile kullanılan parametrelerin karşılaştırılması, bu çalışma ve önceki çalışma	84

1. GİRİŞ

Toz metalürjisi (TM), malzemelerin veya bileşenlerin metal tozlarından yapıldığı çok çeşitli yolları kapsayan bir terimdir. Toz metalürjisi işlemi, küçük bileşenlerden büyük ölçekli yapılara kadar çeşitli metal ürünler oluşturmak için kullanılabilir. İşlem çok yönlüdür ve yüksek mukavemetten yüksek kaliteye kadar çok çeşitli özelliklere sahip ürünler oluşturmak için uyarlanabilir(Diener, Zocca and Günster, 2021). Toz metalürjisi, metal ürünler yaratmanın uygun maliyetli bir yoludur ve karmaşık şekil ve tasarımlara sahip ürünler için kullanılmaktadır.

Toz metalürjisini kullanmanın bazı avantajları bulunmaktadır. İlk olarak, diğer imalat yöntemleri kullanılarak üretilmesi zor veya imkânsız olan karmaşık şekillerin oluşturulmasına izin vermektedir(German, 1984). İkincisi, nihai ürünün özellikleri, toz karışımının bileşimi değiştirilerek özelleştirilebilir. Son olarak, toz metalürjisi nispeten verimli(Fang and Zheng, 2020) ve uygun maliyetlidir, bu da onu seri üretim için popüler bir seçim haline getirmektedir.

Derin öğrenme, geleneksel yöntemler için çok karmaşık olan verilerin analiziyle ilgilenen bir makine öğrenimi dalıdır. Genellikle görüntü tanıma ve işleme için kullanılmaktadır(Gao *et al.*, 2019). Derin öğrenme çalışmaları içerisinde yüzey kusurları, bir malzemenin yüzeyinde işlevi veya görünümü ile ilgili sorunlara neden olabilecek kusurları tespit etme amacıyla kullanılmaktadır. Üretim kusurları ise, çevresel hasar, aşınma ve yıpranma dahil olmak üzere çeşitli faktörlerden kaynaklanmaktadır.

Bu çalışma kapsamında toz metalürjisi üretimi proseslerinin derinlemesine incelenmesi, bu üretim proseslerinin alt üretim proseslerine kadar neler olduğunun tespit edilmesi ve tespit edilen parametre değerleri üzerinden deneysel tasarım çalışması yapılması hedeflenmektedir. Bununla birlikte, çalışmanın ikinci evresinde deney çalışmasında kullanılacak olan parçaların yüzeylerini yakalayabilen bir görüntü işleme sistemi kurulması planlanmaktadır. Bir sonraki aşamada, elde edilen görüntü verilerinin piksel boyutunda, bu çalışmada geliştirilen k parametresi ile gri renk derinliğinde yüzey hata tespiti noktasında efektif bir başarı elde edilmesi amaçlanmaktadır.

Bu tez ařaęıda belirtilen altı blme ayrılmıřtır. Blm 1’de alıřma hakkında bilgi verilmiřtir. Blm 2, yzey kusurları kavramından bahsetmekte ve bu alanda daha nce yapılmıř alıřmalar gzden geirilmektedir. Blm 3’te toz metalrjisi kavramı ve prosesleri anlatılmıřtır. Blm 4, derin ğrenme kavramı, prosedrleri ve bu alanda daha nce yapılmıř alıřmalar gzden geirilmektedir. Blm 5, arařtırma konusuna ait yntem ve uygulama sreleri hakkındadır. Bu blmde ilk olarak gerekli deneysel istatistiksel yntemler ve aralar kullanılarak analiz ařaması tamamlanmıřtır. Bu blmn ikinci kısmında, grnt toplamak iin kurulan sistem anlatılmaktadır. Bu blmde kurulan sistem ile toplanan grnt verileri zerinden tek kanal boyutunda “k” parametresi ile piksel enterpolasyonu testleri yapılmıř ve model doęrulaması yapılmıřtır. Blm 6’da arařtırma bulguları zetlenmiř ve bu ıktılar zerinden tretilmiř sonular sunulmuřtur. Bu blmde ayrıca gelecekteki olası arařtırma ynleri nerilmektedir.

2. LİTERATÜR TARAMASI

Bu çalışmanın odak noktası olan toz metalürjisi metal parça endüstrisinde popüler olarak kullanılan üretim yöntemlerinden biridir. Ancak, popüler olan bu yöntemin yaygın sorunları bulunmaktadır. Örneğin parçaya ait yüzey kusurları sıklıkla rastlanan sorundur ve tespiti genellikle zordur. Son yıllarda bu üretim konusu hakkında önemli çalışmalar yapılmıştır. Toz metalürjisi ile parça yüzeyine ait çalışmaları incelediğimizde, Fan ve arkadaşları, gözenekli toz parçalarının yüzeyini incelemek, sistem gürültüsü sorunlarını bulmak ve başarılı bir yüzey hatası algılama sistemi gösterebilmek için optik bir sistem kurmuşlardır (Fan *et al.*, 2010). Yüzey kusurunu alt tabakadan ayırmak ve parça yüzeyinde herhangi bir işaret olmadan kütle akışını konumlandırmak için karmaşık algoritmaların kullanılmasını önermektedirler. Bununla birlikte, toz parçaların ve hassas alanların ayrılmasına dayalı olarak anormalliklerin meydana geldiği diğer bölgeler için bir optik yüzey hatası algılama sisteminin başarı durumunu değerlendirmişlerdir.

Grisson ve Remy, bir yorulma döngüsü sırasında çatlak başlatıcıların ve çatlakların birikmiş hacim değişiklikleri açısından toz metalürjisi üretiminde alaşım yorulma arızasını tanımlamışlardır. Bununla birlikte, yorulma çatlaklarını başlatan kusurların boyutlarını, şeklini ve yerini hesaba katan toz metalürjisi süreci için süper alaşımların yorulma kırılmasının olasılıksal modelini geliştirmişlerdir (Grisson and Remy, 1997). Çatlakları başlatan inklüzyonların boyutu, şekli ve konumu dikkate alınarak toz metalürjisi yönteminde süper alaşımların arızalanmasına kadar yorulma çatlaklarının büyüme olasılığını hesaplamışlardır. Çalışma içerisinde beklenen sonuçlar deneysel sonuçlarla karşılaştırılmış ve model tahminlerinin deneysel sonuçlarla iyi bir uyum gösterdiği tespit edilmiştir.

Xiao ve arkadaşları, kusur tespiti için kusurların diğer geleneksel yöntemlerden daha yüksek tanıma doğruluğu ile tespit edilmesini sağlayan yeni genelleştirilmiş SHGA-PSO-BP (Serial hybrid genetic algorithm, particle swarm optimization, back propagation) algoritmasını önermişlerdir. Dişlileri otomatik olarak teşhis etmeyi öğrenen, aynı zamanda kullanıcının farklı dişli kusurlarına yanıt olarak özel sinir ağıları oluşturmasını sağlayan, otomatikleştirilmiş dişli diş görüntü incelemesi ve teşhisi için basit ve verimli bir algoritma geliştirmişlerdir (Xiao *et al.*, 2021). Makinelere dişlileri tür ve kusur kalitesine göre ayırt etmeyi öğretmek için genetik algoritmaları ve

parçacık sürüşü optimizasyonunu birleştirmek için Gauss Proses sinir ağlarını kullanmışlardır. Çalışma sonucunda, çizikler ve işaretler gibi belirli kusur türlerinin görüntü teşhisi, maksimum fark değerinin iki 'ye eşit olduğunu ve dört veri seti arasındaki ortalama değer farkı sırasıyla 0.8, 0.6, 1.1 ve 1,0 olarak tespit edilmiştir. Bu da farklı kusur türlerini başarılı bir şekilde ayırt edebildiklerini göstermektedir.

Polasik ve arkadaşları, otomotiv endüstrisinde ve diğer sektörlerde kullanılan demirli toz metalürji malzemelerinde yorulma çatlaklarının başlamasını ve yayılmasını karakterize etmişlerdir (Polasik, Williams and Chawla, 2002). Gözeneklilik, yüzey gözenekliliği gibi malzemeler için yorulma davranışını, gözenek boyutu, gözenek şekli gibi mikro yapısal özellikleri ve çatlak sapması üzerindeki heterojen yapıyı incelemişlerdir. İnceledikleri malzemelerin mukavemetinin çeşitli mikro yapı tiplerine bağlı olduğunu ve bu faktörlerin dengelenmesiyle yorulma mukavemetinde bir gelişme sağlanabileceğini göstermişlerdir.

Zaykin ve Aliyev, yüzey özelliklerinin radyasyon işleminden nasıl etkilendiğine ve bunun metal tozu işlemeyi nasıl etkilediğine odaklanarak, metal tozu radyasyon işlemlerini araştırmışlardır. Işınlama yoluyla bir malzemenin dönüşümünü açıklayarak, radyasyonun parçacıkları atomik düzeyde nasıl değiştirdiğini göstermişlerdir (Zaykin and Aliyev, 2002). Bu çalışma, radyasyonla indüklenen nano kristal malzeme oluşturmak için radyasyon tedavisinin toz işleme üzerindeki etkisini göstermektedir. Işınlanmanın neden olduğu derin yapısal değişikliklerin deneysel kanıtlarını ve bunun sonucunda ortaya çıkan yeni “şekilsiz” durumu göstermektedir.

Dunstan ve arkadaşları, deneysel verilerle doğrulanmış, malzeme mikro yapısına dayalı olarak, eklemeli olarak üretilmiş malzemelerin yorulma testi için bir çerçeve önermişlerdir. Çalışmalarında, net şekle yakın üretim teknikleri ile üretilen büyük ölçekli metalürjik mikro yapıların fraktografik analizi, mikro yapısal kaymanın yorulma başarısızlığının bir nedeni olduğunu göstermişlerdir (Dunstan, Paramore and Fang, 2018). Bu çalışma, yorulma ve üretim ayarlarıyla ilgili farklı mikro yapısal koşullar altında mikro gözeneklilik eşikleri için kılavuz sağlamaktadır.

Li ve arkadaşları, sürünme beslemeli taşlanma ve yüksek alümina taşlama disklerini birleştirerek işlenmiş yüzey pürüzlülüğünü en aza indirmek için yeni bir yaklaşım önermişlerdir. Toz metalürjisi nikel bazlı süper alaşım FGH96 kullanarak sürünme beslemeli taşlamada iki aşındırıcı diskin taşlama özelliklerini araştırmışlardır.

Çalışmalarına göre, toz metalürjisi nikel bazlı süper alaşım için sürünme beslemeli taşlama işlemi sırasında karakteristik taşlama davranışını ve takım aşınmasını ortaya çıkarmaktadır (Li *et al.*, 2020). Taşlama parametrelerinin işlenmiş yüzey pürüzlülüğü, takım aşınması, taşlama oranı ve taşlama kuvveti üzerindeki etkilerini ayrıntılı olarak analiz etmişlerdir.

Ludwig ve arkadaşları, gözlenen yüzey gerilim dağılımları açısından hatalı yüzey kusurlarının doğrudan üç boyutlu sayısal modellemesi üzerine bir çalışma yapmışlardır. Enjekte edilen bir akım nedeniyle iki boyutlu yüzey kıran çatlağını sayısal olarak araştırmışlar ve uygun bir yineleme şemasıyla elektrostatik integral denklemini çözmüşlerdir (Ludwig, Makarov and Apelian, 1998). Saç çizgisi çatlaklarının voltaj tepkisini incelemek için basit bir görüntü kaynağı modeli uygulamışlar ve modeli geliştiren sayısal çözümlerle karşılaştırmışlardır. Ayrıca, iki boyutlu ince çizgi çatlağının voltaj yanıtını değerlendirilen yüzey voltajlarından ve akım yoğunluklarını değerlendirmek için bir görüntü kaynağı modeli ortaya atmışlardır.

Benzerrouk ve arkadaşları, toz kompaktlardaki yüzey altı kusurlarını tespit etmek ve gereksiz hurdayı azaltmak için kullanılabilecek bir ısı darbesi görüntüleme tekniği olan geçici termografiyi önermektedirler. Çalışmalarında, yeşil durumdaki metal toz kompaktlarındaki yüzey altı kusurlarını ölçmek ve tespit etmek için darbeli bir termografi yaklaşımının nasıl kullanılabileceğini göstermektedirler. Saatte 1000 parçaya varan hızlarda, sıkıştırma presinden çıkarken toz sıkıştırmalardaki yüzey altı kusurlarını tespit etmek için geçici termografinin nasıl kullanılabileceğini gösteren ön sonuçları bu çalışmalarında göstermektedirler (Benzerrouk, Ludwig and Apelian, 2007). Darbeli termografinin, daha ileri üretim süreçlerinden önce kritik kusurlarını tespit ederek metal tozu ile üretilen üretim hurdalarını azaltmak için standart görüntüleme teknikleriyle birlikte kullanılabileceğini tespit etmişlerdir.

Wang ve arkadaşları, çeşitli SiC takviyeli metal matrisli kompozitlerde parçacık çatlaması nedeniyle oluşturulan yeni yüzey alanı miktarını ve çatlamış parçacıkların sayı fraksiyonlarını nicel olarak incelemişlerdir. Çalışmalarının amacı parçacık boyutunun ve matris akma dayanımının, parçalanmış parçacıkların sayı fraksiyonu ve parçacık çatlaması tarafından oluşturulan yeni yüzey alanı üzerindeki etkisini araştırmaktadır (Wang, Janowski and Patterson, 1995). Çalışmaları, parçacık

çatlama tarafından oluşturulan yeni yüzey alanı ile yerel gerinim arasında doğrusal bir ilişki olduğunu göstermektedir; bu parçacık çatlamaının esas olarak büyük parçacıklara sahip kompozitlerde kırılma bir şekilde meydana geldiğini göstermektedir. Buraya kadar incelenen çalışmalarda mekanik olarak kusurlara ait bir ölçme ve değerlendirme yöntemleri uygulanırken, günümüz dünyasının geldiği noktada, yapay zeka teknolojilerine ihtiyaç duyulmaktadır.

Son yıllarda, derin öğrenme algoritmaları, birçok endüstride kullanılmaya başlanmıştır. Toz metalürjisi birçok endüstri için önemli bir süreçtir ve yüzey kusurları ciddi sorunlara neden olmaktadır. Derin öğrenme, ürünlerin kalitesini arttırmaya ve üretim maliyetlerini düşürmeye yardımcı olabilmektedir. Tao ve arkadaşları, karmaşık üretim alanlarını, küçük bir dizi kusur sınıfına dönüştürerek büyük endüstriyel ortamlarda metal yüzey kusurlarını tespit etmek için bir yaklaşım önermektedirler. Çalışmalarında, metal yüzey kusurlarını tespit etmek için kademeli otomatik kodlayıcıları kullanmışlar ve doğrudan üretim süreçlerinde kullanılan makine parçalarına eşlenen hassas sınıflandırıcıları oluşturmak için evrişimli sinir ağı kurmuşlardır (Tao *et al.*, 2018). Gerçek endüstriyel ortamdan bölümlere ayrılmış ve sınıflandırılmış kusurları, kademeli otomatik kodlayıcı ve kompakt bir evrişimli sinir ağı ile yukarıdan aşağıya bir ağ tarafından doğru bir şekilde tespit edebilmişlerdir.

Soukup ve Mörk çalışmalarında, ray yüzeylerinin karanlık alan görüntülerinden kusur algılamayı iyileştirmek için CNN'leri ve çok ölçekli modelleri kullanmışlardır. Ayrıca, metal yüzeylerindeki kusurları, bozulma sürecinde erken önlem alınmasına izin verecek şekilde otomatik olarak tanımak için derin öğrenmeyi kullanmayı önermektedirler. Metal yüzey kusur tespiti için çok ölçekli bir CNN'ni eğitmek için 928 görüntü yamasından oluşan bir veri seti oluşturmuşlardır (Soukup and Huber-Mörk, 2014). Ön eğitim ve güçlendirmeyi birleştiren bu yaklaşımın, bu teknikleri ayrı ayrı kullanmaya kıyasla performansı iyileştirdiğini göstermektedir. Ortaya çıkan model, metal yüzeylerdeki boşlukları, kraterleri ve çarpma noktalarını düşük yanlış pozitiflik oranıyla tespit edebilmektedir.

Xing ve Jia çalışmalarında, simetrik modüller ve FPN yapısı ile evrişim ağı sınıflandırıcı çerçevesi, kayıp fonksiyonu optimize edilmiş IOU (XIoU) ve kayıpskotastik gradyana dayalı eğitim algoritması dahil olmak üzere, katı olmayan nokta bulutlu algılama için uçtan uca bir çözüm önermektedirler (Xing and Jia, 2021).

Çalışmaları, YOLOv3 ve Darknet-53'nin yapı katlarının rijit olmayan nokta bulutunu tespit etme, sınıflandırma sonuçlarını analiz etmekte ve önerilen yöntemin iki modelden daha iyi performans gösterdiğini ortaya koymaktadır. Ayrıca, iş parçası üzerindeki rijit olmayan nokta bulutu kusurlarını tespit etmek için açık bir kaynak sağlamakta, bu da denetimin hızını ve doğruluğunu büyük ölçüde arttırmaktadır.

He ve Liu çalışmalarında, devre kartlarındaki kusurları tespit etmek, iyi bir tahmin yeteneği geliştirmek ve verimliliği bulmak için derin bir sinir ağı önermektedirler. Çalışmaları, doğruluğu ve yanlış pozitif oranları vurgulayarak, yöntemlerin genel performansının ölçülmesini ve analizini sağlamaktadır (He and Liu, 2020). Ayrıca, yanlış pozitif azaltma ve sınıflandırma yoluyla kapasitör yüzey görüntülerinde görüntü kalitesi kusurlarının ayrıntılı analizini gerçekleştirmişlerdir.

Xu ve arkadaşları, görüntü düzeyinde etiketler aracılığıyla anormalliği belirlemek için ESA'ları uygulayarak yüzeylerdeki kusurları tespit etmek için yeni bir çerçeve önermektedirler. Büyük miktarda etiketlenmiş eğitim verisi gerektirmeyen üretim hatlarında düşük maliyetli hata tespiti için önerilen denetimli derin öğrenme yöntemi kullanmışlardır (Xu *et al.*, 2020). Uyguladıkları modelin etiket dengesizliğinin üstesinden gelmek ve yerleştirme için tipik olarak gerekli olan sınırlayıcı kutulama yönteminden faydalanmışlardır. Bununla birlikte veri kümesine ait diğer bilgilerin yokluğunu telafi etmek için yeni bir öğrenme yaklaşımı uygulamışlardır.

Cao ve arkadaşları, yüzey kusurlarının tespiti için tamamen evrişimli bir sinir ağı tabanlı segmentasyon yöntemi önermişlerdir. Kodlayıcı-kod çözücü yapısı ve çok düzeyli özellik füzyonu sayesinde görüntülerden yüzey kusurlarını bölümlere ayırma sorununu ortadan kaldırmışlardır (Cao, Yang and Yang, 2021). Çalışmaları, önerilen yöntemin diğer yöntemlere kıyasla iyi bir performans gösterdiğini göstermektedir.

Yuan ve arkadaşları, karmaşık kusur özelliklerini yakalayan kusur tespiti için uçtan uca bir hedef tespit modeli önermektedirler. Uçtan uca hedef tespiti ve hafif evrişimli ağ yapısı kullanılarak, demiryolu yüzey kusur tespiti için yeni bir yaklaşım sunmuşlardır (Yuan *et al.*, 2019). Hata tespit modelleri, tespit, kategorizasyon ve lokalizasyon olmak üzere üç aşamadan oluşmaktadır.

Lin ve arkadaşları, iki modelden oluşan bir makine öğrenimi hattı tanıtmışlardır. Tanıttıkları bu model, tek atış çoklu kutu detektörü modeli ve çelik yüzeylerdeki üç tür kusuru sınıflandırmak için ResNet tabanlı derin ağ tabanlı bir modeldir. Çeşitli çelik kusurlarını doğru bir şekilde tahmin etmek için büyük ölçekli derin öğrenme modellerinin olanaklarını araştırmışlardır. Ayrıca, küçük ölçekli büyük kapasiteli modellerin kusurlarını daha yüksek hassasiyete sahip, geri çağırma puanlarıyla yüzeylerin doğru bir şekilde tespit edilebildiğini de göstermişlerdir (Lin *et al.*, 2020).

Jia ve arkadaşları, çeşitli kusur modellerine göre ayarlanabilen çelik kusurları için gerçek zamanlı bir görsel denetim sistemi önermişlerdir. Destek vektör makinası kullanılarak çelik yüzey kusurlarının gerçek zamanlı görsel denetimi için bir model ve çerçeve sunmaktadırlar. Özellikleri otomatik olarak öğrenen ve kenar kırılmaları, dolgu çubukları, kavisli parçaları ve yerinden çıkmış kısımlar dahil olmak üzere, çeşitli karmaşık çelik yüzey kusurlarını ele almışlardır (Jia *et al.*, 2004). Önerilen sistemin algılama oranını ölçerek, farklı teknikler kullanarak çeşitli proses görüntülerinden 1000'den fazla çelik yüzey hatası üreterek, sistemin etkinliğini test etmişlerdir.

Wei ve arkadaşları, çubuk çelik yüzey kusurlarını tespit etmek için daha hızlı bir R-CNN ve deforme olabilen evrişime dayalı bileşik bir algılama sistemi önermişlerdir. Hem sınıf hem de ofseti aynı anda öngören standart softmax regresyonunu doğrudan hesaplamak için kurdukları R-CNN, yaygın olarak kullanılan sürgülü pencere yaklaşımından çok daha hızlıdır ve farklı şekillerdeki herhangi bir kusura sağlam bir şekilde uygulanabileceğini göstermişlerdir (Wei, Song and Zhang, 2020). Çalışmalarında, algılama hassasiyetini artıran ve işleme maliyetini azaltan nesneler arasındaki örtüşmeyi azaltmak için deforme olabilen evrişimden yararlanmışlardır.

Su ve arkadaşları, filigran verilerini, dönüşüm alanından daha algılanamaz olan uzamsal alana yerleştiren SVD tabanlı bir damgalama yöntemi geliştirmişlerdir. Çalışmalarında uzamsal alanı ve SVD tabanlı teknikleri birlikte kullanan, renkli görüntüler için algılanması güç bir damgalama yöntemini araştırmışlardır. Çalışmanın katkıları, uzaysal alanda niceleme indeks modülasyonu ile MSV üzerinden görüntü düzeltme ve görüntü ayrıştırmanın sınıflandırılmasıdır (Su, Zhang and Wang, 2022).

Yi ve arkadaşları, bir görüntüdeki sırt/vadi dağılımlarının doğasını farklı bir perspektiften temsil ederek çekirdek nokta tespitini geliştirmek için bir sistem önermişlerdir. Ayrıca, parmak izlerinde tekil nokta tespitinin doğruluğunu

değerlendirmek için yeni yöntemler ve araçlar geliştirmişlerdir. Çalışmalarında ABD polis veri tabanından alınan toplam 398 görüntü üzerinde, performans değerlendirmesi yapılmış ve son derece tutarlı sonuçlar üretmişlerdir (Ye *et al.*, 2022).

Bu tez çalışmasında, deneylerin ilk tasarımı olarak Plackett-Burman deney tasarımı kullanılmıştır. Plackett-Burman deney tasarımı, bağımsız değişkenlerin önemine göre dışlanmasına izin veren, etkili ve yaygın olarak kullanılan bir deney tasarımıdır (Zhang *et al.*, 2012). Birinci deney tasarımında bu faktörler için seçilen düşük ve yüksek değerler Plackett-Burman tasarımında olduğu gibi kabul edilmiş, Box-Behnken deney tasarımında da ortalama seviye kullanılmıştır.

Literatürdeki örneklerden de anlaşılabacağı üzere deneysel tasarım ve analiz için uygun yazılımların kullanılması, çalışmadan elde edilen verilerin kalitesi göz önüne alındığında oldukça önemlidir. Bu tez çalışmasında Minitab 21 (Minitab Ltd., İngiltere) yazılımı deney tasarımlarının kurulmasında, regresyon ve varyans analizlerinde ve grafiklerin düzenlenmesinde kullanılmıştır (Gadhawe, Gadhawe and Dhawale, 2022).

Literatürdeki çalışmalar incelendiğinde, toz metalürjisi üretiminde gerçekleşen üretim proseslerini inceleyen, üretim sonrasında ortaya çıkan hata türlerini belirleyip, sınıflandıran ve buradan çıkan istatistiksel değerleri açıklayan bir çalışma bulunmamaktadır. Bununla birlikte, yüzey kalitesinde ortaya çıkan hata türleri ile sayısal olarak ilişkilendiren ve elde edilen görüntü verilerini, tek kanal piksel boyutunda, k” parametresi aracılığıyla, görüntü frekanslarının çıkarıldığı ve bu sonuçların diğer modeller ile karşılaştırıldığı bir çalışmadır. Yukarıda da görüleceği üzere, daha çok, belirli bir ürünün ya da malzemenin sadece proseslerine ya da sadece yüzey kalitesine odaklıdır. Bu çalışma, yukarıda anlatıldığı üzere, toz metalürjisi sektöründe yer alan firmalar ve üreticiler için üretim proseslerini açıklayan bir çalışma olması hedeflenmektedir. Buna ek olarak üretim proseslerini kategorize eden ve çalışmanın çıktısı açısından parça kalitesine etki eden unsurları anlatarak, bir rehber niteliği taşımaktadır.


3. TOZ METALÜRJİSİ

Gelişmiş bir imalat yöntemi olan toz metalürjisi, teknolojik ürünlerin ana malzemelerinin üretilmesine çok uygun olmakla birlikte, küçük boyuttaki parçaların çok sayıda ve ekonomik üretimini sağlayan bir yöntemdir. Toz metalürjisi, nihai şekle yakın üretim aşamaları olarak sinterleme, sıcak presleme, toz metal enjeksiyonu, nano parçacık teknikleri, mekanik alaşımlıma gibi konularla sürekli gelişen bir pazara sahip olan ileri teknolojilerden biridir. Çok kompleks şekilli ürünlerin daha kolay bir şekilde elde edilmesinde uygulanan bir teknolojidir.

Toz metalürjisi, ana malzemesi metalik ve metalik olmayan farklı malzemelerin kullanılmasına olanak vermektedir. Nihai ürünün metalürjik içeriği ve yoğunluğu basitçe kontrol edilebilmekte ve toz metalürjisi günümüz tasarım mühendislerinin gün geçtikçe dikkatini çekmektedir. Bununla birlikte, üretim hızı çok yüksektir, tozun kalıplara doldurulması ve toz karışımının şekillendirilmesi bir saniyeden kısa zamanda gerçekleşmektedir. İşlem sürecinde meydana gelen toz kaybı, sinterleme aşamasında oluşan hatalı parçalar ile ortaya çıkan kayıplar dışında düşüktür. Bu nedenle toz metalürjisinin maliyet verimliliği yüksektir. Doğru sinterlenmiş parçaların yüzeyleri oldukça düzgündür ve ikinci işlemlere gerek duyulmaz. Bu özellik sayesinde tungsten karbür, titanyum karbür ve elmas benzeri işlenmesi zor malzemelerin işlenmesine imkân vermektedir. Toz metalürjisi ile üretilen parçaların gözeneklilik miktarı kolay bir şekilde kontrol edilebilmekte ve filtre parçaları gibi özel parçalar üretilmektedir. Ayrıca küçük, kompleks şekilli parçalar da bu yöntem ile basit bir şekilde üretilmektedir.

3.1 Toz Metalürjisi Üretim Prosesleri ve Parametreleri

Toz metalürjisinde üç farklı ana üretim prosesi ve on bir adet de alt üretim prosesi olmak üzere toplam on dört farklı üretim prosesi bulunmaktadır. Bunlar sırasıyla, toz hazırlama, presleme, sinterlemedir. Şekil 1 de TM üretim prosesleri gösterilmektedir.



Şekil 1. Toz Metalürjisi Üretim Prosesleri (Karagöz, Yamanoglu and Atapek, 2009)

3.1.1 Toz Karıştırma

Toz karıştırma işlemi, istenilen ebat, şekil ve bileşimdeki tozların yağlayıcı veya bağlayıcı katkı maddeleri ve alaşım elementi tozları ile karıştırılması işlemidir. Karıştırma işlemi homojen bir karışım elde edilene kadar özel bir karıştırıcı ile devam eder. Karıştırma sırasında farklı boyutlardaki tozların homojen bir karışım oluşturmaya özen gösterilir. Karıştırmanın amaçları şunlardır;

- Değişik yöntemlerle üretilen tozlar farklı boyut ve şekillere sahiptir. Üniform özellikte parça üretmek için tozlar karıştırılmalıdır. İdeal bir karışımda her malzemenin tozları üniform olarak karıştırılmalıdır.
- Farklı metal ve diğer malzemelerin tozları özel fiziksel ve mekanik özellikler elde edilmesi amacıyla karıştırılabilir.
- Akış özelliklerini iyileştirmek için toz karışımlara yağlayıcılar eklenebilir. Bu şekilde toz partikülleri ile kalıp arasındaki sürtünme katsayısı azaltılır. Ayrıca kalıbın ömrünü uzatır ve daha düzgün presleme sağlar.

Toz karıştırma, kontaminasyonu ve özelliğin bozulmasını önlemek için kontrollü koşullar altında yapılır. Aşırı karıştırma tozu deforme edecek ve gerinim sertleşmesine neden olacaktır. Toz karıştırma proses adımı toz malzeme karışımının, farklı malzemeler ile karıştırılması şeklinde tamamlanmaktadır. Proses parametreleri, birim cinsinden kullanılmaktadır. Toz karıştırma aşamaları; üç ana kategoriye

ayrılmaktadır. Bunlar sırasıyla, toz malzeme karışımı (kg), bağlayıcılar (gr), top-toz oranı (gr.) şeklindedir.

3.1.1.a Toz Malzeme Karışımı

Toz malzeme karışım süreci, üretime konu olan malzemeyi elde etmek için, daha önce tanımlanmış bilgiler doğrultusunda, kimyasal bileşenlerin, doğru miktarlarda karışım öncesi hazırlanması aşamasıdır. Metalik tozlar, yağlayıcılar ve isteğe bağlı alaşım elementleri ile homojen bir karışım elde etmek için karıştırılır. Yağlayıcı kullanmanın ana amacı, toz kütleleri ile takım yüzeyleri ve kalıp duvarları arasındaki sürtünmeyi azaltmak, tozların sıkıştırma esnasında kaymalarını sağlamaktır. Karıştırma işlemleri, sinterleme sırasında yeni alaşımların oluşturulması, homojen karışımların elde edilmesi ve özel tanecik boyut dağılımının sağlanması amacıyla gerçekleştirilmektedir.

3.1.1.b Bağlayıcılar

Toz enjeksiyon kalıplama gibi kalıplama işlemlerinde, toz bir bağlayıcı içinde kalıplanır. Bağlayıcı toz ile eşit olarak karıştırılmalıdır. Benzer şekilde, preslemeden sonra parçayı kalıptan çıkarmak için gereken stresi azaltmak ve böylece kalıbın ömrünü uzatmak için tozlar organik yağlayıcılarla karıştırılır. Ayrıca, aktif yüzeye sahip olan maddeler, stearik asit gibi, bağlayıcı-toz ıslatmasını artırmada kullanılmaktadır. Bağlayıcılar, parafin benzeri, tozlara ham dayanım sağlamak için de kullanılmaktadır. Bu sayede, öğütme veya atomize edilmek suretiyle küçük parçacık boyutlarına getirilerek presleme öncesi tozun içerisine karıştırılmaktadır.

3.1.1.c Top-Toz Oranı

Top/toz oranı (TTO), hem mekanik (bilye) öğütme hem de mekanik alaşımlamada sıklıkla kullanılan bir işleme parametresidir. Top- oranı değerlerinin belirlenmesi, toz metalürjisi ile üretilecek çelik malzemelerin mikro yapıları ile alaşımlıma tekniğine ve üretim yöntemine bağlıdır. Elde edilen mikrosal yapı, kimyasal bileşime ve mevcut fazlara göre homojen veya heterojen olarak ayrılmaktadır. Ancak mikro yapının homojen/heterojen olmasının malzeme üzerinde nasıl bir etkisi olacağı konusunda görüş birliği bulunmamaktadır. Ayrıca, top-toz

oranı, toz metalürjisinde, toz karıştırma (mixing) aşamasında uygulanan alt yöntemlerden biridir.

3.1.2 Presleme

Toz karışımı dayanıklı bir kalıp içinde istenilen şekil ve boyutta sıkıştırılır. Böylece yeterli mukavemet ve yoğunlukta şekillendirmesi sağlanır. Yüzey kusurları, toz metalürjisinde önemli bir kalite sorunudur. TM’de, toz parçacıkları birbirine düzgün şekilde yapışmadığında yüzey kusurları oluşmaktadır. Sıkıştırma basıncı genellikle 0-800 MPa arasında değişir, sıkılaştırma oranı, gevşek toz hacminin sıkıştırılmış toz hacmine oranıdır. Bu oran kullanılan hammaddelerin özelliklerine bağlı olarak değişmektedir.

En yaygın kalıplama yöntemi, toz karışımını parça şeklindeki bir kalıba dökmek ve bunu hidrolik veya mekanik bir preste sıkıştırmak için zımba kullanmaktır. Presleme ile oluşan toz kütesine yeşil kompakt veya briket denir.

Üretim sırasında tozların preslenmesinin amaçları şunlardır;

- Toz karışımına şekil vermek
- Toz karışımına istenen boyutları vermek
- Parçaya istenilen şekilde ve miktarda gözeneklilik kazandırmak
- Daha sonraki işlemler için parçaya istenilen mukavemeti kazandırmak

Sıkıştırma sırasında, toz önce yeniden doldurulur, paketleme sırasında oluşan çapraz bağları ortadan kaldırır ve gözenekleri azaltır. Bu, toz parçacıkları arasındaki temas noktalarını artırır. Basınç arttıkça parça plastik olarak deforme olur, temas alanı artar ve gözeneklilik azalmaya devam eder. Artan basınçla yığın yoğunluğu ve yığın gücü artar. Presleme aşaması, üç farklı kategoriye ayrılmaktadır. Bunlar sırasıyla; kalıp doldurma (MPa), kalıp basıncı (MPa), kalıp çıkarma (MPa) şeklindedir.

3.1.2.a Kalıp Doldurma

Toz bir besleme pabucundan boşaltılır ve kalıp boşluğuna düşmesi sağlanır. Bu işleme kalıp doldurma işlemi denir. Genel olarak, sabit bir kalıbı, 50 ile 300 mm/sn. arasında doldurabilmektedir.

Kalıp doldurma aşaması kendi içerisinde parça kalitesini etkileyen iki farklı proses parametresi bulunmaktadır.

- Kalıptan hava kaçıışı
- Toz içerisinde sürüklenen havanın kaçıışı

Malzeme yüzeylerinde herhangi boşluk kalmaması için kalıpların doğru şekilde doldurulması gerekmektedir. Ancak her malzemenin kendi karakteristiği olmasından dolayı, bazı malzemelerde dolum esnasında kayıp verilebilmektedir. Kalıp doldurma aşaması, iki farklı kategoriye ayrılmaktadır. Bunlar sırasıyla; kalıptan hava kaçıışı (MPa), toz içerisinde sürüklenen havanın kaçıışı (MPa) şeklindedir.

3.1.2.b Kalıp Basıncı

Presleme aşamasının ikinci aşaması, kalıp basıncı sürecidir. Genel olarak, metal tozları kapalı bir kalıpta preslendiğinde, esas olarak uygulanan basıncın dışına doğru akmaktadırlar. Genellikle, parça yoğunluğunun, parçanın tüm yüksekliği boyunca mümkün olduğu kadar homojen olması gerekir. Sinterleme sırasında boyutsal tutarlılıkları sağlamak için tek tip yoğunluk esastır. Ayrıca sıkıştırma kuvvetinin parçanın enine kesiti boyunca aynı değerde kalması önemlidir.

3.1.2.c Kalıp Çıkarma

Presleme döngüsünün son aşaması kalıp çıkarma işlemidir. Pres tipine, toz doldurma özelliklerine, parça boyutuna ve geometrisine göre saatte 400 ile 50000 kez tekrarlanabilmektedir. Toz kalıp presleme için 750 tona kadar yüke sahip hidrolik ve mekanik presler kullanılmaktadır.

3.1.3 Sinterleme

Sinterleme, temas eden parçaların yüksek sıcaklıklara ısıtılarak birleştirilmesini sağlar. Parçacıklar arasındaki mekanik bağlar kimyasal bir nitelik kazanır. Ayrıca, erime noktasının altındaki bir katı içinde atomik hareketle de oluşturulabilir. Ancak

çoğu zaman bir sıvı fazın oluşumu ile ortaya çıkar. Parçacıklar arası bağlanma, mikro yapı ile temas halinde olan parçacıklar arasındaki boyun büyümesi ile kendini gösterir. Bu tip boyun büyümesi, ham mukavemete kıyasla artan mukavemet ve diğer birçok faydalı özelliğin gelişmesine neden olur. Sinterleme, atomik göç ve tane birleşmesi yoluyla yüksek sıcaklıklarda gerçekleşir ve serbest partiküllere kıyasla azaltılmış yüzey enerjisine sahiptir.

Toz üretimi esasen bir yüzey oluşturma işlemidir. Bu enerji, sinterleme sırasında partiküller birleştiğinde malzeme içinde enerji açığa çıkararak ortadan kalkar. Sinterleme aşaması, üç farklı kategoriye ayrılmaktadır. Bunlar sırasıyla; sıcaklık ($^{\circ}\text{C}$), tutma zamanı (dk.), nem dengesi (kJ/mol) şeklindedir.

3.1.3.a Sıcaklık

Sinterleme işleminde en temel değişkenlerden biri doğru sıcaklık ayarıdır. Sinterleme sıcaklığı artırılarak daha yüksek yoğunluk elde edilebilir. Genel olarak sinterleme sıcaklığı 100°C ile 1500°C arasında yükseltilebilir. Sıcaklık arttıkça sinterlemenin aktivasyonu nedeniyle yoğunlukta keskin bir artış meydana gelmektedir. Her malzeme için farklı bir ısı direnci bulunmaktadır. Bu değerlerin üstünde, sıcaklığın artırılması, nedeniyle yoğunluk oranı daha düşük seviye kalmaktadır.

3.1.3.b Tutma Zamanı

Sinterleme işlemin ikinci önemli değişkeni tutma zamanıdır. Malzeme ısıya maruz kaldığı andan itibaren, belli bir süre ısı işlem içerisinde tutulması gerekmektedir. Her malzeme için ortalama olarak bu değerler belirlenmiştir. Malzemenin kısa süre tutulması, dayanıklılığını azaltırken, malzemenin uzun süre tutulması ise sertliğini arttıracak gibi, kırılma toleransını da aynı şekilde arttırabilmektedir. Bundan dolayı malzemenin özelliğine ve karakteristiğine göre, belirlenen değerleri aşmamak gerekmektedir.

3.1.3.c Nem Dengesi

Sinterleme, çeşitli şekiller için sıkıştırılmış metal veya seramik tozları kullanılan bir işlemdir. Bu yapısal parçalar genellikle karmaşıktır. Hemen hemen tüm metaller sinterlenebilir. Atmosferik basınçla sinterleme işlemi, hidrojen, nitrojen veya karbon monoksit gibi koruyucu bir gaz gerektirmektedir. Azot ve hidrojen bazlı atmosferlerin

kullanılması, sinterleme operasyonu için daha tutarlı bir performans sağlamaktadır. Hidrojen veya karbon monoksit kullanan atmosferler, indirgeyici maddeler olarak kabul edilmektedir. Bu gazlar birlikte çalışırlar ve sinterlenmiş parçaları oksidasyon ve dekarburizasyondan korurlar. Makine içerisinde yer alan nem ölçer sensörler sayesinde, nem değerleri görülebilmektedir. Bunun sonucu olarak, nem değerlerinde beklenmedik değişimlerin gerçekleşmemesi için kullanılan gazlar, belli oranda ısıtılma işlem makinesi içerisinde serbest bırakılmaktadır. Bu sayede nem dengesi sağlanabilmektedir.



4. DERİN ÖĞRENME

Derin öğrenme, 1950’li yılların ortasından itibaren, genellikle makine öğrenmesi olarak isimlendirilen yapay zekanın bir alt kümesi olarak, son yıllarda birçok alanda devrim yaratmıştır. Sinir ağları, makine öğreniminin bir alt dalı olması ile birlikte, derin öğrenme algoritmalarının öncülüğünü yapan yapay zekanın bir koludur (Fogg, 2018). Derin öğrenme kavramı ortaya atıldığı tarihten bu yana, neredeyse her uygulama alanında olağanüstü bir başarı göstermiştir. Ancak sistemdeki her başarı, sistemin bir sonraki noksanlarını ortaya çıkarmaktadır. Derin öğrenmenin asıl çıkışı 2006 yılından sonra makine öğrenmesinin bir alt sınıfı olarak kabul edilmesiyle başlamıştır (Kelleher, 2020). Öğrenme süreci derin öğrenme için bir eğitim sürecidir. Öğrenilen modelin belirli bir görevi yerine getirebilmesi için model parametrelerinin sisteme doğru girilmesi gerekmektedir. Örnek olarak yapay sinir ağları (Saikia *et al.*, 2020), parametre ağırlıklıdır. Doğru değerler ve doğru ağırlıklar girilmediği durumlarda, elde edilecek çıktı, hatalı olacaktır. Derin öğrenme, özellikle öğrenme ve örüntü sınıflandırması için kullanılan hiyerarşik algoritmik mimarilere sahip doğrusal olmayan veri işlem birimlerinin birçok aşamasında giriş ve çıkış katmanlarının dahil edildiği birkaç katmandan oluşmaktadır. Veri setlerine dayalı öğrenme yöntemleri, temsili öğrenme olarak tanımlanmaktadır. Son yıllarda yayınlanan bazı çalışmalarda derin öğrenme, farklı uygulama alanlarındaki hemen hemen her türlü sorunu çözebilen evrensel bir öğrenme yaklaşımı olarak tanımlanmaktadır. Kısaca tanımlamak gerekirse derin öğrenme görev tabanlı çalışmaktadır. Şu anda derin öğrenme hemen hemen tüm alanlarda uygulanmaktadır. Sonuç olarak, bu yaklaşıma evrensel öğrenme yaklaşımını da denmektedir (Kennette and Wilson, 2019).

Derin sinir ağları olarak da adlandırılan derin öğrenme, biyolojik görme (Eminaga *et al.*, 2020) ve beyin bilgi işlemenin modellenmesinden ortaya çıkmaktadır. Derin öğrenme, makine öğrenimi veya makine zekasının bir parçasıdır. Derin öğrenmenin birçok alanda hızlı bir şekilde uyarlanmasıyla birlikte, derin öğrenme yavaş yavaş birçok makine öğrenimi sorununun çözümü haline gelmiştir. Temelde çok çeşit sorunlara çözüm sağlama yeteneği nedeniyle, derin öğrenme artık geniş bir alanda kullanılmaktadır. Tek bir makinede veya tek bir grafik işlemcisi üzerinde çalışabilen küçük deneylerden, derin öğrenme modelinin eğitiminin ve çıkarımının birden fazla makineyi kapsayabileceği süper bilgisayarlar gibi sistemlerin kullanılabileceği geniş bir yelpazede yer alan uygulamaların kullanımı mümkün

olmuştur. Yazılım çerçeveleri, derin öğrenmenin geniş adaptasyonu, derin öğrenme hesaplamalarını son derece verimli bir şekilde çalıştırabilen özel donanım bileşenlerinin tasarımlarını ve geliştirilmesini teşvik etmiştir. Bununla birlikte, derin öğrenmenin büyük veri işleme (Najafabadi *et al.*, 2015) boru hatlarına uygulanması gereken birçok kullanım durumu ortaya çıkmıştır. Bu tür kullanım durumları için, böyle bir sistemin performansını göz önünde bulundurarak derin öğrenmenin yanı sıra büyük veri analizini de gerçekleştirebilen uçtan uca bir çözüme sahip olmak hayati önem taşımaktadır. Etkili bir derin öğrenme uygulamasına sahip olmak için hem veri ön işleme hem de derin öğrenme bileşenlerinin verimli olması gerekir. Bu alanda ilk uygulama AlexNet (Cortes and Sanchez, 2021) sayesinde, ünlü harfler üzerinden el yazısı (HUSSEIN, 2019) tanıma için geliştirilen model, derin öğrenmenin ilk adımlarına örnek gösterilebilir.

MNIST (Gnatushenko, Dorosh and Fenenko, 2021) veri seti, yani AlexNet, Alex Krizhevsky tarafından tasarlanmış ve Ilya Sutskever ve Geoffrey Hinton (Yann LeCun, Yoshua Bengio, 2015) ile birlikte makale olarak yayınlanmıştır. AlexNet, Eylül 2012'de ImageNet (Marmanis *et al.*, 2016) yarışmasında büyük ölçekli görsel tanıma kategorisinde ilk defa yarışmıştır. Ağ, ikinciden daha düşük, %15,3 lük bir ilk 5 hata elde etmiştir. Bu başarısından dolayı alanında en iyi algoritma ödülünü kazanmıştır. AlexNet evrişimli bir sinir ağıdır (Krishna *et al.*, 2018). AlexNet sekiz katman içermektedir, ilk beşi evrişimli katmanlardır, ardından maksimum havuzlama katmanı, son üç ağı tamamen birbirine bağlı katmanlardır. Makine öğrenimi ve makine zekasında bir dönüm noktası olan AlexNet, 2012 ImageNet yarışmasını kazanmıştır (Sik-Ho, 2018).

AlexNet, ImageNet veri tabanındaki bir milyondan fazla görüntüye dayalı olarak eğitilmiş bir ESA (Hassan *et al.*, 2019) ağıdır. Ağ görüntüleri klavyeler, fareler, kalemler ve birçok hayvan dahil olmak üzere 1000 nesne kategorisine ayırabilmektedir. Ağın 227×227 görüntü giriş boyutu bulunmaktadır.

ImageNet 2015 yarışması (Du, Zhang and Shi, 2019), ImageNet, hiyerarşinin her bir düğümünün yüzlerce ve binlerce görüntüyle gösterildiği Word Net hiyerarşisine göre düzenlenmiş bir görüntü veri tabanıdır (Russakovsky *et al.*, 2015). Derin öğrenme matematikle, özellikle optimizasyon, grafik teorisi, sayısal analiz, fonksiyonel analiz, olasılık teorisi, matematiksel istatistik, bilgi teorisi vb. ile yakından

ilişkilidir. Bu konular bir sinir ağı modeli için analiz sağlayabilmektedir. Genellikle, bir sinir ağını ölçüldüğünde veya bir algoritma değerlendirildiğinde, sayısal analizde sağlamlığı, kararlılığı ve yakınsaması dikkate alınmaktadır.

Derin öğrenmede, derin öğrenme modellerinin parametrelerini güncellemek için gradyan inişi sıkça kullanılmaktadır (Yang *et al.*, 2020). Gradyan inişi, bir fonksiyonun yerel minimumunu bulmak için birinci dereceden yinelemeli bir optimizasyon algoritmasıdır (Gong, 2020). Örneğin, gradyan inişi, doğrusal en küçük kareler kullanılarak, ikinci dereceden bir minimizasyon problemi olarak bir doğrusal denklem sistemini çözmek için kullanılmaktadır.

Çözümü için,

$$Ax-b=0 \quad (1)$$

Fonksiyonu en aza indirmek için,

$$F(x)= \|Ax-b\|^2 \quad (2)$$

Gerçek A ve b için doğrusal en küçük kareler yöntemi ile, Öklid normu kullanılmaktadır,

$$\nabla F(x)=2A^T (Ax-b) \quad (3)$$

Minimum değeri hesaplamak için x_0 ile başlanır,

F değeri ile sırasıyla, $x_0, x_1, x_2, \dots$ şeklinde devam etmektedir.

$$x_{n+1}=x_n-\gamma \nabla F(x_n), n \geq 0 \quad (4)$$

$\gamma \in R^+$ yeterince minimum değere ulaştığında, adım boyutu γ değerinin her yinelemede ayarlanmasına izin verilmektedir.

Küçültülmesi gereken bir maliyet veya hata fonksiyonu $F(w)$ var ise, gradyan inişi bize ağırlıkları $F(w)$ ayarlamamıza yardımcı olmaktadır.

$$w_{n+1}=w_n-\gamma \nabla F(w_n), n \geq 0 \quad (5)$$

Burada γ öğrenme oranıdır, w_n ise DSA'larının ağırlıklarını temsil etmektedir. Sayısal analizde, denklemdeki yinelemeler için son koşulları, (Du *et al.*, 2021)

önceden ayarlanmış bir döngü sayısı veya çalışma süresinin yanı sıra belirli bir sonuç tahmini ve iki bitişik döngü arasındaki hatalardır.

Derin öğrenmede, hesaplama yöntemlerinde var olan çözüm varlığı, kararlılık, sağlamlık ve ağırlık azalması için yakınsama gibi optimizasyon problemleriyle karşı karşıya kalınmaktadır. Bu problemlere örnek, iki problem, gradyan kaybolma problemi ve gradyan patlama problemidir (Sun, Ran and Su, 2020).

Halihazırda, SGD'deki gradyan kaybolma sorunu ve gradyan patlaması sorunu (Nemeth and Fearnhead, 2021), ağ kısıtlı Boltzmann makinesi (Srivastava and Salakhutdinov, 2014), üretken model, uzun kısa süreli bellek (LSTM) (Yu *et al.*, 2019), artık ağlar (ResNets) (McNeely-White, Beveridge and Draper, 2020) gibi çok düzeyli ağ hiyerarşisi kullanılarak çözülebilirken, gradyan patlamasından kaçınılabilmektedir.

Gradyan patlamasını ve kaybolmasını önlemek için düzenleme uygulanmaktadır (Tao and Wang, 2020). Düzenleme, eğitim hatalarını değil, genelleme hataları azaltmak için bir öğrenme algoritmasında yapılan bir değişiklik olarak tanımlanmaktadır. Düzenleme, fazla takmayı azaltmaya ve ağırlıkları daha düşük değerlere çekmeye yardımcı olmaktadır.

Derin öğrenme, pratik problemlerin çözümünde etkinliğini ve üstünlüğünü göstermiştir. Görsel nesne algılama ve tanıma, görüntü bölümlendirme, konuşma tanıma, doğal dil işleme (Zhou *et al.*, 2020) ve büyük veriyle ilgili teknoloji kullanıldığında robot kontrolünde insan yeteneklerimizi aşmada özellikle başarılı olmuştur.

1995 yılında, ESA (konvolüsyonlu sinir ağı veya ConvNets) tipik bir sinirsel çalışma olarak (Li *et al.*, 2019), bir banka çeki üzerindeki bir zarf (Agrawal *et al.*, 2021) veya el yazısı numaraları üzerinde posta kodu tanıma (Zhao *et al.*, 2021) için kullanılmıştır. ESA'lar, insan sinir sistemimizin mekanizmasını taklit etmeye dayanan bununla birlikte ROI (yani ilgi bölgesi) ve göze çarpan bölgeleri bulmamıza yardımcı olan bir modeldir (Sun *et al.*, 2020). Uçtan uca yapı ve ince ayar değerleri, ağı tanımaya yardımcı olmaktadır.

LeNet, ağ analiz süresince piksel düzeyinde ayrıntılara sahip küçük nesneler (Erwin *et al.*, 2020) şeklinde parçalara ayrılmaktadır. Ayrıca LeNet, LeCun Yann ve

diğerleri tarafından oluşturulan öncü bir yedi seviyeli evrimsel ağ olan LeNet-5 olarak adlandırılmaktadır (LeCun *et al.*, 1998). LeNet, 1998 yılında ilk olarak, 32×32 piksel görüntülerde sayısallaştırılan banka çeklerinde el yazısıyla yazılan sayıları tanımak için bazı bankalar tarafından uygulanmıştır (Tan and Tan, 2019).

1997 yılında, güçlü bir sınıflandırıcıyı zayıf bir sınıflandırıcı üzerinden yükseltmek için AdaBoost algoritması önerilmiştir (Žižka, Dařena and Svoboda, 2019; Breiman, 1997). AdaBoost algoritması, topluluk öğreniminin makine öğrenimine (Kao and Venkatachalam, 2021) veya derin öğrenme üzerine (Chahal and Gulia, 2019) uygulanabilmesini sağlamaktadır.

Rastgele Orman, denetimli bir öğrenme algoritmasıdır (Breiman, 2001). İnşa ettiği “orman”, genellikle “torbalama” yöntemiyle eğitilmiş bir karar ağaçları topluluğudur. Torbalama yönteminin genel amacı, öğrenme modellerinin bir kombinasyonunun genel sonucunu arttırmasıdır (Schonlau and Zou, 2020). Rastgele ormanın büyük bir avantajı, mevcut makine öğrenimi sistemlerinin çoğunluğunu oluşturan hem sınıflandırma hem de regresyon problemleri için kullanılabilmesidir (Ackoff *et al.*, 2010).

1995 ten bu yana, destek vektör makinesi (Chandrasekaran *et al.*, 2010), hiper düzlem ve hiper parametrelerin (Gul, Alpaslan and Emiroglu, 2021) yanı sıra belirli özelliklere dayalı örüntü sınıflandırması için popüler bir makine öğrenme algoritması haline gelmiştir. Makine öğrenmesinde destek vektör makinesin ’den (Xiao *et al.*, 2021) farklı olarak, derin öğrenme algoritmaları birden fazla sınıf kullanmaktadır. En yüksek olasılığa sahip sınıf bir diğer sinir ağının çıktısı olarak düşünülmektedir (Siddharth *et al.*, 2020). Derin öğrenme (Wang ve Yeung, 2020), yalnızca programlama ve veri toplamada değil, aynı zamanda matematiksel teorilerde ve ağ yapılarında da iyi tasarlanmış bir konu olan sinir ağlarının uçtan uca çerçevesine dayanmaktadır.

Derin İnanç Ağı, (Sohn, 2021) kenarların ve düğümlerin farklı ağırlıklara sahip olduğu yönlendirilmiş bir ağıdır (Wang *et al.*, 2021). Öte yandan, derin Markov rastgele alanı (Sun *et al.*, 2018), tüm kenarların çift yönlü olduğu yönsüz bir ağıdır. Derin Boltzmann Makinesi (DBM) (Passos and Papa, 2018), birden fazla gizli rastgele değişken katmanı içeren bir ikili Markov rastgele alanı (yönsüz olasılıklı grafik modeli) türüdür. Simetrik olarak eşleştirilmiş stokastik ikili birimlerden oluşan bir

ağdır (Lestari, 2019). DBM, örüntü sınıflandırması, regresyon ve zaman serisi modellemesine başarıyla uygulanmıştır. Yukarıdaki çalışmalarda incelediğimiz üzere evrişimli sinir ağlarının uygulama noktasında birçok artısı bulunsa da bölge tabanlı yüzey kusurlarının tespitinde bazı dezavantajları bulunmaktadır.


Bölge bazlı evrişimli sinir ağlarının en büyük sorunu, her yeni görüntü için tahminler yapmak için analizin 40-50 saniye sürmesidir (Sharma and Mir, 2019). Bu da modeli devasa bir veri kümesiyle karşı karşıya kaldığında çıktı oluşturmaya hantal ve pratik olarak imkânsız hale getirmektedir. Ek olarak, tam bağlı katmanın tüm vektörlerinin aynı boyuta sahip olması beklenir, tüm verilerin kırpma veya boyutlandırma kullanılarak yeniden boyutlandırılması gerekir, kırpma ile elde edilen veri tam olarak çıkarılmamasına ve boyutlandırmaya neden olabileceğinden her iki strateji de uygun değildir. Bu sorunu aşmak için nesnelerin ölçeklendirilmesi gerekmektedir.

4.1. Derin Öğrenme Algoritmaları

4.1.a Evrişimli Sinir Ağları

Evrişimli sinir ağları ilk olarak 1988 yılında Fukushima tarafından ortaya atılmıştır. Ancak, ağı eğitmek için gereken hesaplama donanımının sınırları nedeniyle yaygın olarak kullanılamamıştır (Fukushima, 1980). 1990 yılların başında LeChun ve arkadaşları, evrişimli sinir ağları üzerine gradyan tabanlı bir öğrenme algoritması uygulamışlar ve el yazısı üzerine oluşturulan rakamsal sınıflandırma problemlerinin çözümü için başarılı sonuçlar elde etmişlerdir (Ackoff *et al.*, 2010). Daha sonraki yıllarda yapılan çalışmalar ile, araştırmacılar evrişimli sinir ağlarını daha da geliştirmişler ve birçok obje tanıma görevinde başarılı çıktılar elde etmişlerdir. Evrişimli sinir ağlarının derin sinir ağlarına göre, insanın görsel işleme sistemine daha benzer bir sistemde çalışması, iki boyut ve üç boyut görüntüleri işlemek için yüksek düzeyde optimize edilmiş olmaları ve iki boyut özelliklere ait verilerin öğrenme ve çıkarmada etkili olmaları dahil olmak üzere birçok avantajı bulunmaktadır. Evrişimli sinir ağlarının maksimum seviyede havuzlama katmanı özellikleri, şekil değişikliklerini uyum sağlamada etkilidir. Ayrıca, belirli ağırlıklara sahip seyrek

seviyede oluşan bağlantılara sahip evrişimli sinir ağılar, benzer boyuttaki tam bağlı bir ağdan önemli ölçüde daha az parametreye sahiptir. Hepsinden önemlisi, evrişimli sinir ağılar gradyan tabanlı öğrenme algoritması ile eğitilmektedir ve azalan gradyan probleminde daha az etkilenmektedir. Gradyan tabanlı algoritmaların (Ahmadianfar, Bozorg-Haddad and Chu, 2020) tüm bir ağı bir hata kriterini doğrudan en aza indirecek şekilde eğittiği göz önüne alındığında, evrişimli sinir ağılar yüksek düzeyde optimize edilmiş ağırlıklar üretebilmektedir. Şekil 2’de örnek mimari gösterilmektedir.



Şekil 2. Evrişimli sinir ağı mimarisi

Evrişimli sinir ağılar, bir önceki katmanı girdi olarak alır ve çıktısını girdi olarak bir sonraki katmana iletmektedir. Evrişimli sinir ağılar mimarisi, üç tür katmanın birleşiminden oluşmaktadır. Bunlar; evrişim, maksimum havuzlama ve sınıflandırmadır. Ağın alt ve orta seviyesinde iki tür katman bulunmaktadır. Bu katmanlar evrişimli katmanlar ve maksimum havuzlama katmanlarıdır. Çift numaralı katmanlar kıvrımsal ağılar içindir ve tek numaralı katmanlar maksimum havuzlama işlemleri içindir. Evrişim ve maksimum havuzlama katmanlarının çıktı düğümleri, özellik eşleme adı verilen bir iki boyutlu düzlem üzerinde gruplanmaktadır. Bir katmanın her bir düzlemi genellikle önceki katmanların bir veya daha fazla düzleminin birleşiminden türetilmektedir. Bir düzlemin düğümleri, önceki katmanın bağlı olduğu her düzlemin küçük bir bölgesine bağlanmaktadır. Evrişim katmanının her bir düğümü, giriş düğümlerindeki evrişim işlemleriyle giriş görüntülerinden ağa ait öznitelikleri çıkarmaktadır. Daha yüksek seviyeli özellikler, alt seviye katmanlardan yayılan ağa ait özelliklerden türetilmektedir. Öznitelikler en üst katmana veya düzeye yayıldıkça, öznitelik boyutları, sırasıyla evrişimli ve maksimum havuzlama (Hao *et al.*, 2021)

işlemleri için çekirdeğin boyutuna bağlı olarak küçülmektedir. Bununla birlikte, ağın sınıflandırma doğruluğunu sağlamak için giriş görüntülerinin daha iyi özelliklerini temsil etmek için özellik haritalarının sayısı genellikle artmaktadır. Evrişimli sinir ağlarının son katmanın çıktısı, sınıflandırma katmanı olarak adlandırılan tam bağlantılı bir ağın girişi olarak kullanılmaktadır. İleri beslemeli sinir ağları, daha iyi performansa sahip oldukları için sınıflandırma katmanı olarak kullanılmaktadır. Sınıflandırma katmanında, istenilen sayıda öznitelik girdi olarak seçilebilmektedir. Ancak tam bağlantılı katmanlar, ağ veya öğrenme parametreleri açısından bazı durumlarda etkisiz kalabilmektedir. Günümüzde, tam bağlantılı ağlara alternatif olarak kullanılan ortalama havuzlama ve genel ortalama havuzlama dahil olmak üzere birçok yeni teknik bulunmaktadır. İlgili sınıfa ait puanların, softmax katmanı (Zhu *et al.*, 2020) kullanılarak en üst sınıflandırma katmanında hesaplanması ile, en yüksek doğruluğa ait çıktılar elde edilebilmektedir. En yüksek puanı temel alan sınıflandırıcı, ilgili sınıflar için çıktı sağlamaktadır. Evrişimli sinir ağlarının farklı katmanlarına ilişkin matematiksel ayrıntılar aşağıda verilmektedir.

Evrişim katmanı; bu katmanda, bir önceki katmandan gelen özellik haritaları, öğrenilebilir çekirdek ağlar ile kaynaştırılmaktadır. Çekirdek ağların çıktıları, çıktı özellik haritalarını oluşturmak için sigmoid ve hiperbolik gibi doğrusal veya doğrusal olmayan bir etkinleştirme işlevinden geçmektedir. Çıktı özellik haritalarının her biri, birden fazla girdi özellik haritası ile birleştirilmektedir. Tek boyutlu ve 2 boyutlu evrişimli sinir ağlarına ait matematiksel formülasyon aşağıdaki gösterilmektedir.

$$s_t = \sum_{a=0}^{\infty} \left[(x_t - a^w) - a(x^*w)_t \right] \quad (6)$$

$$S_{ij} = (I * K)_{ij} = \sum_{a=-m/2}^{m/2} \sum_{b=-n/2}^{n/2} \left[I_{(i-a, j-b)} K_{(m/2+a, n/2+b)} \right] \quad (7)$$

Sınıflandırma katmanı; önceki ağ adımlarında bir evrişim katmanından çıkarılan özelliklerden her bir sınıfın puanını hesaplayan tam bağlantılı katmandır. Son katman özelliğine sahip ağların haritaları, tamamen bağlı katmanlara ileten geçici değerlere sahip vektörler olarak temsil edilmektedir. Tam bağlantılı ileri beslemeli nöral katmanlar, softmax sınıflandırma katmanı olarak kullanılabilir. Ağ modeline

dahil edilen katman sayısı konusunda katı kurallar yoktur. Ancak çoğu durumda, farklı mimari ağırlara sahip olan iki ve dört katmanlı yapılar gözlemlenmektedir. Tam bağlantılı katmanlar hesaplama açısından verimli olmadığından dolayı son birkaç yılda alternatif yaklaşımlar önerilmektedir. Bunlar, ağıdaki parametre sayısını önemli ölçüde azaltmaya yardımcı olan geniş boyutta ortalama havuzlama katmanını (Jie and Wanda, 2020) kapsayan modellerdir. Evrişimli sinir ağları aracılığıyla geriye doğru yayılmada, tamamen ağırlı olan katmanlar, tam bağlantılı sinir ağlarının genel yaklaşımını inceleyerek kendilerini güncelleyebilmektedirler. Evrişimsel katmanların filtreleri, evrişim katmanı ile hemen önceki katmanı arasındaki özellik haritaları üzerinde tam bir evrişimsel etkileşim gerçekleştirerek güncellenmektedirler.



5. YÖNTEM VE UYGULAMA

Çalışmada IN718 kod adlı Inconel malzemesi ile üretilen somun parçalarının üretim proses parametrelerinin sayısal değerlerle tanımlanarak, bu parametre değerleri ile yüzey kalitesi değerleri arasındaki istatistiksel ilişkiler incelenmiştir. Bu ilişki itibarıyla en iyi sonuçları veren proses parametreleri belirlenmiştir.

Literatürde önceki kısımlarda belirtildiği üzere IN718 malzemesi üzerine proses parametrelerinden başlayarak, metal malzemenin üretim aşamaları ve üretim sonrası yüzey kalitesinin derin evrişimli sinir ağları ile tespiti üzerine detaylı çalışmalara rastlanmamıştır.

Literatürde belirtilen çalışmalar genellikle, üretim sonrası metal parçaların yüzeylerinin geleneksel makine öğrenmesi algoritmaları ile incelenmesi üzerine yapılmıştır. Bu çalışmada yapılan analizlerin avantajı, evrişimli sinir ağları konusuna derin öğrenme yapısını entegre ederek, yenilikçi bir çalışma olmasının yanında, Raspberry Pi tabanlı akıllı ve düşük maliyetli bir görüntü işleme uygulaması içermektedir.

5.1. DENEYSEL TASARIM (DOE)

5.1.a. Deneyisel tasarım: Plackett-Burman Deney Tasarımı

Plackett-Burman deney tasarımı, 1946 'da Plackett ve Burman tarafından geliştirilmiş olup, iki aşamalı deneysel faktöriyel tasarımlardır. N sayıda yapılan deneyde, $k=N-1$ değişkene eşit olduğunda ve deney sayısı N'in 4 'ün katı ve üzeri olduğu durumlarda kullanılmaktadır. Plackett-Burman tasarımları küp şeklinde olup, geometrik olmayan tasarımlar olarak adlandırılmaktadır. (Mongomery, 2017).

Plackett-Burman deney tasarımı, toz metalürjisindeki temel kalite özelliklerini etkilemesi öngörülen formülasyon ve işlem parametrelerinin önemini istatistiksel olarak değerlendirmek için uygulanmıştır. 12 deneyde altı faktör incelenmiştir. Faktör seviyeleri, ön deneme sonuçlarına ve literatüre dayalı olarak belirlendi ([Egész *et al.*, 2014],[Fang *et al.*, 2022],[Nejad, Khanchi and Taghizadeh, 2018]). Toz metalürjisinde parça üretimine ait birincil işlemler dikkate alınmıştır. Müşteri tercihinine göre değişen

ikinci işlemler, kişiye özel prosesler olduğundan dolayı deney tasarımına dahil edilmemiştir. Seçilen faktörler ve düzeyleri Tablo 1’de gösterilmektedir.

Tablo 1. Plackett-Burman deney tasarımlarında kullanılan faktörler ve seviyeler

Faktör	Düzey	
	Düşük	Yüksek
Metal tozu boyutu	5	80
Karışımın yağlanması	0.4	0.6
MPa – Basınç	400	850
Sinter sıcaklığı	500	1120
Sıkıştırma sıcaklığı	100	160
Sinterleme süresi	20	30

Deney matrisinin oluşturulması, randomizasyonu ve istatistiksel analizler için Minitab 21 (Minitab Ltd., İngiltere) yazılımı kullanılmıştır. Oluşturulan on iki deney sonucunda Mini tab 21 yazılımının uyguladığı Plackett-Burman tasarımı deney matrisi Tablo 2’de gösterilmektedir. Birinci dereceden polinom modelleri oluşturmak için çoklu lineer regresyon analizi ve varyans analizi uygulanmıştır (formül 8):

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_6 X_6 \quad (8)$$

Bu eşitlikte Y cevap değişkenini, X_1 - X_6 faktörleri, β_0 sabiti ve $\beta_1 - \beta_6$ ise faktörlerin katsayılarını göstermektedir.

Tablo 2. Plackett-Burman Tasarım Test Matrisi

Formülasyon	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆
Kodu	(MPa)					
PBD01	80	0.4	850	160	500	20
PBD02	80	0.6	850	100	500	20
PBD03	80	0.6	400	100	1120	20
PBD04	5	0.4	400	100	500	20
PBD05	5	0.4	850	160	1120	20
PBD06	5	0.6	400	160	1120	20
PBD07	80	0.4	850	100	1120	30
PBD08	80	0.4	400	160	1120	30
PBD09	80	0.6	400	160	500	30
PBD10	5	0.4	400	100	500	30
PBD11	5	0.6	850	100	1120	30
PBD12	5	0.6	850	160	500	30

5.1.b. Toz Metalurjisinde Kullanılan Proses Parametrelerinin Optimizasyonu: Box-Behnken Deney Tasarımı

İstatistikte, Box-Behnken tasarımları, 1960 yılında George E. P. Box ve Donald Behnken tarafından ortaya atılmıştır (Ferreira *et al.*, 2007). Bu deneysel yöntemin bazı özellikleri bulunmaktadır. Bunlar sırasıyla;

- Her faktör veya bağımsız değişken, genellikle -1, 0, +1 olarak kodlanır ve eşit aralıklı üç değerden birine yerleştirilir.

- Tasarım, kare terimleri, iki faktörün çarpımları, doğrusal terimler ve bir kesişim içeren ikinci dereceden bir modele uymaya yeterli olmalıdır.
- İkinci dereceden modeldeki deneysel noktaların sayısının katsayı sayısına oranı makul olmalıdır.
- Tahmin varyansı az çok sadece merkezden uzaklığa bağlı olmalıdır.

Plackett-Burman deney tasarımı ve istatistiksel olarak önemli anahtar formülasyon ve proses parametrelerinin belirlenmesinin ardından toz metalürjisinde kullanılan proses parametrelerinin optimizasyonu için üç düzeyli, altı faktörlü bir yüzey cevap yöntemlerinden biri olan Box-Behnken deney tasarımı uygulanmıştır. Düşük ve yüksek düzeyler Plackett-Burman deney tasarımı üzerinden doğrudan alınmıştır ve üçüncü düzey olarak düşük ve yüksek düzeylerin ortasındaki sayısal ifadeler kabul edilmiştir (Tablo 3).

Tablo 3. Box-Behnken Deney Tasarımında Kullanılan Faktörler ve Düzeyler

Faktör	Düzey		
	Düşük	Orta	Yüksek
X ₁ : Metal tozu boyutu	5	42.5	80
X ₂ : Karışımın yağlanması	0.4	0.5	0.6
X ₃ : Basınç	450	625	800
X ₄ : Sinter sıcaklığı	100	130	160
X ₅ : Sıkıştırma sıcaklığı	500	810	1120
X ₆ : Sinterleme süresi	20	25	30

Plackett-Burman deney tasarımı kapsamında analiz edilen ancak etkileri istatistiksel boyutta anlamlı olmayan veya belirli bir düzeyde kullanılmaları mecburiyeti ortaya çıkan altı faktörün Box-Behnken deney tasarımı kullanılarak sabit sayısal değerleri Tablo 4’te gösterilmektedir.

Tablo 4. Box-Behnken Deney Tasarımında belirli bir düzeyde kullanılan formül ve işlem parametreleri

Formülasyon ve proses parametreleri	Düzey
Metal tozu boyutu	42.5
Karışımın yağlanması	0.5
Basınç	625
Sinter sıcaklığı	130
Sıkıştırma sıcaklığı	810
Sinterleme süresi	25

DeneySEL matrislerin, randomize çalışmaların ve istatistiksel analizlerin hazırlanması için Mini tab 21 (Minitab Ltd., UK) yazılımı kullanılmıştır (Tablo 5). Tüm formülasyonlar üç kopya halinde yapılmıştır.

Tablo 5. Box-Behnken Tasarım Test Matrisi

Formülasyon	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆
Kodu	(mg)	(mg)	(MPa)	(C°)	(C°)	(dk)
BBD01	80	0.4	850	160	500	20
BBD02	80	0.6	850	100	500	20
BBD03	80	0.6	400	100	1120	20
BBD04	5	0.4	400	100	500	20
BBD05	5	0.4	850	160	1120	20
BBD06	5	0.6	400	160	1120	20
BBD07	80	0.4	850	100	1120	30
BBD08	80	0.4	400	160	1120	30
BBD09	80	0.6	400	160	500	30
BBD10	5	0.4	400	100	500	30
BBD11	5	0.6	850	100	1120	30
BBD12	5	0.6	850	160	500	30

Her bir yanıt değişkenine çoklu regresyon analizi uygulandıktan sonra ikinci dereceden bir polinom regresyon modeli aşağıda gösterilmektedir (Formül 9):

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \beta_{11} X_1^2 + \beta_{22} X_2^2 \quad (9)$$

Eşitlikte Y cevap değişkenini, X_1 - X_3 faktörlerinin ana etkilerini, $X_1 X_2$, $X_1 X_3$, $X_2 X_3$ faktörlerinin etkileşim etkilerini, X_1, X_2^2 faktörlerin ikinci dereceden etkilerini, β_0 sabiti ve $\beta_1 - \beta_3$ faktörlerin katsayılarını göstermektedir. Faktörlerin tepki değişkenleri üzerindeki etkilerinin anlamlılığının ve modelin tümünün test edilmesi için regresyon katsayılarının ($\beta_1 - \beta_3$) p değerleri varyans analizi ile belirlenmiştir.

Faktörlere ve cevap değişkenlerine ilişkin polinom eşitlikler oluşturulduktan sonra geliştirilen matematiksel model kullanılarak formülasyon proses değişkenleri “metal tozu boyutu” Y_1 , “karışımın yağlanması” Y_2 , “basınç” Y_3 , “sinter sıcaklığı” Y_4 , “sıkıştırma sıcaklığı” Y_5 , “sinterleme süresi” Y_6 , esas alınarak optimize edilmiştir.

5.1.c. Risk Analizi: Plackett-Burman Deney Tasarımı

Önemli formülasyon süreci değişkenlerini belirlemek ve etkilerini değerlendirmek için 6 faktörlü, 2 seviyeli, 12 deneyli Plackett-Burman istatistiksel tasarımı kullanıldı. Test edilen formülasyonlar ve cevap değişkenlerine ilişkin değerler Tablo 6’de gösterilmektedir.


Tablo 6. Plackett-Burman deney tasarımı sonucunda elde edilen bağımlı değişkene ait değerler

Formülasyon Kodu	Y_1
PBD01	66
PBD02	74
PBD03	76
PBD04	83
PBD05	85
PBD06	81
PBD07	67
PBD08	69
PBD09	72
PBD10	83
PBD11	85
PBD12	89

Üretim kalite sonuçları (Y_1) sonuçları 66'dan (PBD01), 89'a (PBD12) kadar değişkenlik göstermiştir (Tablo 6). En anlamlı iki faktör sırasıyla toz karışımı (X_2), sinter sıcaklığı (X_5) olarak tespit edilmiştir (Şekil 1). Faktörlerin üretim kalitesi üzerindeki etkisini temsil eden doğrusal bir model aşağıda gösterilmektedir (Formül 10):

$$Y_1 = 180,766 + 46,500X_1 - 0,459X_2 + 5,492X_3 - 59,250X_4 + 138,492X_5 + 145,750X_6 \quad (10)$$


R^2 değeri 0,8835 olarak bulunmuş ve test edilen modelin uyumunun anlamlı olduğu tespit edilmiştir. Pozitif değere sahip bir sayısal faktör hedef boyutunu artırırken ve negatif değere sahip bir sayısal faktör hedef boyutunu küçültmektedir. Varyans analizinden elde edilen ana etkenlere ilişkin p değeri 0.017 olarak tespit edilmiş ve anlamlı olarak değerlendirilmiştir (tablo 7).



Şekil 3. Değişkenlerin etkisini gösteren S/N grafiği

Tablo 7. Plackett-Burman deney tasarımı ile elde edilen bağımlı değişken değerlerinin istatistiksel analiz sonuçları

Katsayılar						
Değişken	Effect	Coef	SE Coef	T-Value	P-Value	VIF
Constant		73,800	0,849	86,93	0,000	
Metal tozu boyutu	-2,600	-1,300	0,849	-1,53	0,150	1,00
Karışımın yağlanması	16,400	8,200	0,849	9,66	0,017	1,00
Basınç	1,200	0,600	0,849	0,71	0,492	1,00
Sinter sıcaklığı	2,200	1,100	0,849	1,30	0,218	1,00
Sıkıştırma sıcaklığı	-0,000	-0,000	0,849	-0,00	1,000	1,00
Sinterleme süresi	1,400	0,700	0,849	0,82	0,425	1,00



Şekil 4. Üretim kalitesi verimliliği için kritik olan formülasyon ve proses değişkenlerini gösteren Pareto grafiği

Şekil 4'te Pareto analizine göre, etki gücü en yüksek olan proses parametreleri gösterilmektedir. Uygulamalı bir deney tasarımı, her deney bir faktörü değiştirir ve diğerlerini sabit tutar, bu da çok sayıda deneyle sonuçlanmaktadır. Ayrıca, uygulamalı deney tasarımı ile faktör etkileşimi etkileri ve deneylerin istatistiksel tasarımı, uygulanan yaklaşımlara kıyasla daha az deneyle daha açıklayıcı sonuçlar sağlamaktadır. Ayrıca, veri görselleştirme sayesinde ürünleri ve süreçleri optimize etmek için deneysel tasarımlar kullanılabilir (Dejaegher and Vander Heyden, 2008). Literatürde deney sayısını azaltmak ve daha faydalı veriler elde etmek için birçok istatistiksel deney tasarımı kullanılmıştır (Committee, 1998). Deney tasarımının amacı, birçok değişkeni etki durumlarına göre sınıflandırmaksa, Plackett-Burman gibi doğrusal bir tasarım tercih edilebilir (Talib and Rahman, 2010). Ancak, hedef değişkenlerin etkilerini matematiksel olarak ifade etmek ve süreç optimizasyonu için Box-Behnken tasarımları gibi ikinci dereceden modeller tercih edilmelidir (de Souza Couto, Silveira and de Castro, 2021).

Bu tez çalışmasında, deneylerin ilk tasarımı olarak Plackett-Burman deney tasarımı kullanılmıştır. Plackett-Burman deney tasarımı, bağımsız değişkenlerin önemine göre dışlanmasına izin veren, etkili ve yaygın olarak kullanılan bir deney tasarımıdır (Zhang *et al.*, 2012). Birinci deney tasarımı bu faktörler için seçilen

düşük ve yüksek değerler Plackett-Burman tasarımında olduğu gibi kabul edilmiş, Box-Behnken deney tasarımında da ortalama seviye kullanılmıştır.

Proses parametreleri belirlendikten sonra, Plackett-Burman Deney Tasarımı ve istatistiksel bir deney tasarımı olan Box-Behnken Deney Tasarımı, bu parametrelerin anahtar kalite özellikleri üzerindeki etkisini matematiksel olarak modellemek ve tasarlamak için kullanılmıştır. Elde edilen çıktılar regresyon analizi ile değerlendirildiğinde oluşturulan matematiksel modellerin faktörlerinden karışımın yağlanması değişkeninin kalite üzerindeki etkisinin yüksek olduğu ve kurulan modelin istatistiksel olarak anlamlı olduğu görülmüştür.

5.2. SİSTEM TASARIMI

Bu bölümde sistem tasarımı, yüzey hatalarının bulunması üzerine algoritma çalışmaları, analiz sonucunda elde edilen sonuçlar verilmektedir.

Görsel analiz sistemleri, insan görüşünü kullanarak kalite kontrol işlemlerini gerçekleştirmek için kameralar ve dahili yazılımları kullanan bilgisayar destekli bir görüş sistemidir. Bütünleşik ve ayrıklı kameralı kontrol sistemleri kullanılarak birçok farklı sektörlerde çalışmalar yapılmaktadır. Bu sektörler örnek olarak robotik, gıda, otomotiv ve askeri sistemler gösterilmektedir. Bilgisayarlı görüntü işleme ile bütün endüstrilerde sorunlu ve yüzey hatalı parça kontrolü, boyut ölçüsü tespiti, desen tanıma, yüzey analizi, ürün yüzey hatası tespiti gibi pek çok işlem yapılabilmektedir.

Bu tez çalışmasında metal somun üretim aşamasında, yüzey hatalarına sahip olan bir uygulama sistemi oluşturulmuştur. Bu tez çalışmasının kapsamı ise toz metalürjisi ile üretilen somun parçalarının yüzey hatalarının bulunması ile yüzey hataları algoritmalarının derin öğrenme ile uygulanmasıdır.


Metal somunların üretim sürecinde çeşitli aşamalarda kalite kontrol yapılmaktadır. Bunlardan biri de somun üretimi aşamasında yapılan kontrol süreçleridir. Somun üretim sürecinde yüzeyinde hatalı olan somun parçaları üretim bandından dışarı alınması ile hatalı somunların diğer aşamalara geçmelerinin önüne geçilmekte ve bu sayede maliyet düşürülmektedir.

Üretim bandı üzerinde insan işçiler ile yapılan gözle kontrolün bazı dezavantajları bulunmaktadır.

Bunlar;

- Düşük hızda kontrol
- Hata oranlarının yüksek çıkması
- Üretim maliyeti
- İnsan çalışan dezavantajı
- İstatistiksel verilerin doğruluğunun tespitinin zor olması

Bu olumsuz faktörleri ortadan kaldırmak için bu tez çalışmasında hatalı somun parçalarını tespit eden bir derin öğrenme sistemi geliştirmektedir. Toz metalürjisi üretiminde gerçekleşen hata çeşitleri ISO/ASTM 52911 standartlarıyla belirtilmektedir. Bu hatalar, Şekil 5'te gösterilmektedir.



Şekil 5. TM üretiminde karşılaşılan hatalar

Toz metalürjisinde karşılaşılan hatalar aşağıdaki başlıklar halinde özetlenmiştir;


a) işleme ile ilgili kusurlar

- Toz yayma dinamikleri ve anomaliler
- Gözeneklilik hatası
- Anahtar deliği gözenekliliği
- Mikro yapısal homojen sızlıklar
- Sütunlu tanelerin oluşumu
- Çapaklanma
- Parça gerilmesi
- Çatlama
- Geometrik kusurlar
- Boyutsal doğruluk

b) İşlem sonrası ile ilgili kusurlar


- Yeniden boyutlandırma
- Buhar işlemi
- Kaynaştırma

Geliştirilen sistem ile somun parçalarının yüzey kısımlarında oluşan hataların kontrolünün otomatik olarak tespit edilmesi hedeflenmektedir. Bu amaca ulaşmak için geliştirilen sistemin şeması Şekil 6’de gösterilmektedir. Analiz süresince kullanılan bilgisayar için işlemci olarak Core i7 Gen 10th seçilmiştir. Bellek seçimi 64 GB olarak belirlenmiştir. Ekran kartı olarak Nvidia RTX 2080 kullanılmıştır. Uygulama platformu olarak Windows 10 tercih edilmiştir.



Şekil 6. Uygulama sisteminin şeması


Hatalı olarak üretilen parçalar, Raspberry Pi ile bağlanmış kamera sayesinde görüntü verileri çekilerek ve bu veriler analiz için kullanılacak olan bilgisayara aktarılır. Malzeme yüzeyinde çekim esnasında ışıksal sorunlar olmaması için sabit iki ışık 5000 lm olarak ışık vermektedir. Kamera ile metal parça arasındaki mesafe 20 cm olarak belirlenmiştir.



Şekil 7. Geliştirilen sistemin görüntüsü

Şekil 7’de kurulan uygulama sistemi gösterilmektedir. Bu sistem ile yakalanan tüm görüntü verileri, derin evrişimli sinir ağı yöntemi ile eğitilerek, hem parça üzerindeki hataların tespit edilmesi hem de hataların sınıflandırılmasının yapılması planlanmaktadır. Toplanan görüntü verilerinin yeterli sayıya ulaşmadığı durumlarda sentetik veri yöntemi kullanılmıştır.

Geliştirilen sistemde somun parçasına ait yüzey hatalarını tespit için, yüzey görüntüleri CPU işlemci çekirdekleri kullanılarak, bilgisayar ve Raspberry Pi sistemlerini paralelleştiren hibrit bir yapı kullanılmıştır. Bu çalışmadaki metodoloji aşağıdaki süreci izleyecektir (Şekil 8):



Şekil 8. Metodoloji akış şeması

5.3. UYGULAMA TASARIMI

Bu bölümün tek görüntü enterpolasyonu alanına yaptığı başlıca katkılar şu şekilde özetlenmiştir:

- Bu bölüm, tek görüntü enterpolasyonunu, yarı-yerel piksel benzerlikten yararlanan tipik algoritmaların birbirlerini dışlayan renk örtüşmesinin ortaya çıkardığı benzersiz zorlukları açıkça ele alan ilk çalışmadır: i) benzer renk yamalarının tanımlanması ve ii) hedefin tahmini için verilen benzer renk yamalarının tanımlanması.
- Bu bölüm, güvenilir benzer renk yamalarını belirlemedeki zorluklarda güçlü örtüşmenin rolünü keşfeden ve bu soruna açık bir çözüm geliştiren ilk çalışmadır. Dikkatle tasarlanmış özgün operatör aracılığıyla, bu çözüm, “K” parametresinin düşük çözünürlüklerde yakalanan parça görüntüleri üzerinde güçlü bir ayırıştırıcı olduğu tespit edilmiştir. Geleneksel tekniklerde düşük çözünürlüklü parça görüntüleri üzerinde tespit edilmesi güç olan hata yüzeyleri “k” parametresi ile yakalanmaktadır.
- Bu bölüm, benzer yöntemler üzerinden hata unsurlarını tanımlayan hedef hata unsurlarını daha iyi tahmin etmek için yeni bir yöntem sunmaktadır. i) ilk yinelemedeki benzer hata unsurlarının ağırlıklarını tahmin etmek için görüntü örtüşmelerinin pikselleri kullanılmıştır. ii) Sonraki model yinelemelerinde tahmini benzer hata unsurlarını iyileştirmek için manifold modelleri kullanılmıştır.
- Önerilen yaklaşımın performansı çeşitli standart test görüntüleri üzerinde test edilmiştir. Sayısal sonuçlar hem nesnel metrik hem de görsel kalite açısından tüm model tabanlı yaklaşımlarla karşılaştırıldığında, yaklaşımın en gelişmiş performansa ulaştığı görülmektedir.


5.3.a K detektörü

K detektörü, görüntü alanı üzerinde uzamsal alan yönetiminden esinlenilen bir terimdir. Görüntü üzerindeki renk piksellerinin sayısal ifadesini temsil etmektedir. Matematiksel ifadesi aşağıdaki formülde gösterilmektedir. K detektörü, renk değerleri arasındaki sayısal ifadenin, belirlenen değer ve karşıtı olan unsura hedeflenmesini sağlamaktadır. Grafik yazılımları içerisinde RGB formatında, yani kırmızı, yeşil, mavi renk tonları üzerinde çizilen histogram grafiklerinde görülmektedir. Genel olarak renk tonlarının sayısal ifade aralığı 0-255 arasında yer almaktadır.

$$g(x, y) = T[f(x, y)] \quad (7)$$

$g(x, y)$: Giriş görüntüsüne T fonksiyonu uygulandıktan sonraki çıkış görüntüsünü temsil etmektedir.

$f(x, y)$: Şekil 9'de gösterildiği gibi belirli (x, y) koordinatlarında piksel değerlerini tanımlayan giriş görüntüsünü ifade etmektedir.



Şekil 9. Bir görüntü üzerindeki belirlenen noktanın 3x3 şeklinde taranması


T: (x, y) 'nin bazı komşulukları üzerinde belirtilen $f(x, y)$ üzerinde bir operatördür ve ayrıca n görüntüden piksellerin toplamını hesaplayan set girdi görüntülerinin operatörünü göstermektedir. Gri seviye işlevini yerine getirmektedir.

Normalleştirme: $T(r)$ Şekil 10'da gösterilen forma sahipse, dönüşümü uygulamanın etkisi görülmektedir.

G'de karşılık gelen pikselleri oluşturmak için f_{nin} her pikseline:

Bu çalışmada 0-255 renk tonları ile sayısal olarak ifade edilen k değeri, 0-100 sayısal değer aralığına çekilmiştir. Sınır olarak belirlenen bu değerler sadece görüntü verilerinin siyah ve beyaz tonlara çevrilmesi ile anlam kazanmaktadır. Teknik ifade ile renk tonları boyutsal olarak indirgenmiştir.

Orijinal görüntüdeki (bu çalışma için 90) k seviyesinin üstündeki alan hatalı yüzeyi göstermektedir. Orijinal görüntüde ($40 < k < 90$) k seviyeleri yüzey hakkında hatasız alanı ifade etmektedir. Elde edilen görüntü üzerinde ($0 < k < 39$) k değeri ise, ışıklandırma ortamında sorun olduğunu göstermektedir.



Şekil 10. Gri tonlamalı görüntüler için seviye dönüşüm fonksiyon değerleri (a), (b) –

Önerilen şeklimiz (c)

5.3.b Piksel yama boyutu seçimi

Bu çalışmada model doğrulama için, iki farklı enterpolasyon yöntemi kullanılmıştır. İlk enterpolasyon için iki faktörlü, alt örnekleme ızgarasının her aşamasının aynı miktarda piksele sahip olduğundan emin olmak için eşit kenar uzunluk yaması kullanılmıştır. Aynı şekilde, üç faktörlü enterpolasyon analizi için üç çarpanlı kenar uzunluğu tercih edilmiştir.

Yama boyutları seçiminde, “k” detektörü, aşırı uyum durumuna karşı koruma sağlamak için daha büyük bir yama boyutu kullanılmıştır. Aşırı uyum durumu model

eğitiminde gerekli önlemler alınmaz ise başarısız bir eğitim çıktısına neden olabilmektedir. Ancak, elde edilen görüntünün temizliğine göre hedef yamalara yaklaşımı iyileştirmek için daha küçük yama boyutu kullanılmıştır.

5.3.c Renk boyutunun değişimi

Gri tonlamalı görüntü, algoritmanın girdisi olarak kullanılmaktadır. İlk elde edilen görüntüler KYM (kırmızı, yeşil, mavi) olarak görüntülenmektedir. Bu görüntülerin gri tonlamalı görüntülere dönüştürülmesi gerekmektedir. Aşağıda bu dönüştürme aşamasında kullanılan kod örneği gösterilmektedir.

```
Import numpy as np
import matplotlib.pyplot as plt
import matplotlib.image as mpimg
def rgb2gray(rgb):
    return np.dot(rgb[...,:3], [0.2989, 0.5870, 0.1140])
img = mpimg.imread('image.png')
gray = rgb2gray(img)
plt.imshow(gray, cmap=plt.get_cmap('gray'), vmin=0, vmax=1)
plt.show()

dcnn_k_parameter.py
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.image as img
turn rgb2gray(rb):
    return np.dot(rgb[3x3], [x, y, z])
img = img.imread('image.png')
gray = rgb2graay(img)
plt.imshow(gray, cmap=plt.get_cmap('gray'), vmin=0, vmx=1)
if cmap= 40<k<90, 0
else cmap=90<k,
then 1
```

Devamı.

Girdi: tek yönlü kümeleme

Uygulama: M: Sinir ağı


```
// girdi/çıktı katman boyutları
M.input.num_paramet. - E(3).input.num_paramet;
M.output.num_paramet. – E(3).output.num-layers;
M.num.layers – getShalllowestNetwork€.num-layers;

// gizli katman sayısını ayarlama
For ,-0....M.num_layers-1 do
    M.layers(i).num_paramet – getMin(E,i);
End
Return M;

// minumum katman boyutunu ayarlama
Function getMin(E,posn)
    min – E(3).layers(posn).num_paramet;
    for j – 0...len€-1 do
        min – E(j).layers(posn).num_paramet
    end
end
return min;
```


Gri görüntülerini, gri tonlamaya dönüştürmenin amacı, farklı renklerin neden olduğu farklı görüntü değeri farklılıklarını en aza indirmeyi amaçlamaktadır. Şekil 10’de 3x3 kutulama yapılarak her bir karenin analize dahil edilmesi aşaması gösterilmektedir. Bu çalışmada, modele ait görüntü uzamsal yöntem sayesinde analiz aşamasında 12*12 kare alanı, örneklem alanı olarak kullanılmıştır. Sabit bir noktada ve hareketsiz olarak kurulan ışık kaynağı 5000lm değerinde aydınlatma sağlamaktadır.

Bu sayede parça yüzeyindeki kusurlu kısımlar, Python kodu sonrası, parça yüzeyindeki kusurlu kısımlar koyu ve siyah olarak algılanmaktadır.




Şekil 11. Renk paleti üzerinde “k” değerleri

Beyaz rengin “k” değeri “0” iken siyah rengin “k” değeri “100” sayısal ifadesini ifade etmektedir. Bu iki renk arasındaki değerler gri tonları oluşturmaktadır. Kullanılan ışık kaynaklarının sağladığı aydınlatma nedeniyle düz metal yüzeyler düşük gri oranına veya beyaza yakın tonlara sahiptir. Ancak, yüzey üzerinde yer alan çizik, delik gibi herhangi bir hasar oluştuğunda bu yüzeylerde siyah ve gölgeli alanlar oluşmaktadır. Bu alanlar “k” değeri üzerinden hatalı yüzeyleri ifade etmektedir. Şekil 12’de örneklem grubunda bulunan dört farklı hatalı parça ve bu parçaların 3 boyutlu grafikler ile kusurlarının tespiti gösterilmektedir. Şekil 13’te parçalara ait yüzey görüntülerinin kutulama yöntemi ve “k” parametresi değerleri gösterilmektedir.



Şekil 12. Örneklem grubunda kullanılan hatalı parçalara ait 3 boyutlu grafik ile kusur tespitleri



Şekil 13. (a) - Yüzey görüntüsü alınan metal somun parçasının tespit edilen “k” yüzde değerleri (hatasız ürüne aittir). (b) - Yüzey görüntüsü alınan metal somun parçasının (arızalı ürüne ait) tespit edilen “k” yüzde değerleri.

5.3.d Uzamsal olarak alçak piksel görüntüleme

Formül 1’de görüldüğü üzere, örtüşmeyi kaldırmanın basit bir yolu, düşük “ I_L ” geçişli filtreleme uygulamaktır. Yüksek frekanslı bileşenlerde örtüşmeyi kaldırmak için önce bir Gauss düşük geçişli “ I_L ” filtreleme kullanılması gerekmektedir.

$$I_L^{lp} = I_L * F \quad (8)$$

Bu simge “*” evrişim operatörünü göstermektedir. D---d boyutundaki F filtresi, standart sapma ile parametrenmiş, iki boyutlu bir Gauss filtresidir.

5.3.e Boyutsal-Varyant Projeksiyon

Uzamsal olarak düşük boyutlu filtreleme, yalnızca hafif boyutta örtüşmeyi göstermektedir. Düşük frekanslı görüntü bileşenleri bozan güçlü bir örtüşme

durumunda, tipik olarak Şekil 3.2 (sürekli görüntülerde), hedef hata kusurlarını uzamsal olarak düşük geçişli filtrelemeden sonra sınıflandırmaktadır. Böylece, inceltirilmiş hedef hata unsurlarının görsel resimleri ciddi şekilde etkilenmektedir.

Güçlü tarama yapılan bölgeler yönlü yerleştirilmiş yapılar içermektedir. Bu yapıların oryantasyon bilgilerinin korunması, sürekliliği korumanın ve güvenilir benzer hata unsurlarını tanımlamanın anahtarıdır. Bu her bir hata unsurunun oryantasyonla ilgili karakterizasyonlarını çıkarmak ve bu tür karakterizasyonlar için bir yama görevi görmektedir. Yönlü piksel alanlarının yakınındaki komşu pikseller benzer parçaların ana bileşenlerinin karakterizasyonlarıdır. Çünkü, bazı parçaların boyutsal görüntülerinin üzerindeki hata unsurlarının yoğunluğunun yakalanması için “k” parametresinin iki boyutlu renk kanalında kullanılması gerekmektedir.

K parametresi üzerinden oluşan ağdan bir E değeri kümesi oluşturulduğunda (yani, eğitilmiş bir Network üzerinden elde edilen ağlar), ilk olarak taranan her ağ için bir tane olmak üzere K değeri, giriş ve çıkış katmanıyla başlatılmaktadır. Ardından, her bir gizli katmanı, girdiden çıktı katmanına doğru tek tek inşa edilmektedir. Daha sonra, ana ağ’dan kaynaklanan tüm nöronlar birleştirilmektedir. Bir sinir ağı içerisinde nöronları “i” katmanında birleştirmek için önce o nöronun “k” kadar kopyası tek bir kopyaya indirgenmelidir. Farklı taranmış ağlar boyunca, tüm katmanlardaki diğer çeşitli nöronlardan elde edilen bilgiler sırasıyla girdi olarak birbirlerine eklenmektedir. Bu birleştirilmiş nöronların çıktısı daha sonra tüm katmanlara iletilmektedir.

Temelleri sağlam bir şekilde hata unsurlarını tahmin etmek için, renk derinliklerinin kullanılması analiz sürecini arttıracaktır. Burada, ortalama görüntü piksellerinin sayısal değerleri baz alınmaktadır. Spesifik olarak, temel kusurları hesaplarken, hedef ekine benzer bir gruplama yöntemi kullanılması yerine, hata gruplarının renk skalası belirlenmiştir. Her bir hata grubu, birbirlerine benzer piksel değeri üzerinden örtüşmeleri sağlanmaktadır. Gösterim kolaylığı için, her piksel gruplandırılmış matris birleşimi boyutunda tanımlanmaktadır. Burada hata kümelerinin birleşimi, hatalı piksel yüzeylerinin kalitesini “ Y_i ” göstermektedir.

$$Y_i = Y_i^x - Y_i^* \quad (9)$$

Burada Y_i , y_i , “ k ” parametresinin ters negatifini göstermektedir. Ek olarak $y_i \in R_1^{n2 \times 1}$ denkliği $y_i = P_i^{lp} - y_i$ şeklinde histogram grafiği üzerinde işaretlenmektedir.

Verilen Y_i , yerel görüntülerin sayısal temsilleri için SVD ana bileşenleri kullanılmaktadır.

$$U_i D_i V_i = Y_i \quad (10)$$

Burada U_i , $k \times k$ birim matrisi ifade etmektedir. D_i , köşegen görüntülerde negatif olmayan gerçek sayılara sahip bir $k \times n^2$, diyagonal matristir. V_i , bir $n^2 \times n^2$ üniter matrisi ifade etmektedir. V_i , ayrıca sütunlar üzerinde yer alan “ k ” ana bileşeninin doğrusal kombinasyonunu göstermektedir.

$$y_i^u = \sum_{j=1}^k (y_i, v_i^j) v_i^j \quad (11)$$

Tüm örtüşen görüntülenmiş hedef hata kusurlarının her piksele katkısının ortalaması alınarak, görüntünün ara sürümü şu şekilde oluşturulmaktadır:

$$(\sum_{i=1}^l R_i^T P_i \cdot - (\sum_{i=1}^l R_i^T 1_{n2 \times 1}), \quad (12)$$

Yukarıdaki prosedürler tekrarlanarak ve (4) üzerinden hesaplanan çıktılar üzerine enterpolasyon uygulanmaktadır. Metal parçalara ait görüntüler ile aynı boyuttaki düşük ve yüksek eşik frekanslar üzerinde örtüşme kaldırılmıştır. Ayrıca yerleştirilmiş kenarların ikincil alanları da kaldırılmıştır. İkinci bölgeler üzerinde lokalize edilmiş kenarların çevresindeki benzer hata kusurları, model için daha iyi tahminleme olanağı sağlamaktadır.

Algoritma deneme: Uzamsal değişken örtüşme kaldırma

Girdi: girdi görüntüsü I_L ; giriş görüntüsündeki hedef kusurların sayısı I ; hata boyutu n ; benzer hataların her bir içerisindeki sayısı K_{ar} ; arama pencere boyutu W ; Gauss filtre boyutu d ; Gauss filtre standardı sapması k ; yineleme sayısı φ .

Çıktı: takma adı kaldıran görüntü I_{ar} ;

Hesaplama I_L^{up}

Yineleme için -1 ’den φ ’a kadar.

for $i = -1$ to I

Çıkarım P_i^{lp} den I_L^{lp} i -th hedef yamasına

Gruplama $12K_{ar}$ piksel boyutunda, benzer yama P_i^{lp} için Y_i uzaklığına kadar.

Hesaplama y_i , birliğin anlamı olarak, $12K_{ar}$ benzer yama boyutunda

Hesaplama Y_i , y_i (3) ve (4), sırasıyla.

Hesaplama V_i den Y_i 'ye kadar (5)

for $j = 0$ dan k 'ya kadar

Çıkarım v_i^j 'den j -th sütununa kadar V_i boyutunda.

End

Hesaplama y_i^u den y_i 'ye kadar tüm değerler için v_i^j (5)

End

$P_i = y_i^u + y_i$.

Yenileme I_L^{lp} 'den P_i 'ye kadar.

End

Hesaplama I_{ar} ile enterpolasyon.

5.3.f Tanımlanmış benzer kusurlar üzerinden hedef kusurları tahmin etme

Bu bölümde, toplanan hata kusurları göz önüne alındığında, ilk denemede ortaya çıkan tahmin başarılarının nasıl arttırılacağı ve sonraki algoritma yinelemelerinde kusur tahmin kayıplarını iyileştirmek için bir operatör zincirinin nasıl tasarlanacağı anlatılmaktadır. Şekil 14'te operatör zincirinin şematik görüntüsü gösterilmektedir. Bu noktada, uygulanan verilerin sapma içermediğinden emin olmak için veri tutarsızlıklarını azaltmak için uygulanan veri işleme adımlarının akış diyagramı gösterilmektedir. Her veri kümesinin kaynağı, boyutu ve biçimi tespit edildikten sonra, veri kümelerindeki hatalı bölgelerin doğru bir şekilde tanımlanmasını sağlamak için

her veri kümesine benzersiz bir tanımlayıcı atanmıştır. Son olarak, hatalı ve hatasız parçalar belirlenirken, veri ön işleme sırasında doğru kayıtların elde edildiğinden emin olmak için (0,1) çıkışlı bir ikili karar mekanizması kullanılmıştır.

Çalışmada oluşturulan kod aşağıda gösterilmektedir;

```
Import os
```

```
Import numpy as np
```

```
Import tensorflow as tf
```

```
Slim=tf.contrib.slim
```

```
From config import
```

```
From tensorflow.python.ops import embedding_ops
```

```
From tensorflow.python.layers.core import Dense
```

```
From tensorflow.contrib import rnn
```

```
From tensorflow.python.framework import graph_util
```

```
From tensorflow.python.ops import math_ops
```

```
Class Model(object):
```

```
Def __init__(self, sess, param):
```

```
Self.step = 0
```

```
Self._session = sess
```

```
Self.is_training=true
```

```
Self.__learn_rate=param[“learn_rate”]
```

```
Self.__learn_rate=param[“learn_rate”]
```

```
Self.__max_to_keep=param[“max_to_keep”]
```

```
Self.__checkPoint_dir = param[“checkPoint_dir”]
```

```
Self.__restore = param[“b_restore”]
```

```

Self.__mode= param["mode"]

Self.is_training=true

Self.__batch_size = param["batch_size"]

If self._mode is "savaPb" :

Self.__batch_size = 1

With self.__session.as_default():

Self.build_model()

With self._session.as_default():

Self.init_op.run()

Self.__saver = tf.train.saver(tf.global_variables(), max_to_keep=self.__max_to_keep)

If self.__restore:

If ckpt:

Self.step = int(ckpt.split('-')[1])

Self._saver.restore(self.__session, ckpt)

Print('restoring from epoch: {}'.format(self.step))

Self.step+=1

Def build_model(self):

Def segmentNet(input, scope, is_training, reuse=None):

With tf.variable_scope(scope, reuse=reuse):

With slim.arg_scope([slim.conv2d],

Padding='SAME',

activation_fn=tf.nn.relu,

normalizer_fn=slim.batch_norm):

```

```

net = slim.conv2d(input, 32, [5, 5],scope='conv1')

net = slim.conv2d(net, 32, [5, 5], scope='conv2')

net=slim.max_pool2d(net,[2,2],[2,2],scope='pool1')

net = slim.conv2d(net, 64, [5, 5],scope='conv3')

net = slim.conv2d(net, 64, [5, 5], scope='conv4')

net = slim.conv2d(net, 64, [5, 5], scope='conv5')

net=slim.max_pool2d(net,[2,2],[2,2],scope='pool2')

net = slim.conv2d(net, 64, [5, 5],scope='conv6')

net = slim.conv2d(net, 64, [5, 5], scope='conv7')

net = slim.conv2d(net, 64, [5, 5],scope='conv8')

net = slim.conv2d(net, 64, [5, 5], scope='conv9')

net=slim.max_pool2d(net,[2,2],[2,2],scope='pool3')

net = slim.conv2d(net, 1024, [15, 15], scope='conv10')

features=net

net = slim.conv2d(net, 1, [1, 1],activation_fn=None, scope='conv11')

logits_pixel=net

net=tf.sigmoid(net, name=None)

mask=net

return features,logits_pixel,mask

def DecisionNet(feature,mask, scope, is_training,num_classes=2, reuse=None):

    with tf.variable_scope(scope, reuse=reuse):

        with slim.arg_scope([slim.conv2d],

                               padding='SAME',

```

```

        activation_fn=tf.nn.relu,

        normalizer_fn=slim.batch_norm):

    net=tf.concat([feature,mask],axis=3)

    net = slim.max_pool2d(net, [2, 2], [2, 2], scope='pool1')

    net = slim.conv2d(net, 8, [5, 5], scope='conv1')

    net = slim.max_pool2d(net, [2, 2], [2, 2], scope='pool2')

    net = slim.conv2d(net, 16, [5, 5], scope='conv2')

    net = slim.max_pool2d(net, [2, 2], [2, 2], scope='pool3')

    net = slim.conv2d(net, 32, [5, 5], scope='conv3')

    vector1=math_ops.reduce_mean(net,[1,2],name='pool4',
keepdims=True)

    vector2=math_ops.reduce_max(net,[1,2],name='pool5', keepdims=True)

    vector3=math_ops.reduce_mean(mask,[1,2],name='pool6',
keepdims=True)

    vector4=math_ops.reduce_max(mask,[1,2],name='pool7',
keepdims=True)

    vector=tf.concat([vector1,vector2,vector3,vector4],axis=3)

    vector=tf.squeeze(vector,axis=[1,2])

    logits = slim.fully_connected(vector, num_classes,activation_fn=None)

    output=tf.argmax(logits,axis=1)

    return logits,output

    Image      =      tf.placeholder(tf.float32,      shape=(self.__batch_size,
IMAGE_SIZE[0],IMAGE_SIZE[1], 1), name='Image')

```

```

PixelLabel=tf.placeholder(tf.float32, shape=(self.__batch_size,
IMAGE_SIZE[0]/8,IMAGE_SIZE[1]/8, 1), name='PixelLabel')

Label = tf.placeholder(tf.int32, shape=(self.__batch_size), name='Label')

features, logits_pixel, mask=SegmentNet(Image,'segment',self.is_training)

logits_class,output_class=DecisionNet(features,mask, 'decision', self.is_training)

logits_pixel=tf.reshape(logits_pixel,[self.__batch_size,-1])

PixelLabel_reshape=tf.reshape(PixelLabel,[self.__batch_size,-1])

loss_pixel =
tf.reduce_mean(tf.nn.sigmoid_cross_entropy_with_logits(logits=logits_pixel,
labels=PixelLabel_reshape))

loss_class =
tf.reduce_mean(tf.nn.sparse_softmax_cross_entropy_with_logits(logits=logits_class,
labels=Label))

loss_total=loss_pixel+loss_class

optimizer = tf.train.GradientDescentOptimizer(self.__learn_rate)

train_var_list = [v for v in tf.trainable_variables() ]

train_segment_var_list = [v for v in tf.trainable_variables() if 'segment' in
v.name]

train_decision_var_list = [v for v in tf.trainable_variables() if 'decision' in
v.name]

optimize_segment =
optimizer.minimize(loss_pixel,var_list=train_segment_var_list)

optimize_decision = optimizer.minimize(loss_class,
var_list=train_decision_var_list)

optimize_total = optimizer.minimize(loss_total, var_list=train_var_list)

init_op=tf.global_variables_initializer()

```

```
self.Image=Image

self.PixelLabel = PixelLabel

self.Label = Label

self.features = features

self.mask = mask

self.logits_class=logits_class

self.output_class=output_class

self.loss_pixel = loss_pixel

self.loss_class = loss_class

self.loss_total = loss_total

self.optimize_segment = optimize_segment

self.optimize_decision = optimize_decision

self.optimize_total = optimize_total

self.init_op=init_op

def save(self):


    self.__saver.save(

        self.__session,

        os.path.join(self.__checkPoint_dir, 'ckp'),


        global_step=self.step

    )
```



Şekil 14. Operatör zinciri.

5.4 DENEYLER VE SONUÇLAR



Şekil 15. Test parçaları: ID 1 den 10'a kadar.

Uygulama için önerdiğimiz “k” detektörü, Şekil 15’de gösterilen literatürde yaygın olarak kullanılan on farklı parça üzerinde gri tonlamalı test görüntüsü ile çalıştırılmıştır. Her görüntü için, k detektörü hem yatay hem de dikey olarak, 2 alt örneklenmiş versiyon 2 kat ve 3 alt örneklenmiş versiyonu 3 kat enterpolasyon yapılmıştır. Her iki analizin alt örnekleme ızgaraları, her test görüntüsünün sol üst köşesindeki pikselle başlamaktadır. Enterpolasyon performansını değerlendirmek için büyütülmüş enterpolasyonlu görüntü üzerinde genişletilmiş piksellerin boyut alanı daraltılmıştır. Bu aşamada değerlendirme metriği olarak, sinyal-gürültü oranı kullanılmıştır (SGO).

$$SGO = 20 \log_{10} \left(\frac{255}{\sqrt{MSE}} \right), \quad (13)$$

$MSE = \|I_H - I_H\|_2$, I_H , toplam piksel sayısını ifade etmektedir. I , frobenus matrisini göstermektedir. Genel performansı değerlendirmek için on farklı parçanın SGO ortalaması kullanılmıştır. Bu analizde kullanılan veriler, 1024x1024 piksel gri tonlamalı bir görüntü üzerinde enterpolasyon algoritmaları uygulanmıştır. Tablo 1’de dokuz farklı algoritma üzerinde nicel enterpolasyon analizi yapılmıştır. K detektörünün analiz için seçilen dokuz algoritmaya etkisi Tablo 2’de gösterilmektedir.

Tablo 8. Nicel enterpolasyon analizi

Algoritma	Gürültü standart sapması	Gürültü piksellerinin yüzdesi
Orijinal fotoğraf	0.09645	97.51
En yakın komşu(Cunningham and Delany, 2021)	0.09632	97.45
Lanczos-4(Shimizu <i>et al.</i> , 2019)	0.08756	96.38
Lanczos-3	0.08528	95.98
Bikubik Spline(Zaynidinov <i>et al.</i> , 2021)	0.07671	93.64
Çift doğrusal(Ge <i>et al.</i> , 2019)	0.05865	82.81
Catmull-Rom(Li, Chen and Sari, 2016)	0.05696	81.52
Mitchell-Netravali(Parsania and Virparia, 2016)	0.04258	63.25
Bikubik B-Spline (Bourke)(Han and Han, 2019)	0.03628	54.41
Cubic B-Spline(Alaofi, Ali and Dragomir, 2021)	0.02536	24.95

Tablo 8’de gürültü piksellerinin yüzdelere bakıldığında, en yüksek skora sahip algoritma, %97,45 ile En yakın komşu algoritması olurken, en düşük skora sahip algoritma %24,95 ile Cubic B-Spline algoritması olduğu tespit edilmiştir.

Tablo 9. K detektörü ile Nicel enterpolasyon analizi

Algoritma	Gürültü standart sapması	Gürültü piksellerinin yüzdesi
Orijinal fotoğraf	0.09645	97.51
En yakın komşu / k	0.09640	97.51
Lanczos-4 / k	0.08759	96.42
Lanczos-3 / k	0.08552	95.93
Bikubik Spline / k	0.07652	93.24
Çift doğrusal / k	0.05921	83.36
Catmull-Rom / k	0.05692	81.43
Mitchell-Netravali / k	0.04269	63.48
Bikubik B-Spline / k	0.03634	54.68
Cubic B-Spline / k	0.02156	22.67

Tablo 9’de k detektörü modülünün, dokuz algoritma üzerindeki etkisi, beş algoritma için pozitif, dört algoritma için negatif yönde gerçekleşmiştir. Sırasıyla, 0.06 GPY ile En yakın komşu, 0.04 GPY ile Lanczos-4, 0.55 ile Çift doğrusal, 0.23 GPY ile Mitchell-Netravali, 0.27 GPY ile Bikubik B-Spline üzerinde pozitif bir artış elde edilmiştir.

5.4.a Analiz Çalışması

K detektörünün temel bileşenlerinin önemini göstermek için analiz çalışması yapılmıştır. Bu çalışmaya ek olarak dört kontrollü deney uygulanmıştır. İlk kontrollü deney (D1), hem güvenilir benzer hata kusurlarını seçmenin yanında, daha önce kullandığımız değişken ağırlıkları tercih edilmiştir. İkinci kontrollü deney (D2), hata kusurlarını tespit etmek için yalnızca hedeflenen piksel boyut aralığı daraltılmıştır. Bu nedenle, üçüncü kontrollü deney (D3), performansı iyileştirmede düşük frekans boyutunda (90-100) bileşenlerden, piksel örtüşme kaldırmanın rolünü ölçmeye yardımcı olması amaçlanmıştır. Dördüncü kontrollü deney (D4), enterpolasyon performansının iyileştirilmesinde, görüntü boyunca oluşabilecek artifakların bastırılması hedeflenmiştir. K detektörünün performansını test etmek için, sırasıyla 2 ve 3 kat enterpolasyon yapılmıştır. Bu bölümün içerisinde bahsedilen manifold

modellerinin uygun kullanımı hedef kusurlarının tespitinde elde edilen katkıları doğrulamaktadır.

5.4.b 2 faktörlü enterpolasyon

İki faktörlü enterpolasyon görevi için, k detektörü sonuçları literatürde kullanılan diğer yöntemler ile karşılaştırılmıştır. Bu yöntemler, bikübik enterpolasyon (Bikübik)(Hirahara *et al.*, 2021), Seyrek karıştırma tahmini (SKT)(Gashnikov, 2021), Yumuşak karar ve uyarlamalı interpolatör (YKUİ)(Forbus *et al.*, 2017), Yerel olmayan otomatik gerilemeli modelleme (YOOGM)(Lecouat, Ponce and Mairal, 2020), Hızlı rastgele ormanlar (HRO)(Huang, Siu and Liu, 2015), Çok ölçekli dikkate duyarlı başlangıç ağı (ÇÖDDBA)(Ji, Zhong and Ma, 2020)'dır. Bu yaklaşımlar, harici bir eğitim görüntüsü setinden model parametrelerini öğrenen, veriye dayalı yaklaşımlardır. Tablo 10 model tabanlı algoritmalarla karşılaştırıldığında, “k” detektörü on görüntünün tamamında en yüksek ortalama SGO'ya ve tekil bazda en yüksek SGO'ya ulaştığı görülmektedir. Kusur tespit tabanlı yöntemlerle karşılaştırıldığında, “k” detektörü, toplam on veri seti üzerinden yedisinde en yüksek SGO oranını elde etmiştir. Sırasıyla, ortalama 2.73dB, 0.54dB, 0.22dB, 0.26dB, 0.04dB, 0.1dB skoru Bikübik, SKT, YKUİ, YOOGM, HRO, ÇÖDDBA enterpolasyonundan daha iyi performans göstermiştir

Tablo 10. Modellerin 2 faktörlü enterpolasyon SGO karşılaştırmaları, koyu kırmızı renkli olan veriler en yüksek SGO skorlarını göstermektedir.

ID	Bikubik	SKT	YKUİ	YOOG M	HRO	ÇÖDDDB A	K Model
1	33,69	37,15	37,63	37,69	37,79	37,79	37,82
2	30,38	33,45	33,54	33,63	34,09	34,06	34,41
3	28,45	30,81	31,36	31,59	31,79	31,74	31,76
4	30,26	32,79	33,09	33,08	33,28	33,29	32,68
5	27,62	29,65	29,79	29,79	29,94	29,94	29,98
6	26,02	27,82	28,05	28,02	28,26	28,25	28,51
7	29,56	31,96	31,09	31,85	32	32,06	32,14
8	27,21	28,48	28,93	28,8	28,89	28,65	28,95
9	25,96	27,04	28,65	27,23	27,35	27,38	28,71
10	29,36	31,25	31,48	31,59	31,65	31,68	30,89
Ortalama	28,85	31,04	31,36	31,32	31,54	31,48	31,58

5.4.c 3 faktörlü enterpolasyon

Üç faktörlü enterpolasyon analizi için, kaynak kodun mevcudiyeti nedeniyle, Tablo 11’de kullandığımız altı yöntem ile karşılaştırma yapılmıştır. Kusur tespit tabanlı yöntemlerle karşılaştırıldığında, “k” detektörü, toplam on veri seti üzerinden yedisinde en yüksek SGO oranını elde etmiştir. Sırasıyla, ortalama 3.6dB, 3.53dB, 6.19dB, 3.05dB, 3.2dB, 3.29dB skoru Bikübik, SKT, YKUİ, YOOGM, HRO, ÇÖDDBA enterpolasyonundan daha iyi performans göstermiştir.

Tablo 11. Modellerin 3 faktörlü enterpolasyon SGO karşılaştırmaları, koyu kırmızı renkli olan veriler en yüksek SGO skorlarını göstermektedir.

ID	Bikubik	SKT	YKUİ	YOOGM	HRO	ÇÖDDBA	K Model
1	28,4	24,46	18,92	30,47	30,91	28,87	31,01
2	27,76	27,75	35,59	25,86	23,54	23,07	29,46
3	28,3	29,31	22,48	29,49	29,3	22,06	29,65
4	22,06	26,8	25,82	24,25	23,07	27,09	27,15
5	26,06	23,21	18,05	27,72	28,92	29,43	29,52
6	22,54	33,15	21,9	24,51	33,45	30,91	31,56
7	31,54	24,51	21,53	26,58	21,54	27,45	31,58
8	19,58	25,6	17,47	32,92	27,43	26,06	27,89
9	26,69	21,59	24,03	27,43	27,46	29,75	29,86
10	30,24	27,46	31,47	19,43	21,53	21,56	31,49
Ortalama	26,31	26,38	23,72	26,86	26,71	26,62	29,91

K detektörü uygulaması için MATLAB (R2021b, akademik lisans) ve Ubuntu 18.04 yazılımı ve Intel i7 11nci nesil işlemci kullanılmıştır. 128 x 128 düşük çözünürlüklü görüntü veri seti ile 256 x 256 yüksek çözünürlüklü görüntü veri seti analiz süreçlerinde kullanılmıştır. Uygulama eklentisi olarak, paralel hesaplama aracı ve çoklu işlem aracı kullanılmıştır. Her satır yenilemesi Matlab yazılımı içerisinde 51 saniye ve toplamda 238 dakika içerisinde tamamlanmıştır.

5.4.d Özellik çıkarma modeli

Belirli bir veri kümesi için sınıflandırma problemlerinde bir DESA modelinin performansı, girdi boyutuna, girdi sayısına ve veri kümesinin ne kadar dengeli olduğuna bağlıdır. Ek olarak, her bir evrişimdeki evrişim katmanlarının sayısı, çekirdek boyutu ve sayısal katman, dolgu ve adım prosedürleri modelin genel sonucunu önemli ölçüde etkilemektedir. Bu bölümde, gelişmiş bir DESA modeli kurulmuştur. Bu çalışmada, veri dengeleme ve veri büyütmenin modelin performansı üzerindeki etkisini göstermek için giriş boyutunu değiştiren farklı ESA mimarileride

kullanılmıştır. Kurduğumuz modelin iki bloğu bulunmaktadır. İlk blok optik görüntülerden özellik çıkarmak içindir, diğeri ise tanımlanan kusurların sınıflandırılmasıdır. Özellik çıkarma katmanları temel olarak doğrusal ve doğrusal olmayan işlemlere sahip evrişimli katmanlardan, yani evrişim işlemi ve etkinleştirme işlevinden oluşur. İlk katmanda $252 \times 252 \times 3$ piksellik giriş görüntüsü ile 3×3 çekirdek boyutundaki 32 filtre arasında matematiksel evrişim işlemi gerçekleştirilmiştir. Daha sonra, görüntü verisi köşeler ve kenarlar gibi görüntü hakkında bilgi veren özellik haritaları çıkarılmıştır. İlk öznitelik haritası katmanının çıktısı, değişkenler arasındaki her türlü sürekli ve karmaşık olan ilişki, ReLU aktivasyon fonksiyonu ile normalleştirilmiştir. Bununla birlikte, katmanın düzeltilmiş doğrusal çıktısı, havuz katmanı kullanılarak yeniden boyutlandırıldı.

5.4.e Sınıflandırma modeli

Bu çalışma için oluşturulan mimarinin sınıflandırma modeli, bir çıktı katmanının ardından 512 ve 64 boyutlarında iki tam bağlantılı katmandan oluşmaktadır. Özellik çıkarma modelinin düzleştirilmiş değerleri bu iki katman üzerinden geçmektedir. Mimarinin içindeki eleman sayısı, çıktı katmanı, problem tanımına göre sınıf sayısına eşittir. Tam yoğun katmanlar için aktivasyon fonksiyonu ReLU kullanılırken, son çıktı katmanı için aktivasyon fonksiyonu için SoftMax kullanılmıştır.

5.4.f Aşırı uyum minimizasyonu

Herhangi bir makine öğrenimi algoritmasında ortaya çıkan ana zorluklardan biri, aşırı uyum sorunudur. Bu durum, modelin tüm alakasız gürültüsünü ezberlemeyi içeren eğitim veri kümesinin düzenliliklerini öğrendiği ve bu nedenle yeni tanıtılan verilerin eğitim için çok zayıf çalıştığı bir durumu ifade etmektedir. Bu sorunu azaltmak için, görüntü verileri için, özellik bırakma veya ağırlık azaltma süreci ile düzenleme ve bu çalışma çerçevesi için veri artırma kullanılmıştır. Bu durum için, aşağı akış nöronlarının aktivasyonu, ileri geçişte geçici olarak kaldırılmış ve geri geçişte nörona herhangi bir ağırlık güncellemesi uygulanmamıştır. Bu çalışmada, tüm evrişimli ve tam yoğun katmanlar için yalnızca havuz katmanları ve ikinci yoğun katmanlar için veri bırakma uygulanmıştır.


5.4.g Sentetik veri arttırma

Fazla uyumu azaltmak için yukarıda bahsedilen tüm teknikleri uygulamanın yanı sıra, tüm analiz için yalnızca genişletilmiş ve geliştirilmiş bir model oluşturmak için eğitim veri setimize veri arttırma uygulanmıştır. Bu süreçte farklı veri dönüştürme kriterleri kullanılmıştır. Modelin eğitim yinlemeleri boyunca benzer türde girdileri almaması için eğitim verileri genişletilmiştir. Çeşitli veri dönüştürme teknikleri arasında, tüm eğitim setlerine yatay çevirme ile 45° döndürme hem yükseklik hem de genişlikte 15° kaydırma uygulanmıştır. Kusurun uzamsal bilgisi bu veri çerçevesinde görüntünün herhangi bir yerinde olabileceğinden görüntü yakınlaştırılmasından kaçınılmıştır.

5.4.h Eğitim detayları

Bu çalışmadaki mimari ayarlar ve ağ deneyleri, Nvidia RTX 2080 grafik işlem birimine (GPU) sahip 12 çekirdekli Core i7 10ncu nesil işlemci üzerinde gerçekleştirilmiştir. DESA kodu için TensorFlow sürüm 2.1 kullanılarak Python 3,9 üzerinde gerçekleştirilmiştir. Farklı deney ayarları boyunca bazı eğitim parametreleri sabit tutulmuştur. Optimizasyon algoritması için stokastik gradyan iniş algoritmasının bir uzantısı olan Adam optimizasyonu kullanılmıştır. Çoklu sınıflandırma problemi için kayıp fonksiyonu olarak çapraz entropi kullanılmıştır. Ağı eğitmek için toplu iş boyu 30 ve öğrenme oranı 1e-4 kullanılmıştır.

Bu çalışmada, IN718 malzeme parçalarının hata tespiti için en uygun sonuçları elde etmek için farklı DESA mimari ayarları ile deneyler yapılmıştır. Özellik çıkarma eşleme modeli tüm deneylerde aynı kalırken, girdi boyutu, örnekleme, veri büyütme ve sınıflandırma bloğu, minimum fazla uydurma ve modellerinin eğitimi, doğrulaması ve test edilmesi için kayıp, doğruluk arasında iyi bir korelasyon elde etmek için değiştirilmiştir. Şekil 16, modelleri eğitirken farklı konfigürasyonların hem eğitimi hem de doğrulaması için kayıp ve doğruluğu göstermektedir.



Şekil 16. Farklı mimariler için eğitim ve doğrulama sonuçları

Tablo 12. Eğitim, doğrulama ve test sonuçları ile DESA model yapılandırmaları ve ayarları

Model	Girdi	Örnekleme	Büyütme	Sınıflandırıcı	Kayıp			Doğruluk		
					Eğitim	Doğrulama	Test	Eğitim	Doğrulama	Test
01	220x220x3	-	-	512	0,05	9,68	2,5	0,992	0,62	0,81
02		-	-	512	0,58	2,14	0,69	0,883	0,751	0,92
03		x	-	512	0,16	3,12	2,1	0,993	0,943	0,93
04		x	x	512	0,48	0,39	0,57	0,956	0,948	0,964
05	252x252x3	x	x	512,128	0,09	0,56	0,05	0,983	0,963	0,974
06	210x210x3	x	x	512,128	0,59	0,84	0,74	0,906	0,932	0,916
07	260x260x3	x	x	512,128	0,17	0,58	0,16	0,953	0,958	0,943
Final	252x252x3	x	x	512,128	0,07	0,46	0,18	0,98	0,98	0,98

Bu çalışmada kullanılan farklı model konfigürasyonları ve ayarları ve bunların eğitim, doğrulama, test için nihai kaybı ve doğruluğu Tablo 12’de gösterilmektedir.

Model 01 sadece örneklenmiş verilerle eğitilmiştir. Örneklem ve büyültme yapılmamıştır. Modeli böyle bir konfigürasyonla eğitmenin amacı, herhangi bir ek örneklem ve büyültme olmaksızın DESA modelinin davranışını gözlemlemektir. Model 01’de eğitim kaybı olmamasına rağmen doğrulama kaybı çok yüksek çıkmaktadır. Şekil 15’te görüldüğü üzere, Model 02 için eğitim ve doğrulama arasındaki hem kayıp hem de doğruluk farkı, veri arttırma uygulaması nedeniyle bir noktaya kadar azaltılabilmektedir. Model 03’te eğitim ve doğrulama doğruluğu, hem yapılandırma olarak Model 01’e göre, hem de Model 02 ile karşılaştırıldığında iyi bir uyum içinde olsa da eğitim ve doğrulama arasındaki kayıp farkı, Model 01’de elde edilen farkla karşılaştırıldığında daha az oranda elde edilmektedir. Ancak, 2 numaralı Model konfigürasyonundan çok daha yüksektir. Model 04’te eğitim ve doğrulama arasındaki hem kayıp hem doğruluk farkının en aza indiği görülmektedir. Model 01’den Model 04’e kadar konfigürasyon için yapılan deneylerin bir kısmı, hata tespiti, örneklem ve veri büyütme için bir DESA modelinin performansını bırakma ve düzenlemenin tek başına iyileştirilemeyeceği tespit edilmiştir. Model 04’te eğitim veri seti için hem üst örneklem hem de veri büyütme uygulanırken, tek bir tam 512 nöron katmanı kullanılmıştır. Bu nedenle, sınıflandırma bloğundaki katman sayısı arttırılmıştır ve ek katmanın model performansı üzerindeki etkisini gözlemlemek için ağ eğitilmiştir. Model 04 için doğruluk, eğitim ve doğrulama için hem kayıp hem de doğruluğun Model 05’te tespit edilenden daha çok erken bir noktada kesiştiği görülmektedir. Bu durumun olası sebepleri, Model 05’teki toplam parametre sayısı, Model 04’teki parametrelerden daha fazladır. Ayrıca, doğrulama kaybında ani artışlar ortaya çıkmıştır. Hem Model 04 hem de Model 05 için eğitim, doğrulama ve test kayıpları arasında önemli bir fark bulunmamaktadır. Ancak Model 05, Model 04 ile karşılaştırıldığında eğitim doğruluğu artış oranının daha yüksek olduğu tespit edilmiştir. Bu nedenle, yapılandırma Model 05 için 252 x 252 x 3 giriş boyutu için en uygun DESA modeli olduğu sonucuna varabiliriz. Deney sayısını arttırmak için Model 05’teki giriş boyutu değiştirilmiştir. Model 06 ve Model 07 için 210 x 210 x 3 ve 260 x 260 x 3 giriş boyutu kullanılmıştır. Model 06 için kayıp ve doğruluk grafiğinden görebileceğimiz gibi hem eğitim hem de doğrulama kaybı 250 yenilemeye kadar sabit kalmıştır. Bundan sonra, model sorunsuz bir şekilde eğitime başlamıştır. Model 07 için, kayıp ve doğruluk da Model 05 ile karşılaştırıldığında daha azdır. Eğitim için gereken toplam süre, bu çalışma çerçevesinde denenen Model 05, 06, 07 konfigürasyonları için yaklaşık 12 saattir. Test setinin tüm test veri seti sonuçlarını

oluşturması yaklaşık 1 saat sürmüştür. Model 05'in eğitim, doğrulama, test kaybı ve doğruluğu için en iyi sonucu verdiği anlaşılmaktadır. Ancak bu konfigürasyonda hem eğitim hem de doğrulama için kayıp ve doğruluk 300 yenilemeden sonra da yükselme gösterememiştir. Bu nedenle eğitim setinin oranlarında değişikliğe gitmek gerekmektedir.

Yukarıdaki tartışmadan, DESA modeli için Model 05'in eğitim, doğrulama ve test açısından en iyi sonuçları verdiği açıktır. Son olarak, optimize edilmiş DESA modelinin performansı kesinlik, geri çağırma ve F ölçümü kullanılarak değerlendirilmiştir.

$$Kesinlik = \frac{TP}{TP+FP} \quad (14)$$

$$Geri \text{ çağırma} = \frac{TP}{FN+TP} \quad (15)$$

$$Fölçümü = \frac{2 \times Kesinlik \times Geri \text{ çağırma}}{Kesinlik + Geri \text{ çağırma}} \quad (16)$$

Denklem 14'e göre kesinlik, gerçek pozitif (TP) / gerçek pozitif (TP) ve yanlış pozitif (FP) sonuçlarının toplamı olarak, Denklem 15 ise, geri çağırma, gerçek pozitif (TP) / yanlış negatif (FN) ve gerçek pozitif (TP) sonuçlarının toplamı olarak hesaplanmaktadır. Denklem 16'da F-ölçümü, kesinlik ve geri çağırmanın genel performansını temsil etmektedir. Optimize edilmiş DESA modelinin kesinliği, geri çağırması ve F-ölçümü önceki çalışmanın karşılaştırılması ile Tablo 13'te gösterilmektedir. Her sınıf türü için kesinlik (≥ 0.97) ve geri çağırma (≥ 0.97) eğitim, doğrulama ve test doğruluğu ile iyi bir uyum içindedir. F-ölçümü (≥ 0.97) mevcut çalışma için değerlendirme metriklerinden elde edilen sonuçlar, DESA modelinin minimum fazla uyum ve yüksek doğrulukla iyi eğitildiğini göstermektedir. Tablo 14, DESA mimarisinin, bu çalışmada ve önceki çalışmada kullanılan parametrelerin karşılaştırmasını göstermektedir. Her iki çalışmada da girdi görüntü boyutunda, görüntü sayısında, DESA çekirdeklerinde, öğrenme oranlarında kayda değer farklılıklar görülmektedir. Ağ mimarisi dahil tüm bu parametreler, Toz metalürjisi ile üretilen parçaların hata tespiti için DESA mimarisinin %92'lik (Sun *et al.*, 2019) performansından %98'e ulaşmasında önemli bir rol oynamaktadır.

Tablo 13. Bu çalışmada daha önceki çalışmalar ile, bu çalışmada oluşturulan model performanslarının karşılaştırılması(Sun *et al.*, 2019)

Karşılaştırma	Bu çalışma			Diğer çalışma		
Sınıflar	Doğruluk	Geri çağırma	F-ölçümü	Doğruluk	Geri çağırma	F-ölçümü
Hatasız	0,98	0,99	0,98	0,90	0,90	0,90
Hatalı	0,97	0,98	0,97	0,93	0,94	0,93
Makro ortalama	0,98	0,98	0,98	0,92	0,92	0,92
Ağırlık ortalaması	0,98	0,98	0,98	0,92	0,92	0,92
Kesinlik	0,98			0,92		

Tablo 14. DESA mimarisi ile kullanılan parametrelerin karşılaştırılması, bu çalışma ve önceki çalışma(Sun *et al.*, 2019)

Parametreler	Girdi görünümlüsü	Girdi boyutu	Toplam veri	Veri büyütmeye	DESA kernel	Adımlama	Devir	Eğitim zamanı
Bu çalışma	Gri	252x252x3	4000	Rotasyon: 45° Değişim: yatay ve dikey Döndürme: yatay	Katman 1: 3x3x32 Katman 2: 3x3x64 Katman 3: 3x3x128	Tüm katmanlar:1 Havuzlama:2	300	12
Diğer çalışmalar	Gri	224x224	1274	Belirtilmemiştir	Belirtilmemiştir	Belirtilmemiştir	Belirtilmemiştir	Belirtilmemiştir

Bu bölümde, derin evrişimli sinir ağı (DESA) tabanlı bir yapay zekâ modeli kullanılarak optik görüntülerden toz metalürjisi ile üretilen (IN718) parçalara ait kusurları tespit edilmiştir. Ayrıca, bu bölümde veri hazırlama ve işleme için sistematik bir yaklaşım sunulmuştur. Modelin veri üzerinde etkisini ölçmek amacıyla veri

büyütme ile ağın eğitilmesinin DESA modelinin performansı üzerindeki etkisi de değerlendirilmiştir. Bu çalışmada önerilen DESA modelinin performansı, önceki çalışmada bildirilen sonuçları (%92) aşmaktadır.



6. SONUÇ VE ÖNERİLER

Bu çalışmada görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılarak toz metalürjisi ile üretilmiş olan on farklı metal parçaların hatalı olanlarını tespit edebilen, hızlı ve maliyeti düşük bir sistem geliştirilmiştir. Metal somun parçalarına ait gerçek zamanlı bir sistem tarafından yakalanan görüntüler, kusurları işlemek ve bulmak için kullanıldı. Ortaya çıkan görüntü verilerinin yüksek çözünürlüğü ve çok sayıda görüntünün de işlenecek olması veri miktarını artırmaktadır. Bununla birlikte analiz edilen verinin yuvarlak bir metal nesne olması nedeniyle hatanın tespit edilmesi için ekstra görüntü işleme süreçlerinin uygulanması gerekmiştir.

6.1. Teorik çıkarımlar

Mevcut konuyla ilgili literatürün analizi, hata unsurunun tespitinde çeşitli bilgi sistemlerinin, teknolojilerinin kullanılması ve sanayi endüstrisini etkilediğini göstermektedir. Örneğin, kullanılan çeşitli algoritmaların türleri, kullanılan malzeme araçlarının yapısı, üretim aşamalarının türleri, yapay zekâ odaklı uygulamaların davranışlarından birkaçıdır. İlgili literatüre katkı sağlamak amacıyla bu çalışma, temel olarak farklı malzeme kategorilerinde yüzey hata unsurunun tespiti ile tanımlı arasındaki ilişkiye odaklanmaktadır. Bu araştırma, malzeme yüzeyindeki farklılıkların hata unsurunun tespitinde önemli bir rol oynadığını açıkça göstererek önceki çalışmaları doğrulamaktadır.

6.2. Yönetimsel çıkarımlar

Bu çalışma, endüstriyel metal parça üretiminde hata özelliklerinin farklı malzeme kategorilerinin tespit edilmesi ve üretim proses parametrelerinin, üretim yöntemini nasıl etkilediğine dair önemli bulgular sunmaktadır. Bu çalışmanın bulguları, kullanılan derin öğrenme uygulamalarının türüne bağlı olarak, söz konusu uygulamanın nasıl kullanılacağını ve başarılı sonuçların nasıl elde edileceğinin mümkün olduğunu göstermektedir.

Bir girdi görüntüsünün aşabileceği en yüksek uzaysal frekans bilgisini çıkarmak, bu çalışmanın önerdiği “k” detektörü ile tek görüntü enterpolasyonu ve kör pan keskinleştirme uygulamalarıyla birlikte algoritmalar üzerinde kullanışlılığı

ispatlanmıştır. Piksel perspektifinden, tek görüntü enterpolasyon problemini ele almak için, bir görüntünün frekans alanındaki karşılığına, yani karmaşık değerli katsayıların çoklu bantlarına ayrıştıran yeni bir görüntü sunumu önerilmiştir. Bununla birlikte, orijinal görüntülerdeki piksel kenarlarını temsil eden katsayıların bant dışı frekans katsayıları ve bant içi frekans katsayıları tespit edilmiştir. Tahmini örtüşmeyen katsayıları piksel alanı üzerinden yeniden yapılandırarak, görüntülenen görüntülerin hem kenar profil yönleri hem de kenarların kontur yönleri sınıflandırılmıştır.

Bu çalışma yarı-yerel benzerlikten yararlanan tipik algoritmaların birbirini dışlayan iki parçasında örtüşme oluşturmanın yarattığı benzersiz zorlukları aşmak için görüntü piksellerinden yararlanarak parça yüzey hata unsurlarını tespit eden ilk çalışmadır. Özenle tasarlanmış özgün görüntü yakalama sistemi aracılığıyla, geleneksel tekniklerde çıkarılamayan düşük frekanslı görüntü bileşenlerinde örtüşmeyi güçlü bir şekilde ortadan kaldırılmıştır. Bu çalışmanın önerdiği “k” detektörü, altı model tabanlı algoritmalarla karşılaştırıldığında hem iki hem üç faktörlü enterpolasyon görevinde yaygın olarak kullanılan on farklı veri kümeleri arasında en yüksek SGO oranını elde etmiştir. Sayısal algoritmalar, uzamsal tüm model tabanlı algoritmalar arasında, “k” detektörünün hem en hızlı çalışma hızlarına hem de en yüksek görüntü kalitesine ulaştığı tespit edilmiştir.

Makine öğrenimi algoritmalarının ardışık düzenlerini kullanıcıya yönelik uygulamalara uyguladığımızda, dikkate alınması gereken yeni zorluklar ortaya çıkmaktadır. Örneğin, insanları doğrudan etkileyebilecek kararlar almak için derin öğrenmeyi kullandığımızda, derin öğrenme modellerinin bu kararları nasıl ve neden verdiğini anlamak çok önemlidir. K detektörü ’nün çeşitli model tasarımları ile sağlamlık ve yorumlanabilirlik arasındaki ilişkiyi daha iyi anlamak gerekmektedir. Burada, hesaplama, dikkatli bir şekilde veri hareketini ve hesaplamayı verimli bir şekilde kullanmak için makine öğrenimi sistemlerinin çerçevesi, işlem hatlarında hata ayıklarken etkileşimi sürdürmek için her zamankinden daha önem teşkil etmektedir.

6.3. Kısıtlar ve Gelecek araştırmalar

Düşük işlem güçlerinde makine öğrenimini verimli bir şekilde uygulamanın zorlukları bulunmaktadır. Örneğin, kişi başına çok daha az bilgi işlem ve bellek kaynaklarının mevcut olduğu durumlar söz konusu olabilmektedir. Analiz süreçlerinde

hem veri erişimini hem de hesaplamayı azaltmak için çeşitli operatörleri bir derin öğrenme modelinde birleştirme ihtiyacı duyulmaktadır.

Görüntü perspektifinden bakıldığında, yoğun kenarlara, desenlere ve dokulara sahip uzamsal bölgeler ile uğraşmak gelecekte yapılacak çalışmalara konu olacaktır. Bu zorluğun üstesinden gelmek için karmaşık değerli görüntü temsili konusundaki alan bilgileri makine öğrenimi yaklaşımları ile birleştirilebilir.

Gri renk düzeyinde örtüşen görüntülerde görüntülerin yüzey ilerlemesi noktasında uç kenar analizleri yapılabilir. Bununla birlikte enterpolasyonlu görüntü üzerinde, kenarların yerleştirilmiş yönlerinin çıkarılmasına yardımcı olmak ve enterpolasyonlu görüntülerdeki yapaylıkları bastırmak için ekstra kısıtlamalar getirilebilir. Gelecek çalışmalarda tek boyutlu ve üç boyutlu görüntülerin işlenmesinde, piksel örtüşmenin etkisi dikkate alınabilecektir.

KAYNAKLAR

Ackoff, R. L., Aguilera-Caracuel, J., Hurtado-Torres, N. E., Aragón-Correa, J. A., Al-Mawali, H., Al-Shbiel, S. O., ... & van Tartwijk, J. (2010). Business research methods. *Journal of Knowledge Management*, 14(1).

Agrawal, P., Chaudhary, D., Madaan, V., Zabrovskiy, A., Prodan, R., Kimovski, D., & Timmerer, C. (2021). Automated bank cheque verification using image processing and deep learning methods. *Multimedia Tools and Applications*, 80(4), 5319-5350.

Ahmadianfar, I., Bozorg-Haddad, O., & Chu, X. (2020). Gradient-based optimizer: A new metaheuristic optimization algorithm. *Information Sciences*, 540, 131-159.

Alaofi, Z. M., Ali, T. S., & Dragomir, S. S. (2021). A numerical solution of the dissipative wave equation by means of the cubic B-spline method. *Journal of Physics Communications*, 5(10), 105014.

Benzerrouk, S., Ludwig, R., & Apelian, D. (2007, March). Active thermography for the detection of defects in powder metallurgy compacts. In *AIP Conference Proceedings* (Vol. 894, No. 1, pp. 1312-1319). American Institute of Physics.

Breiman, L. (1997). Arcing the edge. Technical Report 486, Statistics Department, University of California at Berkeley.

Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2), 123-140.

Cao, J., Yang, G., & Yang, X. (2020). A pixel-level segmentation convolutional neural network based on deep feature fusion for surface defect detection. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-12.

Chahal, A., & Gulia, P. (2019). Machine learning and deep learning. *International*

Journal of Innovative Technology and Exploring Engineering, 8(12), 4910-4914.

Chandrasekaran, M., Muralidhar, M., Krishna, C. M., & Dixit, U. S. (2010). Application of soft computing techniques in machining performance prediction and optimization: a literature review. *The International Journal of Advanced Manufacturing Technology*, 46(5), 445-464.

Committee, S. (1998) *IEEE Standard for Software Verification and Validation IEEE Standard for Software Verification and Validation, IEEE Institute of Electrical and Electronics Engineers*, 69(8), 128-139.

Cortés, E., & Sánchez, S. (2021). Deep Learning Transfer with AlexNet for chest X-ray COVID-19 recognition. *IEEE Latin America Transactions*, 19(6), 944-951.

Padraig, C., & Sarah, J. (2007). k-Nearest neighbour classifiers. *Multiple Classifier Systems*, 34(8), 1-17.

Dejaegher, B., & Vander Heyden, Y. (2008). Supersaturated designs: set-ups, data interpretation, and analytical applications. *Analytical and bioanalytical chemistry*, 390(5), 1227-1240.

Diener, S., Zocca, A., & Günster, J. (2021). Literature review: Methods for achieving high powder bed densities in ceramic powder bed based additive manufacturing. *Open Ceramics*, 8, 100191.

Du, J., Zhang, X., & Shi, J. (2018). A condition change detection method for solar conversion efficiency in solar cell manufacturing processes. *IEEE Transactions on Semiconductor Manufacturing*, 32(1), 82-92.

Du, M., Yang, F., Zou, N., & Hu, X. (2020). Fairness in deep learning: A

computational perspective. *IEEE Intelligent Systems*, 36(4), 25-34.

Dunstan, M. K., Paramore, J. D., & Fang, Z. Z. (2018). The effects of microstructure and porosity on the competing fatigue failure mechanisms in powder metallurgy Ti-6Al-4V. *International Journal of Fatigue*, 116, 584-591.

BUYAKOVA, S. P. (2014). optimization of ceramic manufacturing process using Plackett-Burman design of experiment. *építőanyag*, 52.

Eminaga, O., Abbas, M., Semjonow, A., Brooks, J. D., & Rubin, D. (2020). Determination of biologic and prognostic feature scores from whole slide histology images using deep learning.

Erwin, I. M., Risnandar, E. P., & Sugiarto, B. (2020). Kayu7net: Identifikasi dan Evaluasi F-Measure Citra Kayu berbasis Deep Convolutional Neural Network (DCNN). *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 7(6).

Fan, K. C., Chen, S. H., Chen, J. Y., & Liao, W. B. (2010). *NDT&E International*, 49(8), 79-85.

Fang, M., Yu, Z., Zhang, W., Cao, J., & Liu, W. (2022). Friction coefficient calibration of corn stalk particle mixtures using Plackett-Burman design and response surface methodology. *Powder Technology*, 396, 731-742.

Xiao-liang, F. A. N. G., & He-jing, Z. H. E. N. G. (2020). Application and prospect of copper-based powder metallurgy friction materials. *粉末冶金技术*, 38(4), 313-318.

Morita, R. Y. (1975). Psychrophilic bacteria. *Bacteriological reviews*, 39(2), 144-167.

Room, C. (2020). Deep Learning Frameworks. *algorithms*, 11(45), 11.

Falkenhainer, B., Forbus, K. D., & Gentner, D. (1989). The structure-mapping engine: Algorithm and examples. *Artificial intelligence*, 41(1), 1-63.

Fukushima, K. (1981). Neocognitron--a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *NHK 放送科学基礎研究所報告*, (15), p106-115.

Gadhawe, R. V., Gadhawe, C. R., & Dhawale, P. V. (2022). Plastic-Free Bioactive Paper Coatings, Way to Next-Generation Sustainable Paper Packaging Application: A Review. *Green and Sustainable Chemistry*, 12(2), 9-27.

Gao, Y. X., Zou, J. W., Wang, X. F., Yang, J., Li, Z., Zhu, Y. Y., & Wang, H. M. (2019). An Approach to the Uniform Dispersion of Graphene Nanosheets in Powder Metallurgy Nickel-Based Superalloy. *Materials*, 12(6), 974.

Gashnikov, M. V. (2021). Pyramidal Image Compression Using the Parameterized NEDI Algorithm. *Optical Memory and Neural Networks*, 30(3), 187-193.

葛疏雨, 高子淋, 张冰冰, & 李培华. (2019). 基于核化双线性卷积网络的细粒度图像分类. *电子学报*, 47(10), 2134.

Randall, M. G. (1994). *Powder metallurgy science*. Metal Powder Industries Federation, Princeton, New Jersey, USA.

GNATUSHENKO, V., DOROSH, N., & FENENKO, T. (2021). FASHION MNIST IMAGE RECOGNITION BY DEEP LEARNING METHODS. *APPLIED QUESTIONS OF MATHEMATICAL MODELLING*, 4(1), 78-85.

Gong, D., Goh, O. S., Kumar, Y. J., Ye, Z., & Chi, W. (2020). Deepfake forensics, an ai-synthesized detection with deep convolutional generative adversarial networks. *International Journal*, 9(3).

Grison, J., & Remy, L. (1997). Fatigue failure probability in a powder metallurgy Ni-base superalloy. *Engineering Fracture Mechanics*, 57(1), 41-55.

Gul, E., Alpaslan, N., & Emiroglu, M. E. (2021). Robust optimization of SVM hyper-parameters for spillway type selection. *Ain Shams Engineering Journal*, 12(3), 2413-2423.

Han, X., & Han, J. (2019). Bicubic B-spline surfaces constrained by the Biharmonic PDE. *Applied Mathematics and Computation*, 361, 766-776.

Hao, K., Lin, S., Qiao, J., & Tu, Y. (2021). A Generalized Pooling for Brain Tumor Segmentation. *IEEE Access*, 9, 159283-159290.

Abu, H. M. F., Hussain, A., & Hassan, M. F. A. (2019). Convolution neural network-based action recognition for fall event detection. *International Journal of Advanced Trends in Computer Ence and Engineering*, 8(1), 466-470.

Abu, H. M. F., A. Hussain, and M. F. A. Hassan. "

He, Z., & Liu, Q. (2020). Deep regression neural network for industrial surface defect detection. *IEEE Access*, 8, 35583-35591.

Hirahara, D., Takaya, E., Kadowaki, M., Kobayashi, Y., & Ueda, T. (2021). Effect of the Pixel Interpolation Method for Downsampling Medical Images on Deep Learning Accuracy. *Journal of Computer and Communications*, 9(11), 150-156.

Siu, W. C. (2015). Fast Image Interpolation via Random Forests. *IEEE Transactions*

on Image Processing, 12(8), 160-171.

HUSSEIN, A. K. (2019). Subject Review: Machine Learning and Deep Learning based Arabic Handwriting Recognition, 7(9), 45-61.

Ji, J., Zhong, B., & Ma, K. K. (2020). Image interpolation using multi-scale attention-aware inception network. IEEE Transactions on Image Processing, 29, 9413-9428.

Jia, H., Murphey, Y. L., Shi, J., & Chang, T. S. (2004, August). An intelligent real-time vision system for surface defect detection. In Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004. (Vol. 3, pp. 239-242).

Jie, H. J., & Wanda, P. (2020). RunPool: A Dynamic Pooling Layer for Convolution Neural Network. Int. J. Comput. Intell. Syst., 13(1), 66-76.

Venkatachalam, R. (2018). Human and Machine Learning. Computational Economics, 18(7), 52-87.

KARAGÖZ, Ş., YAMANOĞLU, R., & ATAPEK, Ş. H. (2009). Metalik toz işleme teknolojisi ve prosesleme kademeleri açısından parametrik ilişkiler. Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi, 22(3), 77-87.

Kelleher, J. D. (2020) ‘A Brief History of Deep Learning’, in *Deep Learning*, 11(5), 25-32.

Kennette, L. N., & Wilson, N. A. (2019). Universal design for learning (UDL): Student and faculty perceptions. Journal of Effective Teaching in Higher Education, 2(1), 1-26.

Krishna, M. M., Neelima, M., Harshali, M., & Rao, M. V. G. (2018). Image

classification using deep learning. *International Journal of Engineering & Technology*, 7(2.7), 614-617.

L Lecouat, B., Ponce, J., & Mairal, J. (2020, August). Fully trainable and interpretable non-local sparse models for image restoration. In *European Conference on Computer Vision* (pp. 238-254). Springer, Cham.

LeCun, Y., & Bengio, Y. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, 3361(10), 1995.

Lestari, W. (2016). PENGARUH PELAYANAN PROMOSI DAN SYARIAH TERHADAP MINAT NASABAH DALAM MEMILIH ASURANSI SYARIAH (Studi pada PT. Asuransi Takaful Keluarga Cabang Palembang)(Skripsi) (Doctoral dissertation, UIN RADEN FATAH PALEMBANG).

Li, B. K., Miao, Q., Li, M., Zhang, X., & Ding, W. F. (2020). An investigation on machined surface quality and tool wear during creep feed grinding of powder metallurgy nickel-based superalloy FGH96 with alumina abrasive wheels. *Advances in Manufacturing*, 8(2), 160-176.

Li, J., & Chen, S. (2016). The cubic α -Catmull-Rom spline. *Mathematical and Computational Applications*, 21(3), 33.

Li, Z., Cai, X., Liu, Y., & Zhu, B. (2019). A novel gaussian-bernoulli based convolutional deep belief networks for image feature extraction. *Neural Processing Letters*, 49(1), 305-319.

Lin, C. Y., Chen, C. H., Yang, C. Y., Akhyar, F., Hsu, C. Y., & Ng, H. F. (2019, July). Cascading convolutional neural network for steel surface defect detection. In *International Conference on Applied Human Factors and Ergonomics* (pp. 202-212).

Springer, Cham.

Ludwig, R., Makarov, S., & Apelian, D. (1998). Three-dimensional solution and experimental confirmation for the electric resistivity testing of surface-breaking defects in green-state powder metallurgy compacts. *Journal of nondestructive evaluation*, 17(3), 153-166.

Marmanis, D., Datcu, M., Esch, T., & Stilla, U. (2015). Deep learning earth observation classification using ImageNet pretrained networks. *IEEE Geoscience and Remote Sensing Letters*, 13(1), 105-109.

McNeely-White, D., Beveridge, J. R., & Draper, B. A. (2020). Inception and ResNet features are (almost) equivalent. *Cognitive Systems Research*, 59, 312-318.

Mongomery, D. C. (2017). *Montgomery: design and analysis of experiments*. John Willy & Sons.

O'donovan, P., Leahy, K., Bruton, K., & O'Sullivan, D. T. (2015). Big data in manufacturing: a systematic mapping study. *Journal of Big Data*, 2(1), 1-22.

Nejad, D. G., Khanchi, A. R., & Taghizadeh, M. (2018). Recovery of vanadium from magnetite ore using direct acid leaching: Optimization of parameters by Plackett–Burman and response surface methodologies. *Jom*, 70(6), 1024-1030.

Nemeth, C., & Fearnhead, P. (2021). Stochastic gradient markov chain monte carlo. *Journal of the American Statistical Association*, 116(533), 433-450.

Parsania, P. S., & Virparia, P. V. (2016). A comparative analysis of image interpolation algorithms. *International Journal of Advanced Research in Computer and Communication Engineering*, 5(1), 29-34.

Passos, L. A., & Papa, J. P. (2018). Temperature-based deep boltzmann machines. *Neural Processing Letters*, 48(1), 95-107.

Aich, S., & Ravi Chandran, K. S. (2002). TiB whisker coating on titanium surfaces by solid-state diffusion: Synthesis, microstructure, and mechanical properties. *Metallurgical and Materials transactions A*, 33(11), 3489-3498.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., & Fei-Fei, L. (2015). Desafio de reconhecimento visual em grande escala do ImageNet. *International Journal of Computer Vision*, 115(3), 211-252.

Saikia, P., Baruah, R. D., Singh, S. K., & Chaudhuri, P. K. (2020). Artificial Neural Networks in the domain of reservoir characterization: A review from shallow to deep models. *Computers & Geosciences*, 135, 104357.

Schonlau, M., & Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, 20(1), 3-29.

Sharma, V., & Mir, R. N. (2019). Saliency guided faster-RCNN (SGFr-RCNN) model for object detection and recognition. *Journal of King Saud University-Computer and Information Sciences*, 15(6), 25-39.

Shimizu, N., Mizusaki, T., Utsuno, Y., & Tsunoda, Y. (2019). Thick-restart block Lanczos method for large-scale shell-model calculations. *Computer Physics Communications*, 244, 372-384.

Siddharth, T., Gajbhiye, P., Tripathy, R. K., & Pachori, R. B. (2020). EEG-based detection of focal seizure area using FBSE-EWT rhythm and SAE-SVM network. *IEEE Sensors Journal*, 20(19), 11421-11428.

Tsang, S. H. (2018). Review: AlexNet, CaffeNet–Winner of ILSVRC 2012 (Image Classification). A Medium Corporation, 9.

Sohn, I. (2021). Deep belief network based intrusion detection techniques: A survey. *Expert Systems with Applications*, 167, 114170.

Soukup, D., & Huber-Mörk, R. (2014, December). Convolutional neural networks for steel surface defect detection from photometric stereo images. In *International Symposium on Visual Computing* (pp. 668-677). Springer, Cham.

Couto, A. L. D. S., Silveira, L. P., & Castro, M. D. (2022). Jogos digitais e acentuação gráfica: conexões possíveis entre aprendizagem e ludicidade. *Texto Livre*, 14.

Su, Q., Zhang, X., & Wang, H. (2022). A blind color image watermarking algorithm combined spatial domain and SVD. *International Journal of Intelligent Systems*, 37(8), 4747-4771.

Sun, J., Wang, P., Luo, Y. K., & Li, W. (2019). Surface defects detection based on adaptive multiscale image collection and convolutional neural networks. *IEEE Transactions on Instrumentation and Measurement*, 68(12), 4787-4797.

Sun, L., Shao, W., Zhang, D., & Liu, M. (2019). Anatomical attention guided deep networks for ROI segmentation of brain MR images. *IEEE transactions on medical imaging*, 39(6), 2000-2012.

Sun, R., Li, L., Zhu, Y., Guo, W., Peng, P., Cong, B., ... & Liu, L. (2018). Microstructure, residual stress and tensile properties control of wire-arc additive manufactured 2319 aluminum alloy with laser shock peening. *Journal of Alloys and Compounds*, 747, 255-265.

Sun, Z. Z., Ran, S. J., & Su, G. (2020). Tangent-space gradient optimization of tensor network for machine learning. *Physical Review E*, 102(1), 012152.

Talib, F., & Rahman, Z. (2010). Studying the impact of total quality management in service industries. *Talib, F. and Rahman, (2010)*, 249-268.

Tan, S., & Tan, Z. (2019, June). Improved LeNet-5 model based on handwritten numeral recognition. In *2019 Chinese Control And Decision Conference (CCDC)* (pp. 6396-6399). IEEE.

Tao, S., & Wang, J. (2020). Alleviation of gradient exploding in GANs: Fake can be real. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1191-1200).

Tao, X., Zhang, D., Ma, W., Liu, X., & Xu, D. (2018). Automatic metallic surface defect detection and recognition with convolutional neural networks. *Applied Sciences*, 8(9), 1575.

Wang, B., Janowski, G. M., & Patterson, B. R. (1995). SiC particle cracking in powder metallurgy processed aluminum matrix composite materials. *Metallurgical and Materials Transactions A*, 26(9), 2457-2467.

Wang, Y., Yao, Q., Kwok, J. T., & Ni, L. M. (2020). Generalizing from a few examples: A survey on few-shot learning. *ACM computing surveys (csur)*, 53(3), 1-34.

Wang, Z., Zeng, Y., Liu, Y., & Li, D. (2021). Deep belief network integrating improved kernel-based extreme learning machine for network intrusion detection. *IEEE Access*, 9, 16062-16091.

Wei, R., Song, Y., & Zhang, Y. (2020). Enhanced faster region convolutional neural networks for steel surface defect detection. *ISIJ international*, 60(3), 539-545.

Xiao, M., Wang, W., Shen, X., Zhu, Y., Bartos, P., & Yiliyasi, Y. (2021). Research on defect detection method of powder metallurgy gear based on machine vision. *Machine Vision and Applications*, 32(2), 1-13.

Xing, J., & Jia, M. (2021). A convolutional neural network-based method for workpiece surface defect detection. *Measurement*, 176, 109185.

Xu, L., Lv, S., Deng, Y., & Li, X. (2020). A weakly supervised surface defect detection based on convolutional neural network. *IEEE Access*, 8, 42285-42296.

Yang, Y., Pan, L., Ma, J., Yang, R., Zhu, Y., Yang, Y., & Zhang, L. (2020). A high-performance deep learning algorithm for the automated optical inspection of laser welding. *Applied Sciences*, 10(3), 933.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

Yi, X., Shen, Y., Zeng, M., Liu, Y., Chen, H., & Zhao, Z. (2022). Core point pixel-level localization by fingerprint features in spatial domain. *Mathematical Biosciences and Engineering*, 19(1).

Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.

Yuan, H., Chen, H., Liu, S., Lin, J., & Luo, X. (2019, October). A deep convolutional neural network for detection of rail surface defect. In *2019 IEEE Vehicle Power and Propulsion Conference (VPPC)* (pp. 1-4).

Zaykin, Y. A., & Aliyev, B. A. (2002). Radiation effects in high-disperse metal media and their application in powder metallurgy. *Radiation Physics and Chemistry*, 63(3-6), 227-230.

Zaynidinov, H., Bahromov, S., Azimov, B., & Kuchkarov, M. (2021). Lacol interpolation bicubic spline method in digital processing of geophysical signals. *Advances in Science, Technology and Engineering Systems*, 6(1), 487-492.

Zhang, Q., Vittal, V., Heydt, G., Chakhchoukh, Y., Logic, N., & Sturgill, S. (2012, July). The time skew problem in PMU measurements. In 2012 IEEE Power and Energy Society General Meeting (pp. 1-6). IEEE.

Zhu, L., Song, J., Wei, X., Yu, H., & Long, J. (2020). CAESAR: Concept augmentation based semantic representation for cross-modal retrieval. *Multimedia Tools and Applications*, 1-31.

Zhou, M., Duan, N., Liu, S., & Shum, H. Y. (2020). Progress in neural NLP: modeling, learning, and reasoning. *Engineering* 6 (3): 275–290.

Zhu, D., Lu, S., Wang, M., Lin, J., & Wang, Z. (2020). Efficient precision-adjustable architecture for softmax function in deep learning. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 67(12), 3382-3386.

Svoboda, A. (2019). Adaboost. In *Text Mining with Machine Learning* (pp. 201-210). CRC Press.

ÖZGEÇMİŞ

2005 yılından itibaren endüstriyel tasarımcı olarak yurtdışı freelance çalışmalar yapmaktadır. 2010 yılından beri de yapay zekâ teknolojileri üzerine çalışmalar makale ve projeler üretmektedir. Yaşar üniversitesi Sanat ve tasarım yüksek lisans programını 2014 yılında 4.00 ile birincilik ile tamamlamış. 2018 yılında Gebze Teknik Üniversitesi Sosyal Bilimler İşletme Anabilim dalında Doktora eğitimine başlamıştır. Halen Gebze Teknik Üniversitesi İşletme Fakültesi Yönetim Bilişim Sistemleri Bölümü'nde öğretim görevlisi unvanı ile ders vermektedir.

EKLER

PART NO	SURFACE QUALITY RATE	SURFACE QUALITY DEFECTION RATE
697234774981	0.6450	0.355
800123995478	0.5254	0.4746
737036042025	0.3811	0.6189
441682785539	0.5048	0.4952
557696608440	0.8515	0.1485
633840854688	0.3086	0.6914
324577386704	0.8585	0.1415
540708103955	0.4222	0.5778
421578753341	0.5539	0.4461
498685015734	0.6342	0.3658
441450162431	0.9235	0.0765
787041756437	0.7890	0.2110
829217252230	0.5313	0.4687
330870419685	0.9450	0.055
553480893793	0.8406	0.1594
716482265894	0.6977	0.3023
489873758501	0.6323	0.3677
341317312876	0.7025	0.2975
850768092269	0.8094	0.1906
390305016200	0.4312	0.5688
447508661024	0.9604	0.035
336573411474	0.9036	0.0396
818251589587	0.4911	0.5089
792983511424	0.5140	0.486
522056915083	0.9572	0.0428

600660971710	0.8524	0.1476
327138997096	0.8619	0.1381
666893353939	0.9144	0.0856
497591782014	0.8375	0.1625
536603720815	0.9427	0.0573
350658163806	0.5858	0.4142
650627733394	0.8243	0.1757
369502265407	0.869	0.131
849270259875	0.9020	0.098
417267422557	0.4412	0.5588
814065044339	0.6027	0.3973
554871466099	0.9371	0.0629
360284147769	0.8967	0.1033
558059384389	0.4235	0.5765
641368486345	0.5022	0.4978
427276553287	0.7700	0.23
843255766445	0.9707	0.0293
510545381128	0.9542	0.0458
513698768324	1	0
587843587152	0.6444	0.3556
699959412932	0.9678	0.0322
349389154604	0.9397	0.0603
493312066110	0.8136	0.1864
688723573212	0.7743	0.2257
636507278056	0.9695	0.0305
734481385265	0.9460	0.054
375962513219	1	0
837342313671	0.6048	0.3952
525843809765	0.8313	0.1687
412219083525	0.9653	0.0347

767203824363	0.7642	0.2358
503195792800	0.8999	0.1001
469807425225	0.6320	0.368
850765050106	0.8783	0.1217
620614748912	0.7175	0.2825
452812550623	0.9395	0.0605
452818203282	0.6361	0.3639
698529372570	0.8837	0.1163
463806885469	0.8486	0.1514
794949414527	0.4062	0.5938
312685976320	0.6365	0.3635
325193221005	0.8694	0.1306
475980625605	0.8602	0.1398
605505129428	0.8985	0.1015
736740145947	0.7132	0.2868
591322836324	0.6023	0.3977
788563099526	0.5544	0.4456
364135293695	0.5705	0.4295
327575830464	0.9308	0.0692
366910022866	0.7402	0.2598
816390563411	0.9132	0.0868
781603894259	0.5320	0.468
654429487698	0.8254	0.1746
590479337201	0.6447	0.3553
514957062240	0.9105	0.0895
607314739594	0.9777	0.0223
537728518809	0.9312	0.0688
480552843428	0.9346	0.0654
331307459581	0.4448	0.5552
415060435461	0.7252	0.2748

369061796807	0.6615	0.3385
577756407212	0.7418	0.2582
493348772669	0.7352	0.2648
299850604561	0.5548	0.4452
673436004339	0.7257	0.2743
751791268768	0.7672	0.2328
317923570756	0.9484	0.0516
512820412307	0.9930	0.0007
393443394455	0.8986	0.1014
659173307732	0.5515	0.4485
815379926127	0.5310	0.4690
377451338675	0.7513	0.2487
607847715082	0.9847	0.0153
741324679800	0.8143	0.1867
854278831063	0.7430	0.2670

Üretim Bilgisi : kod 26- seri 2354- parti 10178

Malzeme	Fe-2, Demir Moleküler Formül: Fe+2 PubChem Müşteri Kimliği: 27284 Molekül Ağırlığı: 55.84 Yapı: -
İşleme	Dövme, işleme, freze, tıraş, taşlama, ısıtma
Isı aşaması	Sementasyon, indüksiyon, alev, nitrürleme
Ana makineleri	NC dişli kalıp makineleri, NC dişli şekillendirme (Gealson, Moude), NC torna, NC dişli tıraş makineleri, NC dişli freze, Nc dişli taşlama Makineleri ve ilgili dişli birçok türde makineleri.

KİŞİSEL YAYIN VE ESERLER

1. Tunca S., Sezen B., Balcıoğlu Y.S., "Content and Sentiment Analysis of The New York Times Coronavirus (2019-N-Cov) Articles with Natural Language Processing (NLP) and Leximancer" Electronics, Feb. 2023
2. Balcıoğlu Y.S., Sezen B., Cerasi, C.C, Huang S., "Machine Design Automation Model for Metal Production Defect-Recognition with Deep Graph Convolutional Neural Network" Electronics, Jan. 2023
3. Balcıoğlu Y.S., Sezen B., Cerasi, C.C, "Solar cell busbars surface defect detection based on Deep Convolutional Neural Network" IEEE Latin America Transactions, Jan. 2023
4. Balcıoğlu Y.S., Sezen B., Gök Ş, Tunca S., "Image Processing; With Deep Learning: Surface Defect Detection Of Metal Gear Production; Through Deep Learning" Materials Evaluation , Feb. 2022
5. Balcıoğlu Y.S., Sezen B., "Estimation Of The Probability Of Bank Customers By Artificial Neural Networks" Universal Journal of Management, March 2020
6. Balcıoğlu Y.S., Artar M., Erdil O., "Proje yönetiminde yapay zeka: Bankacılık sektöründe bir uygulama" Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD), Nov. 2022
7. Balcıoğlu Y.S., Artar M., Erdil O., " Makine Öğrenimi ve Twitter Verilerinin Analizi: Covid19 Sonrası İş Trendlerinin Belirlenmesi", Social Science Development, Sept 2022

- 8.Balcıoğlu Y.S., Kılıç A., Pakdamar F., "Modeling of Laughing Mimic caught with Motion Capture Technology using Fuzzy Logic", Social Science Development, Nov. 2022
- 9.Balcıoğlu Y.S., Artar M., The Use of AI in Metaverse (pp.183-213), Springer Nature Business and Economics, March 2023.
- 10.Balcıoğlu Y.S., Özer G., Hisse senedi fiyat tahmini: Derin sinir ağları yöntemi ile Covid-19 sonrası (2020-2021) en çok yükselen 7 şirketin analizi (pp. 213-230), Contemporary Research Practices in Engineering in 21st Century: An Interdisciplinary Approach, June 2022.
- 11.Balcıoğlu Y.S., Sezen B., R yazılımı ile kalp hastalığına ait risk faktörlerinin tahmini (pp. 231-248), Contemporary Research Practices in Engineering in 21st Century: An Interdisciplinary Approach, June 2022.
- 12.Artar M., Balcıoğlu Y.S., Erdil O., İnsan kaynakları süreçlerinde yapay zeka kullanımı (pp.39-54), Güncel işletme, Yönetim ve Muhasebe çalışmaları, March 2022.
13. Balcıoğlu Y.S., Artar M., Çalışanların işten ayrılma olasılığının Makine öğrenmesi ile tahmini : K-En yakın komşu algoritması ile (pp.27-37), Güncel işletme, Yönetim ve Muhasebe çalışmaları, March 2022.
14. Kılıç A., Huseynov F., Balcıoğlu Y.S., Cerasi, C.C, ."A Sentiment Analysis to Understand the role of Twitter towards Sustainable Consumption", IEEE Information Technology, IT 2023, January 2023

15. Cerasi, C.C, Balcioğlu Y.S., "AI and Ethics in Education: ChatGPT Program Example", The International Symposium on Communication and Technology with its Philosophical Dimensions,, January 2023
16. Artar M., Balcioğlu Y.S.; Erdil O. "AI Recruitment: The Next Phase In Employee Selection", 17th International Strategic Management Conference, ISCM 2022, July 2022
17. Kılıç A., Balcioğlu Y.S., Özer G. "Firm bankruptcy prediction: comparative analysis with neural networks", XIV International congress on social sciences, China to Adriatic, June 2022
18. Balcioğlu Y.S., Özer G. "What proportion of the Bitcoin ecosystem is controlled by bots?", the 6th International Conference on Economic Development, Public Finance, Energy and Environment (ICBFP'2022), May 2022
19. Balcioğlu Y.S., Artar, M. "The use of AI in Metaverse", the 6th International Conference on Economic Development, Public Finance, Energy and Environment (ICBFP'2022), May 2022
20. Cerasi, C.C, Balcioğlu Y.S. "Understanding Society 5.0 Jobs for Improving Education 4.0 : An Analysis In Python", 6th FEB International scientific conference challenges in Economics and Business in the Post Covid Times 2022, May 2022
21. Balcioğlu Y.S. "Prediction with machine learning and comparison of land prices in the Metaverse universe", 2. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES, Feb 2022

- 22.Balcıoğlu Y.S."Detection of depression and anxiety symptoms via Twitter after Covid-19 with machine learning", 2. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES, Feb 2022
- 23.Balcıoğlu Y.S., Artar M., Erdil O., "Machine Learning and analysis of Twitter data: Identifying Trend Jobs after Covid-19", 7. International Battalgazi Scientific Studies Congress, Jan 2022
- 24.Balcıoğlu Y.S., Artar M., Erdil O., "Machine Learning in Employee Selection", 7. International Battalgazi Scientific Studies Congress, Jan 2022
- 25.Balcıoğlu Y.S., Artar M., Tunca S., "LSTM Method Analysis of U.S. Employees turnover after Covid-19 Comparative with the Sars-Cov2 Post Omicron Variant", 4. International NewYork Academic Research Congress, Jan 2022
26. Artar M., Balcıoğlu Y.S., Erdil O., "The Effect of Work-Family balance on interpersonal communication in Teleworkers", 4. International NewYork Academic Research Congress, Jan 2022
27. Tunca S., Sezen B., Balcıoğlu Y.S., "Twitter Analysis for Metaverse literacy", 4. International NewYork Academic Research Congress, Jan 2022
- 28.Balcıoğlu Y.S., Artar M., "Employee turnover prediction with Machine Learning: An Application with The K-Nearest Neighbors", 7. International Zeugma Conference on Scientific Researches, Jan 2022
29. Artar M., Balcıoğlu Y.S., Erdil O., "Use of Artificial Intelligence in Human Resources Processes", 7. International Zeugma Conference on Scientific Researches, Jan 2022

- 30.Balcıoğlu Y.S., Özer G.,"Stoke price forecasting method based Deep Neural Network over 5 stocks that performed the best in during Covid-19 between 2020-2021", 7. International Istanbul Scientific Research Congress, Dec 2021
- 31.Balcıoğlu Y.S., Sezen B.,"Predicting of Heart disease risk factors with R", 7. International Istanbul Scientific Research Congress, Dec 2021
- 32.Balcıoğlu Y.S., Gözel A.,"Alternative management approach: Lean Six Sigma", Global Business Research Congress, May 2019
- 33.Balcıoğlu Y.S., Sezen B.,"Yapay sinir ağları ile banka müşterilerinin bankadan ayrılma olasılığının tahmini" II. Business Organization Research Conference, Sept. 2019
- 34.Balcıoğlu Y.S., Gözel A., "2000-2019 Yillari Arasindaki İspanya Borsa Verilerinden Telefonica Firmasinin Yapay Sinir Ağlari Yöntemleri İle Karşılaştırmali Analizi" BOR Conference, Oct. 2019
- 35.Balcıoğlu Y.S., Gözel A., "2019 Dünya Mutluluk Raporu Analiz Sonuçlarının Yapay Sinir Ağlari Yöntemleri İle Karşılaştırmali Analizi" BOR Conference, Oct. 2019

