



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DERİN ÖĞRENME YÖNTEMİ İLE KESİCİ TAKIMLARIN
SINIFLANDIRILMASI VE TESPİTİ**

Kenan TAŞ

YÜKSEK LİSANS TEZİ
Makine Mühendisliği Anabilim Dalı

Ağustos 2023
BATMAN
Her Hakkı Saklıdır.

TEZ KABUL VE ONAYI

Kenan TAŞ tarafından hazırlanan “**Derin Öğrenme Yöntemi ile Kesici Takımların Sınıflandırılması ve Tespiti**” adlı tez çalışması 29/08/2023 tarihinde aşağıdaki jüri üyeleri tarafından oy birliği ile Batman Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan / Danışman

Doç. Dr. Şehmus BADAY

.....

Üye

Dr. Öğr. Üyesi Savaş KOÇ

.....

Üye

Dr. Öğr. Üyesi Fikret SÖNMEZ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdür V.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Kenan TAŞ

Tarih: 15.09.2023

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMİ İLE KESİCİ TAKIMLARIN SINIFLANDIRILMASI VE TESPİTİ

Kenan TAŞ

BATMAN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

Danışmanı: Doç. Dr. Şehmus BADAY

2023, 80 Sayfa

Jüri

Doç. Dr. Şehmus BADAY

Dr. Öğr. Üyesi Savaş KOÇ

Dr. Öğr. Üyesi Fikret SÖNMEZ

Gerçekleştirilen bu tez çalışmasında, tormalama işlemlerinde kullanılan ve ISO standartlarına göre C, R, S, Q vb. olarak adlandırılan takımların derin öğrenme yöntemi ile sınıflandırılması ve tahmini yapılmıştır. Bu amaçla farklı geometrik şekillere sahip kesici takım görüntüleri kullanılarak bir veri seti oluşturulmuştur. Bu veri setindeki görüntüler görüntü çoğaltma yöntemleri kullanılarak artırılmıştır. Daha sonra elde edilen bu veri setlerindeki görüntüler CNN, Xception, ResNet, LeNet, AlexNet ve GoogleNet ağ mimarileri ile kesici takım görüntüleri eğitilmiş, test edilmiş ve doğrulamaları yapılmıştır. Kesici takımların görüntüleri ISO standardında yer alan kodlara göre (C, R, S, Q vb) göre sınıflandırılmış ve görüntülerin tahmini de buna göre yapılmıştır. CNN, Xception, ResNet, LeNet, AlexNet ve GoogleNet ağ mimarileri ile eğitilen kesici takım görüntüleri doğrulama değerleri sırasıyla %91, %99, %13, %60, %97 ve %13 olarak elde edilmiştir. Bu ağ mimarilerinde en iyi sonuçları veren Xception, CNN ve AlexNet olduğu görülmüştür. ResNet, LeNet ve GoogleNet ile eğitilen görüntülerin başarı oranının düşük olduğu sonucuna varılmıştır. Sonuç olarak kesici takımların görüntüleri geliştirilen ve eğitilen derin öğrenme metodu ile değerlendirilmiştir. Böylece tormalamada ne tür bir kesici takım kullanıldığını tahmin eden ve işleme yöntemine uygun bir şekilde sınıflandırılan bir yöntem geliştirilmiştir. Bu görüntü işleme yöntemi ile kesici takımların farklı özellikleri kullanılarak sınıflandırılması ve otomasyon sistemlerinde etkin bir şekilde kullanılarak dijitalleşen sanayi alanına katkıda bulunulacaktır.

Anahtar Kelimeler: AlexNet, CNN, GoogleNet, LeNet, ResNet, TensorFlow2, Yapay sinir ağları, Xception,

ABSTRACT

MASTER'S THESIS

CLASSIFICATION AND DETECTION OF CUTTING TOOLS BY DEEP LEARNING METHOD

Kenan TAŞ

**BATMAN UNIVERSITY GRADUATE EDUCATION INSTITUTE
DEPARTMENT OF MECHANICAL ENGINEERING**

Advisor: Assoc. Dr. Sehmus BADAY

2023, 80 Pages

Jury

Assoc. Dr. Sehmus BADAY

Asst. Prof. Savaş KOÇ

Asst. Prof. Fikret SÖNMEZ

In this thesis study, C, R, S, Q etc. used in turning operations and according to ISO standards. The so-called teams were classified and predicted using the deep learning method. For this purpose, a data set was created using images of cutting tools with different geometric shapes. The images in this dataset were augmented using image augmentation methods. Then, the images in these obtained data sets were trained, tested and verified using CNN, Xception, ResNet, LeNet, AlexNet and GoogleNet network architectures. Images of cutting tools were classified according to the codes in the ISO standard (C, R, S, Q, etc.) and the images were estimated accordingly. Validation values of cutting tool images trained with CNN, Xception, ResNet, LeNet, AlexNet and GoogleNet network architectures are respectively obtained as 91%, 99%, 13%, 60%, 97% and 13%. It has been seen that Xception, CNN and AlexNet give the best results in these network architectures. It was concluded that the success rate of images trained with ResNet, LeNet and GoogleNet was low. As a result, the images of the cutting tools were evaluated with the developed and trained deep learning method. Thus, a method was developed that predicts what type of cutting tool is used in turning and classifies it in accordance with the processing method. With this image processing method, the classification of cutting tools using their different features and their effective use in automation systems will contribute to the digitalized industrial field.

Keywords: AlexNet, Artificial neural networks, CNN, GoogleNet, LeNet, ResNet, TensorFlow2, Xception,

ÖNSÖZ

Gerçekleştirilen bu tez çalışması 5 (beş) bölümden oluşmaktadır. Birinci bölüm tezin giriş bölümünü oluşturmakta ve kesici takımlar, kesici takım şekiller ve derin öğrenme yöntemi ile ilgili bilgiler verilmiş olup, tezin amacı açık bir şekilde belirtilmiştir.

İkinci bölümde yapılan çalışma ile ilgili literatür taraması yapılmış ve yapılan bu çalışmalar hakkında özet bilgiler sunulmuştur.

Üçüncü bölümde gerçekleştirilen bu tez çalışmasının materyal ve yöntemi hakkında bilgiler verilmiştir. Görüntü işlemede kullanılan yöntemler anlaşılır ve açık bir şekilde sunulmuştur. Evrişimli sinir ağları kullanılarak CNN, Xception, AlexNet, LeNet, GoogleNet ve ResNet ağ mimarileri ile kesici takımların görüntülerinin segmentasyon yoluyla analizi yapılmıştır. Bu derin öğrenme ağları ile kesici takımların görüntülerinden elde edilen verilerin eğitimi, test ve doğrulaması yapılmıştır.

Dördüncü bölümde yapılan çalışma ile ilgili ortaya çıkan sonuçlar açıklanmıştır. Sonuçlar grafikler şeklinde değerlendirilmiş olup, görsellerle de desteklenmiştir. En iyi ağ mimarisi Xception olup %99 oranında kesici takım görüntülerini başarılı bir şekilde tahmin ettiği görülmüştür. En kötü sonuçları ResNet ve GoogleNet ağ mimarileri ile elde edilmiştir.

Beşinci bölümde ise yapılan çalışma ile ilgili elde edilen sonuçlar açık bir şekilde izah edilmiştir. Ayrıca elde edilen sonuçlar doğrultusunda bazı önerilerde bulunulmuştur.

Bu çalışmada her zaman yanımda olan ve hiçbir yardımlarını esirgemeyen güler yüzlü ve samimi bir şekilde davranan, her yönüyle bana rehberlik eden saygı değer değerli danışman hocam sayın Doç. Dr. Şehmus BADAY beyefendi ile her zaman bilgi ve tecrübelerinden yararlandığım kıymetli hocam sayın Dr. Öğr. Üyesi Savaş KOÇ'a ayrı ayrı teşekkür eder şükranlarımı sunarım.

Ayrıca bu tez çalışması sırasında her türlü desteğini esirgemeyen başta saygı değer eşim sayın Elif TAŞ ile çok kıymetli çocuklarım Muhammed Baran, Berat Roni ve Arjin Beril'e çok çok teşekkür ederim.

Kenan TAŞ
Batman 2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
ÇİZELGELER DİZİNİ.....	xi
ŞEKİLLER DİZİNİ.....	xii
1. GİRİŞ	1
1.1. ISO Kodlama Sistemine Göre Kesici Takımlar	4
1.2. Derin Öğrenme	5
1.3. Derin Öğrenme Yöntemleri ile Uygulamaları.....	7
1.3.1. Derin öğrenmenin özellikleri.....	8
1.3.2. Derin öğrenmenin kullanım alanları:.....	8
1.4. Yapay Sinir Ağları	9
1.4.1. Yapay sinir ağlarının avantajları	11
1.4.2. Yapay sinir ağlarının kullanım alanları.....	11
1.4.3. Yapay sinir hücresi ve genel yapısı.....	11
1.5. Yapay Sinir Hücresinin Aktivasyon Fonksiyonları	13
1.5.1. Birim basamak fonksiyonu.....	13
1.5.2. Doğrusal fonksiyonu	14
1.5.3. Sigmoid fonksiyonu.....	15
1.5.4. Hiperbolik tanjant fonksiyonu	15
1.5.5. ReLU (Rectified Linear Unit) fonksiyonu	16
1.5.6. LeakyReLU fonksiyonu	17
1.5.7. Swish (A Self-Gated/Kendinden Geçitli) fonksiyonu	17
1.5.8. Softmax fonksiyonu.....	18
1.6. Derin Öğrenme Yönteminde Görüntü İşleme	19
1.6.1. Görüntü.....	20
1.6.2. Derin öğrenmede görüntü işlemenin amacı.....	21
1.6.3. Derin öğrenmede görüntü işleme yöntemleri	21
1.6.4. Derin öğrenmede kullanılan algoritmalar.....	22
1.7. Kesici Takımlar	22
1.7.1. Kesici takımların tarihsel gelişimi.....	24
1.7.2. Kesici takımların özellikleri	24

1.7.3. Kesici takım malzemeleri	25
1.7.4. Kesici takım seçim kriterleri	32
1.7.5. Kesici takım seçimini etkileyen faktörler.....	33
2. LİTERATÜR TARAMASI.....	36
2.1. Derin Öğrenme ile İlgili Yapılan Bazı Çalışmalar.....	36
2.2. Görüntü İşleme ile İlgili Yapılan Bazı Çalışmalar.....	39
3. MATERYAL VE YÖNTEM.....	43
3.1. Kesici Takım Verilerinin Oluşturulması.....	43
3.2. Elde Edilen Verilerin İşlenmesi	48
3.2.1. Python:.....	48
3.2.2. Anaconda.....	49
3.2.3. Conda.....	50
3.2.4. Tensorflow2.....	50
3.2.5. Keras.....	51
3.2.6. Spyder.....	51
3.3. Python Kütüphanesi	52
3.4. R-CNN Mimarisi ile Görüntü Alanını Belirleme.....	52
3.5. Xception Mimarisi	52
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	54
4.1. CNN Ağ Mimarisi Sonuçları	54
4.2. Xception Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti.....	56
4.3. ResNet Ağ Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti.....	59
4.4. LeNet Ağ Mimarisi Sonuçları.....	62
4.5. AlexNet Ağ Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti.....	64
4.6. GoogleNet Ağ Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti.....	67
5. SONUÇ VE ÖNERİLER.....	70
5.1. Sonuçlar.....	70
5.2. Öneriler	71
KAYNAKÇA.....	72
ÖZGEÇMİŞ	80

SİMGELER VE KISALTMALAR

Simgeler

Al_2O_3	: Alüminyum oksit
e	: Euler sayısı
$f(x)$	: Aktivasyon fonksiyonu
k	: Çok sınıflı sınıflandırma problemindeki sınıf sayısı
z	: Nörona girdi olarak kullanılan bir vektör
TiC	: Titanyum Karbür
TiN	: Titanyum nitrür
WC	: Tungsten karbür

Kısaltmalar

API	: Üst düzey sinir ağı
CNB	: Kübik bor nitrür
CNC	: Bilgisayarlı sayısal kontrol
CNN	: Evrişimli sinir ağı
CVD	: Kimyasal buhar biriktirme
DBN	: Derin inanç ağı
DLC	: Elmas benzeri karbon
DÖ	: Derin öğrenme
ESA	: Evrişimli sinir ağı
FDK	: Fonksiyonel derecelendirilmiş kaplama
FFBP	: İleri beslemeli geri yayılım
FLN	: Fonksiyonel bağlantı ağı

GRNN	: Genelleştirilmiş regresyon sinir ağı
GPU	: Grafik İşleme Birimi
HPC	: Yüksek performanslı bilgi işlemi
IMC	: Bellek içi bilgi işlemi
ISO	: Uluslararası Standartlar Teşkilatı
İHA	: İnsansız hava araçları
LVQ	: Öğrenen vektör parçalama
MCD	: Tek kristalli elmas
MÖ	: Makine öğrenimi
M5P	: Karar ağacı makinesi
PCBN	: Çok kristalli kübik bor nitrür
PCD	: Çok kristalli elmas
RBM	: Kısıtlı boltzmann makinesi
R-CNN	: Bölgesel Tabanlı Evrişimli Sinir Ağı
ReLU	: Rektifiye edilmiş lineer birim
RMSE	: Ortalama karekök hatası
RNN	: Tekrarlayan sinir ağı
SVM	: Destek vektör makinesi
TF2	: TensorFlow2
UAV	: İnsansız hava araçları
YHC	: Yüksek hız çelikleri
YSA	: Yapay sinir ağı
YZ	: Yapay zeka

ÇİZELGELER DİZİNİ

Çizelge 4. 1. CNN sınıflandırma raporu	56
Çizelge 4. 2. Xception sınıflandırma raporu.....	59
Çizelge 4. 3. ResNet sınıflandırma raporu	62
Çizelge 4. 4. LeNet sınıflandırma raporu	64
Çizelge 4. 5. AlexNet sınıflandırma raporu.....	67
Çizelge 4. 6. GoogleNet sınıflandırma raporu.....	69



ŞEKİLLER DİZİNİ

Şekil 1. 1. ISO kodlama sistemine göre kesici takımlar	4
Şekil 1. 2. Derin öğrenmenin yapay zekadaki yeri	6
Şekil 1. 3. Yapay sinir ağı.....	10
Şekil 1. 4. Sinir hücresinin yapısı	10
Şekil 1. 5. Bir yapay sinir ağının katmanları	12
Şekil 1. 6. Yapay sinir hücresinin yapısı	12
Şekil 1. 7. Birim basamak fonksiyonu grafiği	13
Şekil 1. 8. Doğrusal fonksiyonu grafiği.....	14
Şekil 1. 9. Sigmoid fonksiyonu grafiği.....	15
Şekil 1. 10. Hiperbolik tanjant fonksiyonu grafiği	16
Şekil 1. 11. ReLU fonksiyonu grafiği.....	16
Şekil 1. 12. LeakyReLU fonksiyonu grafiği.....	17
Şekil 1. 13. Swish fonksiyonu grafiği.....	18
Şekil 1. 14. Softmax fonksiyonu grafiği	19
Şekil 1. 15. Görüntülerin dönüştürülmesi	20
Şekil 1. 16. Kesici takımlar	23
Şekil 1. 17. Kesici takımlar	23
Şekil 1. 18. Kesici takımlar	23
Şekil 1. 19. Takım çelikleri	26
Şekil 1. 20. Sinterlenmiş tungsten karbür	27
Şekil 1. 21. Sinterlenmiş titanyum kaplama karbür çapak parmak freze	27
Şekil 3. 1. ISO standartlarına göre C sınıfı kesici takımlar	43
Şekil 3. 2. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı C sınıfı kesici takımların gösterimi	43
Şekil 3. 3. ISO standartlarına göre D sınıfı kesici takımlar	44
Şekil 3. 4. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı D sınıfı kesici takımların gösterimi	44
Şekil 3. 5. ISO standartlarına göre R sınıfı kesici takımlar	44
Şekil 3. 6. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı R sınıfı kesici takımların gösterimi	45
Şekil 3. 7. ISO standartlarına göre S sınıfı kesici takımlar.....	45
Şekil 3. 8. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı S sınıfı kesici takımların gösterimi	45
Şekil 3. 9. ISO standartlarına göre T sınıfı kesici takımlar	46
Şekil 3. 10. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı T sınıfı kesici takımların gösterimi	46
Şekil 3. 11. ISO standartlarına göre V sınıfı kesici takımlar.....	46
Şekil 3. 12. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı V sınıfı kesici takımların gösterimi	47
Şekil 3. 13. ISO standartlarına göre W sınıfı kesici takımlar	47
Şekil 3. 14. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı W sınıfı kesici takımların gösterimi.....	47
Şekil 4. 1. CNN ağı ile eğitilmiş doğruluk grafiği.....	54
Şekil 4. 2. CNN ağı ile eğitilmiş doğruluk grafiği.....	55
Şekil 4. 3. CNN karmaşıklık matrisi.....	55

Şekil 4. 4. Xception mimarisi ile eğitimi ve doğrulama	57
Şekil 4. 5. Xception hata değişimi gösterimi.....	57
Şekil 4. 6. Xception karmaşıklık matrisi	58
Şekil 4. 7. SNMG ve CNMG kesici takımların geometrisi	59
Şekil 4. 8. ResNet mimarisi ile eğitimi ve doğrulama.....	60
Şekil 4. 9. ResNet hata değişimi gösterimi.....	60
Şekil 4. 10. ResNet karmaşıklık matrisi	61
Şekil 4. 11. LeNet ağı ile eğitilmiş doğruluk grafiği	62
Şekil 4. 12. LeNet hata değişimi.....	63
Şekil 4. 13. LeNet karmaşıklık matrisi	63
Şekil 4. 14. AlexNet mimarisi ile eğitimi ve doğrulama	64
Şekil 4. 15. AlexNet hata değişimi gösterimi.....	65
Şekil 4. 16. AlexNet karmaşıklık matrisi	65
Şekil 4. 17. CNMG ve SNMG insertlerin karşılaştırılması.....	676
Şekil 4. 18. GoogleNet mimarisi ile eğitimi ve doğrulama	67
Şekil 4. 19. GoogleNet hata değişimi gösterimi.....	68
Şekil 4. 20. GoogleNet karmaşıklık matrisi	69

1. GİRİŞ

İmalat, bir hammaddenin veya yarı mamulün işlenerek sanayi ürünü veya mal üretme sürecinin genel adıdır. Bu süreç genellikle talaşlı ve talaşsız imalat yöntemleri olmak üzere iki ana kategoriye ayrılır. Talaşlı imalat, malzemeden talaş olarak isimlendirilen ince parçaların tabakalar halinde çıkartılarak istenen şekil ve boyutlara getirilmesini sağlar. Bu yöntemler temel olarak matkapla delme, frezeleme, taşlama ve tornalamadır. Bir diğer imalat yöntemi olan talaşsız imalat ise malzemeden talaş kaldırılmadan, malzemeye şekil verme işlemidir. Bu yöntemler arasında ekstrüzyon, döküm, dövme, sac metal işleme ile soğuk/sıcak çekme metotları yer alır. Bu imalat yöntemleri, farklı malzemelerin ve ürünlerin üretiminde tercih edilir. Her bir yöntemin farklı bir kullanım alanı olduğu gibi özel avantajları ve dezavantajları da vardır (Anonim-1, 2023).

Çağımız imalat endüstrisinde imal edilen malzeme kalitesi büyük oranda kesme parametreleri, kullanılan tezgahın ve kesici takımın özelliklerine bağlıdır. Bu nedenle, Bilgisayarlı Sayısal Kontrol (CNC) tabanlı tezgahlar, gelişmiş bir parça işleme yöntemi olarak imalat sektöründe önemli bir konuma sahiptir. CNC tezgahları diğer klasik tezgahlara göre hem daha hızlı hem de daha yüksek kalitede üretim yapabilmektedir. Ancak CNC tezgahlarında işleme parametrelerinin değişkenliği, kesici takımların aşınması, malzeme içyapısından kaynaklanan faktörler ve işleme sırasında yüzey ve form hatalarına neden olabilen durumlar gibi faktörlerin varlığı bilinmektedir. Dünya genelinde ve ülkemizde giderek artan tüketim eğilimi, seri üretimin daha fazla vurgulandığı imalat sektöründe ekonomik açıdan zaman ve malzeme kaybına yol açan faktörlerin ortaya çıktığını göstermektedir. Bu tür problemler, ürünler üretim hattından çıkmadan önce çözülmesi gereken önemli zorlukları beraberinde getirir. Bu zorluklara ek olarak ürün taleplerindeki tasarım çeşitliliği özellikle sağlık, biyomedikal ve robotik gibi alanlardaki yüksek hassasiyet gereksinimleri, bahsedilen faktörlerin imalat aşamasındaki etkilerini daha da karmaşık hale getirir. Bu faktörler genel itibarıyla kesici takımın maruz kaldığı kesme kuvvetlerini değiştirerek talaş kaldırma yeteneğini olumsuz etkileyebilir (Afazov ve ark., 2010).

İmalat sektöründe önemli bir yer kaplayan kesici takımların kesme şartlarına uygun olarak belirlenmesi büyük önem arz etmektedir. Bu nedenle görüntüleri çekilen kesici takımların incelenerek görüntünün hangi kesici takıma ait olabileceği yorumu yapılabileceği gibi kesici takım ile ilgili fikirlerde sunulabilir. Kesici takım ile ilgili

yapılan bu analizler ya da incelemeler sayesinde ciddi anlamda zamandan ve maliyetten tasarruf yapılabilmektedir. İmalatın geleneksel imalattan yavaş yavaş daha kaliteli ve tasarruflu olan dijital imalata yönelmesiyle birlikte gelişmiş bir parça işleme yöntemi olan CNC yöntemi gün geçtikçe daha da önem kazanmaktadır. Tahmin edilebileceği gibi kesici takımların çeşitliliği de buna paralel olarak gün gittikçe artmaktadır. Teknolojisinin ilerlemesiyle birlikte üretilecek malzemelerde istenilen özelliklere sahip olması çok önemli bir hal almıştır.

Görüntü işleme sistemlerinde sinir ağlarının 200'den fazla uygulaması bulunmaktadır. Son zamanlarda insan hayatını önemli bir ölçüde etkileyen bu uygulamalar arasında endüstriyel, biyomedikal, bilgisayarla görüntüleme, hava izleme ve tahmin uygulamaları gibi çeşitli uygulamalar bulunmaktadır. Yeni iki boyutlu sınıflandırma altında, görüntü işleme algoritmaları çeşitli uygulama kategorilerine ayrılmaktadır.

İlk boyut, algoritmanın gerçekleştirdiği görev türlerini belirtir. Bu boyut içinde, ön işleme, veri azaltma/özellik çıkarma, bölütleme, nesne tanıma, görüntü anlama ve optimizasyon gibi görevler bulunmaktadır. İkinci boyut ise algoritmanın işlediği girdi verilerinin soyutlama seviyelerini yakalar. Bu düzeyler arasında görüntü piksel, nesne, yapı, yerel özellik, nesnelerin bütünleme düzeyi ve sahne özellikleri gibi farklı düzey seviyeleri bulunur. Her biri, altı görev türü sinir ağlarına belirli kısıtlamalar getirir ve bu özel koşullar detaylı şekilde ele alınır.

Görüntü işleme yönteminde örüntü tanıma tekniklerinin uygulanması, özellikle sinir ağlarının kullanımı ile ilgili çözümlenmemiş sorunların bir derlemesi sunulur. Daha sonra yapay sinir ağlarının teknolojiye dayalı alanlarına kapsamlı bir bakış açısı sunulur ve bunlar teknolojiye bağlı yeni gelişmelerle nasıl ilişkilendirilebileceği tartışılır (Egmont-Petersen ve ark., 2022).

Gelecekteki büyük etkenlerden biri olarak yapay zeka faktörünün belirgin bir rol oynayacağı kesindir. Yapay zeka özellikle yeni nesil bilgi ve teknolojilerinin yaygınlaşmasıyla birlikte teknolojik ve endüstriyel alanındaki devrimi hızlandıracaktır. Tüm bu gelişmelere paralel bilgiye dayalı bir yapay zekanın incelemesi amaçlamaktadır. Bu inceleme, arka plan, itici güçler, kullanılan teknolojiler ve çeşitli uygulamaları içerecek şekilde yapay zekanın kapsamını genişletmeyi amaçlamaktadır (Zhang ve Lu, 2021).

Görüntü bölüntüleme, analizi ve örüntü algılama alanlarında son derece hızlı bir gelişim gösteren bir araştırma konusudur. Bu nedenle, bir dizi gelişmiş algoritma bu

amaçla geliştirilmiştir. Ancak, bu algoritmaların genellikle segmentasyon sonuçlarının yanıltıcı sınıflandırmalara veya aşırı segmentasyona yol açabileceği gözlemlenmektedir. Bu durumun temel sebepleri, görüntü kalitesinin çekim, transfer ve renk alanı dönüşümleri sırasında bozulmasıyla ilişkilidir. Bu nedenle, etkili bir görüntü iyileştirme tekniği gereklidir; bu, renkli görüntülerden fazla pikselleri veya gürültüyü kaldırabilme yeteneğine sahip olmalıdır, böylece segmentasyon adımına geçilmeden önce verileri düzeltebilmek mümkün olur (Bora, 2017).

Yapay sinir ağları (YSA), akıllı sistemler için, kesici takımların belirlenmesi veya tespit edilmesi konusunda çeşitli çözümler sunan yeni bir teknoloji olarak öne çıkmaktadır. Klasik makinelerin çözemediği arıza durumlarında birçok sorunun üstesinden gelebildiği için, yapay sinir ağları özellikle daha iyi ve kaliteli ürünlerin inovasyonu ve geliştirilmesi süreçlerinde toplum için önemli bir rol oynamaktadır.

Yapay sinir ağlarının temel mimarisi, farklı kesici takımların kullanıldığı girdi parametreleri ile hangi kesici takımın kullanıldığını başarıyla tahmin etme yeteneğine dayanmaktadır. Özellikle kesici takım tahmininde, yapay sinir ağları belirli bir kesici takım problemi üzerinde en etkili çözümlerden biri olarak görülmektedir.


Derin öğrenmenin ortaya çıkışı, endüstriyel teşhis ve prognostik tekniklerinde önemli değişikliklere neden olmuştur. Bu alandaki büyük ilerlemeler, Endüstri 4.0'ün devamını sağlayarak Endüstri 5.0'a yönelik bir yol açmaktadır. Özellikle makine durum izlemesinde, makineler ve endüstri alt sistemleri de dahil olmak üzere endüstride derin öğrenmeye dayalı teşhis yöntemleri büyük popülarite kazandığı görülmektedir. Farklı uygulamalardaki makineler çeşitli nedenlerle arızalanabilmektedir. Bundan dolayı durum izleme ve arıza yönetimi endüstride büyük bir öneme sahiptir. Derin öğrenme tabanlı makine durum izlemesi, giriş verileri ve özellik işleme teknikleri bağlamında modern bir değerlendirmeyi sunmaktadır. Özellikle işleme tekniklerini kullanarak, makine durumu izleme problemlerinin derin öğrenme modelleri ile etkin bir şekilde ele alınabilirliği test edilmekte ve çeşitli girdi özelliklerinin uygulanabilirliği incelenmektedir. Ayrıca, derin öğrenme modellerinin makineler için tanı yöntemlerine nasıl uygulandığını ve hibrit teşhis tekniklerinin nasıl kullanıldığını tartışarak, derin öğrenme alanındaki ilerlemeler değerlendirmektedir. Yapılan bu değerlendirme araştırmacılara özellikle işlemeyle ilgili araştırma eksikliklerini belirleme konusunda yardımcı olurken, makinelerin durumlarının izlemesinde derin öğrenme modellerinin etkili bir şekilde uygulanmasına katkıda bulunma potansiyelini açıklamaktadır (Soother ve ark., 2021).

Derin öğrenme, geleceğe umut veren sonuçları ve büyük potansiyeli ile görüntü ve veri analizi gibi alanlarda yeni ve modern bir alan olarak öne çıkmaktadır. Son dönemlerde, imalat dahil birçok farklı uygulama alanında başarılı bir şekilde kullanılmaya başlanmıştır. Bu teknik, özel modeller ve çerçeveler kullanarak, farklı veri kaynakları, veri türleri ve veri ön işleme yöntemleri ile elde edilen performansı değerlendirir. Ayrıca, sınıflandırma veya regresyon performansındaki farklılıkları ortaya koymak amacıyla derin öğrenmeyi diğer popüler tekniklerle karşılaştırmak da mümkündür. Elde edilen sonuçlara bakıldığında derin öğrenmenin doğruluk oranların yüksek çıktığından dolayı sıkça kullanılan geleneksel görüntü işleme tekniklerine göre daha üstün performans gösterdiğini görülmektedir (Kamilaris ve Prenafeta-Boldu, 2018).

1.1. ISO Kodlama Sistemine Göre Kesici Takımlar

ISO kodlama sistemine (ISO 1832:2017) göre kesici takımlar A, B, C, D, E, H, K, L, M, P, R, S, T, V, W ve Q olmak üzere 16 (on altı) sınıfa ayrılmıştır. Bu sınıflandırma kesici takımların şekline ve işlevine göre yapıldığı görülmektedir.

Kesici takımlar üçgen, kare, dikdörtgen, farklı açılara sahip dörtgen, çokgen ve yuvarlak şekillerine sahip olabilmektedirler. Üretilmek istenilen parçanın özelliklerine uygun bir kesici takım kullanmak oldukça önemli ve avantajlıdır. Bu nedenle imalatla kullanılacak kesici takımı tahmin etmek hem imal edilecek malzeme kalitesi açısından hem de zaman ve maliyet açısından son derece büyük bir öneme sahiptir. Şekil 1.1' de ISO kodlama sistemine göre kesici takımlar gösterilmektedir.



Şekil 1. 1. ISO kodlama sistemine göre sınıflandırılan kesici takımlar (Anonim-2, 2023)

1.2. Derin Öğrenme

Derin öğrenme, yapay sinir ağlarının (insan beyni gibi çalışacak şekilde modellenen algoritmalar) büyük oranda veriden öğrendiği makine öğreniminin bir alt basamağıdır. Derin öğrenme, insan beyninin çalışma şekline göre genel hatlarıyla modellenen algoritmalar olan sinir ağlarının katmanları tarafından desteklenir. Büyük miktarlarda veri ile eğitim, sinir ağındaki nöronları konfigüre etmektir. Derin öğrenme modelleri, birden fazla veri kaynağından bilgiyi alır ve bu verileri insan müdahalesine gerek kalmadan otomat bir şekilde gerçek zamanlı olarak analiz eder. Derin öğrenmede, grafik işleme birimleri (GPU'lar), aynı anda birden fazla hesaplamayı işleyebildikleri için eğitim modellerine yönelik olarak optimize edilmiştir (Anonim-3, 2023).

Yapay zeka, günümüzde başta teknoloji alanı olmak üzere birçok alanda ilerleme kaydederek sürekli geliştiği görülmektedir. Bu gelişmeler arasında bilgisayarla görme, konuşma, tanıma, makine çevirisi, sürücüsüz arabalar yapay zekanın uygulama alanlarından bazılarıdır (Anonim-3, 2023).


Makine öğrenimi (MÖ), verilere ve algoritmalara odaklanarak insan öğrenme süreçlerini taklit etmeyi amaçlayan ve makinelerin verilere dayalı kararlarını artan doğrulukla gerçekleştirmelerini sağlayan bir yapay zeka dalıdır. MÖ, geçmiş verileri kullanarak geleceği tahmin etmeyi amaçlayan farklı algoritmaları içerir. Makine öğrenimi, fiziksel veya teorik modellere dayalı karar verme yöntemlerine kıyasla veriye dayalı bir yaklaşım benimser.

Makine öğrenimi üç ana türde gerçekleşir: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Denetimsiz öğrenme, verileri önceden tanımlanmış etiketler veya kategorilerle eşleştirmeksizin incelemeyi içerir. Denetimli öğrenme ise verileri benzer özelliklere sahip kategorilere gruplandırma sürecini ifade eder. Her bir veri öğrenme sürecinde bir etiketle ilişkilendirilir ve öğrenme, çıktı etiketi ile gerçek etiket arasındaki farkı en aza indirmek için bir işlevi genelleştirme süreciyle birleştirir. Pekiştirmeli öğrenme ise nesnel bir durumun olduğu bir durum makinesi ve bu durumu elde etmek için çeşitli eylemler arasında seçim yapma yeteneğiyle tanımlanır. Bütün verilerin bir etiketi olmayabilir, ancak amaca ulaşabilmek için durum makinesinin, belirli eylemler seçilerek eğitim hedefine yönlendirilir (Ngo, 2021).

Derin öğrenme, geniş bir sinir ağı mimarileri yelpazesini içeren ve farklı görevleri gerçekleştirmek üzere tasarlanmış makine öğrenimi alanını ifade eder. Tıbbi görüntüleme dahil olmak üzere makine mühendisliği ve birçok diğer alanlarda özellikle görüntü

sınıflandırması amaçlı olarak tercih edilen bir öğrenme yaklaşımıdır. Bu alanda evrimsel sinir ağları mimarisi en gözde ağ mimarisi olarak bilinir. Geleneksel makine öğrenimi yöntemleri, algoritmanın öğrenmeye dayalı özelliklerin belirlenmesi ve hesaplanması gerektiren yaklaşımlar içerirken, derin öğrenme ise yeni veri setleri için tahminler oluşturarak ve bu tahminlere en uygun verileri seçmeye dayanır (Erickson ve ark., 2017).

DÖ, bir veri seti tabanı ile çalışarak, çalışma sonuçlarını tahmin etmeye çalışan ve birçok algoritmadan oluşan bir makine öğrenme yöntemini ifade eder. Derin öğrenme, makine öğrenmesinin bir alt dalı kabul edilirken, makine öğrenmesi de yapay zekanın bir alt dalını oluşturur. Şekil 1.2' de yapay zekanın içindeki derin öğrenmenin konumu gösterilmektedir.



Şekil 1. 2. Derin öğrenmenin yapay zeka içindeki yerinin şekilsel gösterimi (Anonim-4, 2023)

Yapay zeka, insan zekasının işleyiş yapısına benzer şekilde işleyen ve bir çok farklı görevleri yerine getiren, sürekli olarak kendini geliştiren sistemler veya makineleri ifade eder. 1950 yıllarından itibaren başlayan yapay zeka çalışmaları, hatalardan öğrenme yeteneğine sahip sistemler sayesinde sürekli olarak geliştirilmektedir. Makine öğrenmesi çalışmaları ise 1980'li yıllarda ortaya çıkmış olup, verilen bir veri kümesini işleyerek tahminlerde bulunmayı veya sınıflandırmayı amaçlayan bir yapay zeka modelinin bir alt kümesidir. Makine öğrenme algoritmaları, gözetimli ve gözetimsiz öğrenme algoritmaları olmak üzere genellikle iki tür öğrenme biçimi olarak kullanılmaktadır.

a) Gözetimli öğrenme algoritması: Etiketlenmiş verilerden öğrenme yöntemidir. Bu yöntemde hem girdi verisi hem de beklenen çıktı verisi belirtilir. Elde edilen tahminlerin doğruluğu, geri bildirim sağlayan kişi tarafından değerlendirilir.

b) Gözetimsiz öğrenme algoritması: Etiketsiz verilerden öğrenme yöntemidir. Bu yöntemde sonuç verisiyle eğitim gereksinimi yoktur. Algoritma veriden sonuca kendi başına ulaşır. Algoritmanın kendi başına keşfetmesi beklenir.

Teknolojinin zaman içindeki gelişimi, bilgisayarların performansını artırdı. Bu gelişme, yapay zekâ işlemlerinde daha önce yetersiz kalan bilgisayarların daha güçlü hale gelmesini sağladı. Veri erişimi kolaylaştı, bu da algoritmaların gereksinim duyduğu veri setlerinin artmasına olanak sağladı. Mevcut algoritmalar geliştirildi veya yeni algoritmalar oluşturuldu, bu da yapay zekâ uygulamalarında gözle görülür bir ilerlemeye yol açtı.

Bu algoritmalar büyük miktarda veri girişi ile kendiliğinden ayırt edici özellikleri öğrenir. Öğrenme sürecinin etkinliği, kullanılan veri miktarıyla doğru orantılıdır. Veriler, birçok katmandan geçer. Üst katmanlar, daha yüksek seviyede ayrıntıları çıkaran katmanlar olarak işlev görür (Anonim-4, 2023).

1.3. Derin Öğrenme Yöntemleri ile Uygulamaları

Günümüzde, derin öğrenme kullanıcıları 7/24 sürekli olarak büyük miktarda veri üretmektedirler. Üretilen bu veriler, yüksek performanslı bilgi işleme sistemi olarak adlandırılan (HPC) sistemleri kullanılarak işlenmektedir. Aynı zamanda, bellek içi bilgi işlem (IMC) paralel işlem mimarisi, öğrenme performansını etkilemeden güncellemelere izin vererek kullanılır. Son birkaç yılda elde edilen yeni yapay zeka yetenekleri, şirketlerin daha kapsamlı ve güçlü eğitim modellerini kullanmalarına olanak sağlar. Farklı sektörlerde elde edilen etkileyici sonuçlar, yapay zeka modellerinin kullanımının artmasını kaçınılmaz hale getirmektedir.

Derin öğrenme, ham verileri kullanarak sinir ağı algoritmalarının katmanlarını kullanarak üst düzey bilgileri çıkarmak için tasarlanmış bir yöntemdir. Örneğin, bir görüntü tanıma uygulamasında bir katman keskin kenarları belirlemek gibi temel özellikleri çıkarabilirken, diğer bir katman farklı şekilleri tanıyabilir. Ayrıca, üçüncü bir katman, görüntünün içeriğini anlamak için kullanılabilir. Bu katmanlar önceki katmanlardan gelen bilgileri kullanarak ayırt edilebilir nesneleri oluşturmak için farklı

yolları öğrenir. Sinir ağı algoritmaları, insan beyninden ilham alınarak tasarlanmıştır ve veri modellerini tanımak amacıyla kullanılırlar. Bu ağlar, veri örneklerindeki benzerliklere dayalı olarak noktaları kümelendirebilir, verileri etiketlere göre sınıflandırabilir ve farklı özellikleri çıkarabilir. Bu algoritmaların öğrendiği sayısal modeller, gerçek dünya girdilerini ifade eden vektörlerde saklanır.

Derin öğrenme, gizli katmanları, büyük veri kümelerini ve güçlü hesaplama kaynaklarını kullanarak özgün bir şekilde kendini eğitme yeteneğine sahiptir. Bu algoritma yapılarına sahip olan ağlar sinir ağı olarak adlandırılırken, içerisine gizli katmanlar dahil edildiğinde derin öğrenme terimi kullanılır. Bugün, kesici takımların belirlenmesi gibi uygulamalarda, özellikle nesne tanıma ve görüntü sınıflandırmasında, derin öğrenme tekniklerinin kullanımı önemli bir rol oynamıştır (Anonim-5, 2023).

1.3.1. Derin öğrenmenin özellikleri

Derin öğrenme makine öğrenmesinin bir alt dalı, makine öğrenmesi ise yapay zekanın bir dalı konumdadır. Derin öğrenmenin özelliklerini tam anlayabilmek için makine öğrenimini de bilmek gerekir. Bu nedenle makine öğrenimi sadece yapılandırılmış veya yarı yapılandırılmış veri setleriyle çalışırken derin öğrenme hem yapılandırılmış hem de yapılandırılmamış veri setleriyle çalışır. Derin öğrenme algoritmaları karmaşık görevleri etkili bir biçimde gerçekleştirebilirken, makine öğrenme algoritmaları bu kadar yetenekli değildir. Makine öğrenimi, kalıpları çıkarmak için etiketlenmiş verileri kullanırken, derin öğrenme ise büyük miktarda veriyi alır ve alınan bu verileri analiz ederek nesnelerin özelliklerini belirlemek için kullanır. Veri miktarı arttıkça, makine öğrenimi algoritmalarının performansı genellikle düşerken, modelin performansını korumak için derin öğrenme yaklaşımına olan ihtiyaç artar (Anonymous-1, 2023).

1.3.2. Derin öğrenmenin kullanım alanları:

Günümüz teknolojisiyle birlikte derin öğrenme hemen hemen her alanda kullanılmaya başlanılmış olup, her geçen günde kullanım alanı arttığı görülmektedir. Derin öğrenmenin kullanım alanları aşağıdaki gibi kısaca özetlenebilir.


a) Ses tanıma sistemlerinde,

- b)** Yüz tanıma sistemlerinde,
- c)** Görüntü iyileştirilmesinde,
- d)** Alarm sistemlerinde, kamera kayıtlarını sürekli olarak kontrol etmek yerine, sadece olağandışı hareketler olduğunda alarm sisteminin devreye girmesi gibi teknolojiler, derin öğrenme sayesinde mümkün hale gelmiştir.
- e)** Sağlık sektöründe kanser araştırmalarında, derin öğrenme zaman kaybını ortadan kaldırmaktadır. Kanserli hücre örneklerini tanımlamak için kullanılan derin öğrenme algoritmaları, yeni hücrelerin kanserli olup olmadığına dair tanıyı hem daha hızlı hem de daha başarılı bir şekilde koymaktadır.
- f)** Araçlarda otopilot özelliğinde veya sürücüsüz araçlarda kullanılmaktadır.
- g)** Tavsiye sistemlerinde, beğenilebilecek müzik ve film önerileri sunmada,
- h)** Siber tehdit analizlerinde de derin öğrenme yöntemleri geliştirilebilir.

Yukarıda sayılan örnekler dışında da derin öğrenmeye birçok farklı örnek verilebilir. Türkiye'de gerçekleştirilen derin öğrenme çalışmalarına örnek olarak, ASELSAN'ın Ar-Ge merkezinde silah ve güvenlik sistemleri için görüntü ve doğal dil işleme alanlarında yürüttüğü faaliyetler gösterilebilir. Bunun dışında, "OttOCR" projesi ile Osmanlıca karakter tanıma sistemi geliştirilmiş ve "Openzeka" projesi ile görüntü ve video tanımlama için derin öğrenme API'leri sunmaktadır (Anonim-3, 2023).


1.4. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin bilgi işleme yöntemlerinden ilham alınarak modellenen bir tür bilgi işleme teknolojisidir. Yapay sinir ağları, temelde biyolojik sinir hücrelerinin işleyişini taklit eden bir yapıya sahiptir. Bu yaklaşım, biyolojik nöron hücrelerinin ve bu hücreler arasındaki sinaptik bağlantıların dijital olarak modellenmesini içerir (Aydın ve Şamil, 2017). Şekil 1.3' te yapay bir sinir ağı yapısının (bir katmanın) nasıl görüldüğü gösterilmiştir.



Şekil 1. 3. Yapay sinir ağı (Anonim-6, 2023)

İnsan vücudundaki sinirler, nöron adı verilen özel hücrelerden oluşur. Bu hücreler, sinir sistemi ağını oluşturmak üzere birbirleriyle bağlantı kurarlar. İnsan sinir sisteminde ortalama 1011 nöron bulunur ve bulunan bu nöronların yaklaşık 10000 bağlantı ile birbirine bağlı olduğu bir karmaşık ağıdır. Yapay Sinir Ağları, doğal sinir ağının yapısıyla benzer bir şekilde bağlanmış yapay nöronlardan oluşan bir modeldir (Kukreja ve ark., 2016). Şekil 1.4' te sinir hücresinin yapısı gösterilmektedir.



Şekil 1. 4. Sinir hücresinin yapısı (Anonim-7, 2023)

Nöron olarak adlandırılan işlem birimlerinden oluşan ağa yapay sinir ağı adı verilir. Yapay nöronlar, doğal nöronların yapısını ve işleyişini taklit etmeye çalışır. Bir nöron, girdileri alarak çıktıyı üretir. Nöronların aktivasyonu belirleyen bir işlevi de bulunmaktadır (Kukreja ve ark., 2016).

1.4.1. Yapay sinir ağlarının avantajları

Birden fazla hücreden meydana gelen ve bu hücreleri eş zamanlı bir şekilde çalışarak karmaşık işleri gerçekleştiren ağlara yapay sinir ağları denir. YSA'ları birçok alanda kullanılmaktadır. Bu alanlar arasında teşhis, sınıflandırma, veri tahmini, kontrol, veri ilişkilendirme, veri filtreleme ve verileri yorumlama gibi alanlardır. Bir yapay sinir ağının hangi problemin hangi ağ tipi ile daha iyi çözülebileceğini belirlemek için ağların özellikleri ile problemlerin özelliklerini birbirleriyle karşılaştırılması yapılmalıdır. (Anonim-8, 2023).


1.4.2. Yapay sinir ağlarının kullanım alanları

- a) Hesaplamalı Finans (Computational finance):** Kredi skorlaması (credit scoring), Algoritmik Ticaret (algorithmic trading)
- b) Görüntü işleme ve bilgisayarla görüntü alma (image processing and computer vision):** Yüz tanıma (face recognition), hareket tanıma (motion detection), nesne tanıma (object detection)
- c) Hesaplamalı biyoloji (Computational biology):** Tümör bulma (tumor detection), İlaç keşfi (drug discovery), DNA dizilimi (DNA sequencing)
- e) Enerji üretimi (Energy production):** Fiyat ve yük tahmini (price and load forecasting)
- f) Otomotiv, havacılık ve üretim (Automotive, aerospace and manufacturing):** Öngörücü bakım (predictive maintenance)
- g) Doğal dil işleme (Natural language processing):** Sesli Asistan (voice assistant), Duygu analizi (emotion analysis) (Anonim-8, 2023).

1.4.3. Yapay sinir hücresi ve genel yapısı


Yapay sinir hücresinin temel amacı, girdi ve çıktı verileri arasında bir köprü oluşturarak gerekli hesaplamaları yapmaktır. Yapay sinir ağlarının çalışma prensibi genellikle iki aşamalıdır. İlk aşama eğitim aşamasıdır ve bu aşamada belirli girdi ve çıktı veri setleri yardımıyla yapılır. YSA, girdi ve çıktı veri setlerinin genellemesini yaparak öğrenir. Yapay sinir ağı giriş katmanı, gizli katmanlar ve çıkış katmanı şeklinde üç farklı

katmandan oluşur ve her katmanda birden fazla yapay sinir hücresi yer alır (Tumer ve Edebalı, 2015). Şekil 1.5' te bir yapay sinir ağının katmanları gösterilmektedir.



Şekil 1. 5. Bir yapay sinir ağının katmanları (Anonim-6, 2023)

Bir nöron genel itibariyle aynı anda birden çok girdi verisi alır. Alına her girdi verisinin, toplama işleminin etkisini belirleyen göreceli ağırlığı vardır. Ağırlıklar, yapay nöronun iç yapısında bulunan ve giriş sinyallerinin yoğunluğunu belirleyen katsayılardır. Bağlantı bir giriş gücünün ölçüsü olarak düşünülebilirler. Bu bağlantı güçleri, farklı eğitim setlerine tepkisel veya ağırlık belirli bir topolojisine veya öğrenme kurallarına göre değiştirilebilir. Tüm girdilerin ağırlıklı toplamını hesaplamak görevi işleme elemanının ilk adımıdır. Toplama işlemi sonucunda elde edilen toplam veriler aktivasyon fonksiyonuna geçirilir ve çıktı değeri üretilir. Yapay sinir hücresinin katman yapısının görseli Şekil 1.6' da gösterildiği gibidir.




Şekil 1. 6. Yapay sinir hücresinin yapısı (Tumer ve Edebalı, 2015)

1.5. Yapay Sinir Hücresinin Aktivasyon Fonksiyonları

Derin öğrenme ile ilgili yapılan çalışmalarda en fazla kullanılan yapay sinir hücresinin aktivasyon fonksiyonları; Birim basamak, Doğrusal, Sigmoid, Hiperbolik tanjan, ReLU, LeakyReLU, Swish ve Softmax fonksiyonlarıdır. Bu fonksiyonların açıklaması kısaca aşağıya çıkarılmıştır (Sharma ve ark., 2017).

1.5.1. Birim basamak fonksiyonu

Derin öğrenmede kullanılan yapay sinir hücresinin aktivasyon fonksiyonlarında en çok dikkat edilmesi gereken özelliklerden biri de eşik tabanlı sınıflandırıcının kullanılmasıdır. Başka bir deyişle ifade edecek olursak, doğrusal dönüşüm sonucunda, nöronun etkinleştirilip etkinleştirilmemesi gerektiğini belirlemek veya aktivasyon fonksiyonuna girdinin belli bir değeri aştığında nöronun aktif hale gelmesini sağlamak gibi bir işlevi de vardır. Eğer bir eşik değeri belirlenmemişse nöron pasif durumda kalır ve çıktısı bir sonraki katmana iletilmez (Sharma ve ark., 2017). Şekil 1.7’ de birim fonksiyonunun grafiğini gösterilmektedir.



Şekil 1. 7. Birim basamak fonksiyonun grafiksel gösterimi (Kızrak, 2019)

Python programında birim basamak fonksiyonu için basit if-else ifadeleri kullanılarak uygulanabilen en temel aktivasyon işlevlerinden biridir. Genellikle ikili sınıflandırma problemleri için kullanılan birim basamak fonksiyonu, çok sınıflı sınıflandırma senaryolarında yaygın olarak tercih edilmez. Bunun temel nedeni, çok sınıflı durumlarda daha karmaşık ve esnek aktivasyon işlevlerine ihtiyaç duyulmasıdır.

Ayrıca, birim fonksiyonunun türevi her zaman sıfıra eşittir. Bu özellik, geri yayılım algoritmasının eğitim sırasında karşılaşılabileceği zorluklara neden olabilir. Eğer bir fonksiyonun türevi her zaman sıfırsa, gradyan tabanlı optimizasyon yöntemleri bu fonksiyonu optimize etmekte güçlük yaşayabilir. Matematiksel olarak ifade edecek olursak, birim fonksiyonun denklemi Denklem (1.1) ve Denklem (1.2)' de gösterildiği şekilde yazılabilir.


$$f(x) = 0, x < 0 \quad (1.1)$$

$$f(x) = 1, x \geq 0 \quad (1.2)$$

1.5.2. Doğrusal fonksiyonu

Doğrusal bir fonksiyon, Giriş değişkeni ile doğru orantılı bir ilişki sergileyen fonksiyona doğrusal fonksiyon adı verilir. Öte yandan, birim basamak fonksiyonunun dezavantajı ise türevinin her yerde sıfır olmasıdır. Bu, geri yayılım adımında engellere yol açabilir, zira birim basamak fonksiyonunda x'in herhangi bir bileşeni bulunmaz. Bu dezavantajı aşmak için doğrusal bir fonksiyon kullanmak mümkündür. Doğrusal bir fonksiyon, türevi sıfır olmayan bir gradyan taşır ve bu, gradyan tabanlı optimizasyon yöntemlerinin daha iyi çalışmasını sağlayabilir (Sharma ve ark., 2017). Doğrusal fonksiyonun grafiği Şekil 1.8' de gösterilmektedir. Doğrusal fonksiyonun matematiksel ifadesi Denklem (1.3)' teki gibi ifade edilebilir.

$$f(x) = ax \quad (1.3)$$




Şekil 1. 8. Doğrusal fonksiyonun grafiksel gösterimi (Kızrak, 2019)

1.5.3. Sigmoid fonksiyonu

Parabolik işlevleri modellemek için en yaygın kullanılan aktivasyon fonksiyonlarından biri sigmoid fonksiyonudur. Sigmoid fonksiyonu, giriş değerlerini 0 ile 1 arasındaki bir aralığa dönüştürerek çalışır (Sharma ve ark., 2017). Sigmoid fonksiyonunun grafiği Şekil 1.9' da gösterilmektedir. Sigmoid fonksiyonunun matematiksel ifadesi Denklem (1.4)' teki gibi ifade edilir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (1.4)$$



Şekil 1. 9. Sigmoid fonksiyonu grafiksel gösterimi (Kızrak, 2019)

1.5.4. Hiperbolik tanjant fonksiyonu


Sigmoid fonksiyonu gibi doğrusal olmayan işlevleri modellemek için kullanılan ve orijine göre simetrik olan fonksiyona hiperbolik tanjant fonksiyonu adı verilir. Hiperbolik tanjant fonksiyonu, sigmoid fonksiyonundan farklı olarak girdiyi alıp çıktığı -1 ile 1 arasında bir aralığa dönüştürür. Bu, bir sonraki katmana iletilen çıktılarının önceki katmanlardan farklı işaretlere sahip olmasını sağlar (Sharma ve ark., 2017). Hiperbolik tanjant fonksiyonun grafiği Şekil 1.10' da gösterilmektedir. Hiperbolik tanjant fonksiyonunun matematiksel ifadesi Denklem (1.6)' daki gibi ifade edilebilir.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1.6)$$

Hiperbolik tanjant fonksiyonu ile Sigmoid fonksiyonu birbirine benzedikleri için hiperbolik tanjant fonksiyonunun matematiksel ifadesi Denklem (1.7)' de gösterildiği gibi yazılabilir.

$$f(x) = 2\text{sigmoid}(2x)-1$$

(1.7)




Şekil 1. 10. Hiperbolik tanjant fonksiyonunun grafiksel gösterimi (Kızrak, 2019)

1.5.5. ReLU (Rectified Linear Unit) fonksiyonu

YSA’da sıkça kullanılan ve doğrusal olmayan aktivasyon fonksiyonuna ReLU fonksiyonu denir ve "Rectified Linear Unit" ifadesinin kısaltmasıdır. ReLU fonksiyonu "rektifiye edilmiş lineer birim" anlamına gelen bir fonksiyondur. ReLU fonksiyonunun en önemli avantajlarından biri tüm nöronların aynı anda etkinleştirilmemesini sağlamasıdır. Bu fonksiyonun kullanımıyla yalnızca girdiye uygulanan bir nöronun doğrusal dönüşümünün çıktısı sıfırsa, nöron devre dışı bırakılarak işlem yapılır. Bu durum ağı daha seçici ve öğrenmesi daha hızlı hale gelmesine katkıda bulunabilir (Sharma ve ark., 2017). ReLU fonksiyonunun grafiği Şekil 1.11’ de gösterilmektedir. ReLU Fonksiyonunun matematiksel ifadesi Denklem (1.8)’ de gösterildiği şekilde yazılabilir.

$$f(x) = \max (0,x)$$

(1.8)



Şekil 1. 11. ReLU fonksiyonu grafiksel gösterimi (Kızrak, 2019)

1.5.6. LeakyReLU fonksiyonu

LeakyReLU fonksiyonu, ReLU fonksiyonunun modifiye edilmiş bir versiyonudur. ReLU fonksiyonunun x 'in negatif değerleri için sıfır değerini almasının yerine, LeakyReLU fonksiyonu x 'in son derece küçük bir doğrusal bileşenini alarak tanımlanır. Bu, LeakyReLU'nun negatif bölgelerde de bazı bilgi taşımamasını sağlar (Sharma ve ark., 2017). LeakyReLU fonksiyonunun grafiği Şekil 1.12' de gösterilmektedir. LeakyReLU fonksiyonunun denklemi Denklem (1.9) ve Denklem (1.10)' da gösterildiği gibi yazılabilir.


$$f(x) = x, x \geq 0 \quad (1.9)$$

$$f(x) = 0.01x, x < 0 \quad (1.10)$$

Diğer yandan LeakyReLU fonksiyonunun denklemi Denklem (1.11) ve Denklem (1.12)' de gösterildiği gibide yazılabilir.

$$f(x) = x, x \geq 0 \quad (1.11)$$

$$f(x) = ax, x < 0 \quad (1.12)$$




Şekil 1. 12. LeakyReLU fonksiyonu grafiksel gösterimi (Kızrak, 2019)

1.5.7. Swish (A Self-Gated/Kendinden Geçitli) fonksiyonu

Sigmoid fonksiyonu ile giriş fonksiyonunun bir kombinasyonu ile elde edilen hibrit bir aktivasyon fonksiyonuna Swish fonksiyonu adı verilir. (Nwankpa ve ark.,

2018). Swish fonksiyonunun geliştirilmesi ile birlikte son yıllarda daha kapsamlı ve pekiştirmeli öğrenme yöntemlerinde iş birliği ile kullanılan araştırma tekniklerinde etkili bir aktivasyon fonksiyonu olduğunu göstermiştir. Görüntü sınıflandırma gibi uygulamalarda, CNN mimarisinde Swish fonksiyonunun ReLU'ya tercih edilerek kullanılması sonuçları iyileştirebilir (Jinsakul ve ark., 2019). Swish fonksiyonunun grafiği Şekil 1.13' te gösterilmektedir. Fonksiyon denkleminin matematiksel ifadesi Denklem (1.13)' teki gibi yazılabilir.

$$f(x) = x \cdot \text{sigmoid}(x) = x \cdot \frac{1}{1 + e^{-x}} \quad (1.13)$$




Şekil 1. 13. Swish fonksiyonu grafiksel gösterimi (Kızrak, 2019)

1.5.8. Softmax fonksiyonu

Çoklu sigmoid fonksiyonlarının birleşimine Softmax fonksiyonu denir. Sigmoid fonksiyonları 0 ile 1 arasında değerler ürettiğinden dolayı belirli bir grubun veri noktalarının olasılıkları şeklinde yorumlanabilirler. Bu fonksiyon çok katmanlı sınıflandırma problemleri çözümünde sigmoid fonksiyonlarından daha uygundur (Sharma ve ark., 2017). Fonksiyonunun matematiksel ifadesi Denklem (1.14)' teki gibi verilebilir.

$$\sigma_j(z) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad j=1 \text{ için}, \dots, K \quad (1.14)$$

Denklemdaki "z" ifadesi girdi olarak kullanılan bir vektörü temsil eder, "k" ise çok katmanlı sınıflandırmadaki sınıf sayısını ifade eder. Bu fonksiyonun grafiği Şekil 1.14' te gösterilmektedir.



Şekil 1. 14. Softmax fonksiyonunun grafiksel gösterimi (Çağlar, 2022)

1.6. Derin Öğrenme Yönteminde Görüntü İşleme

Görüntü işleme, girdinin bir görüntü olduğu herhangi bir sinyal işleme biçimidir. Sayısal görüntü işleme, sayısal formatta bulunan görüntülerin bilgisayarlar tarafından işlenmesini ifade eder. Görüntü iyileştirme, görüntülerin kalitesini artırmak amacıyla gerçekleştirilen işlemleri kapsar. Ayrıca otonom sistemlerde, makine endüstrisinde kalite kontrol ve montaj otomasyonlarında görüntü işleme yöntemleri kullanılarak farklı uygulamalar geliştirilir. Bunlarla birlikte, görüntü işleme teknikleri, bilgisayarlarda depolama alanını daha etkili bir şekilde kullanma ve görüntüleri aktarma ihtiyacını karşılamak için de kullanılır (Kour ve ark., 2020).

Görüntü işlemenin ilk adımı, sayısal görüntü verisini elde etmektir. Bu işlem, resim alıcılarının içinde bulunan sistemler aracılığıyla optik görüntüleri sayısal formata çevirme işlemidir. Görüntü işlemenin bir sonraki aşaması ise elde edilen sayısal görüntünün ön işleme adımından geçirilmesidir. Bu sayede görüntüdeki kusurlar ve istenmeyen özellikler giderilerek daha kaliteli bir görüntü elde edilir. Bu aşamada çeşitli görüntü işleme teknikleri kullanılır. Örneğin, kontrast ayarlaması, görüntüdeki görüntünün azaltılması ve farklı bölgelerin daha net bir şekilde ayrıştırılması gibi teknikler bu aşamada uygulanabilir (Atılğan, 2019).

Görüntü işleme, bir görüntüyü dijital formata dönüştürmek ve ardından bu dijital formdaki görüntü üzerinde çeşitli işlemler gerçekleştirmek amacıyla geliştirilmiş bir yöntemdir. Bu yöntem, belirli bir amaca hizmet eden veya görüntüden faydalı bilgiler çıkarmaya yönelik kullanılır. Görüntü işlemenin girdisi genellikle bir video karesi veya fotoğraf gibi görsel verilerdir. Yöntemin çıktısı ise genellikle görüntünün istenen veya vurgulanması gereken bölümüne karşılık gelir. Görüntü işleme sistemi, genellikle


önceden belirlenmiş sinyal işleme (Signal Processing) tekniklerini uygulayarak görüntüleri iki boyutlu sinyaller şeklinde ele alır. Bu sinyaller üzerinde farklı filtreleme, iyileştirme, sınıflandırma veya nesne tanıma gibi işlemler gerçekleştirilir. Bu yöntem, bir dizi matematiksel ve istatistiksel teknikleri içerebilir ve genellikle bilgisayarlar aracılığıyla uygulanır.

Sonuç olarak görüntü işleme, görsel verileri anlamlı bilgilere dönüştürmek ve bu bilgileri kullanarak istenilen sonuçları elde etmek amacıyla kullanılan bir yöntemdir.

Günümüzde işletmelerin farklı alanlarda hızla yaygınlaşan teknolojilerinden biri, görüntü işleme sistemleridir. Bu sistemler, işletmelerin farklı alanlarda çeşitli hedeflere yönelik olarak kullandığı bir teknoloji türüdür. Aynı zamanda, görüntü işleme yöntemi mühendislik ve bilgisayar bilimleri alanlarında temel bir araştırma alanı olarak da kabul edilir (Anonim-9, 2023).

1.6.1. Görüntü

Görüntü; resim, fotoğraf veya videoyu oluşturan her bir karedeki görsel, bilgisayar ortamında manuel veya otomatik olarak oluşturulmuş, gerçek veya sanal grafikler gibi görsellere verilen genel bir kavramdır (Turan, 2017). Görüntüler, analog görüntü ve sayısal görüntü olarak iki ana kategoriye ayrılmaktadır. Analog görüntü, sayısal olarak temsil edilmeyen görüntü türünü ifade eder. Sayısal görüntü ise analog sinyalin sayısal verilere dönüştürülmesiyle elde edilir (Esmeray, 2014). Şekil 1.15' te görüntülerin dönüşüm süreci de gösterilmiştir.



Şekil 1. 15. Görüntülerin dönüştürülmesi (Yaman ve ark., 2001)

1.6.2. Derin öğrenmede görüntü işlemenin amacı

Görüntü işlemenin birçok amacı vardır. Ama genel olarak bu amaçlar 5 (beş) ana kategoriye ayrılmıştır. Bunlar;

- a) GÖrselleştirme: Görünmesi zor nesneleri gözlemlemek amacıyla görselleştirme işlemi yapılarak görünmesi zor nesnelerin görünmesi sağlanır.
- b) Görüntü keskinleştirme ve restorasyon: Gürültülü görüntüleri iyileştirerek daha net bir şekilde görünmesini sağlar.
- c) Görüntü alımı: İlgi çekici ve yüksek çözünürlüklü görüntülerin görüntüsünü alır.
- d) Desen Tanıma: Bir görüntüdeki çeşitli nesneleri tanımlamak amacıyla desen tanımayı görüntü işleme yöntemiyle desen tanımayı sağlar.
- e) Görüntü Tanıma: Bir görüntüdeki nesneleri ayırt etmek için kullanılır.

Görüntü işleme ile ilgili yapılan araştırmada ülkemizde ve dünya genelinde en yaygın olarak kullanılan görüntü işleme alanlarından biride yüz tanıma olduğu görülmektedir. Bu yüz tanıma teknik olarak derin öğrenme yöntemleri kullanılarak gerçekleştirilir. Bu süreçte öncelikle insan yüzlerinin özgün özellikleri makineye öğretilir. İki göz arasındaki mesafe, tipik yüz şekli gibi belirleyici özellikler, yüzün tanımlayıcı öğelerini oluşturur. İnsana özgü bu özellikler öğrenildikten sonra, görüntüler içinde benzer şekillere sahip nesneleri yüz olarak tanır. Yüz tanıma işlemi, yüzü oluşturan özgün metriklerin tanımlanması ve insana özgü hale getirilmesiyle gerçekleşir (Anonim-9, 2023).

1.6.3. Derin öğrenmede görüntü işleme yöntemleri

Görüntü işleme, iki temel yöntem olan Analog ve Dijital görüntü işleme yöntemlerini içerir. Analog görüntü işleme, basılı kopyalar gibi fiziksel formlarda bulunan görüntüler için kullanılırken, dijital görüntü işleme dijital formattaki görüntülerin işlenmesinde kullanılır. Görüntü analistleri, bu görsel işleme tekniklerini kullanarak yorumlarını farklı temellere dayandırabilirler. Görüntü işleme sadece teknik bilgiyle sınırlı kalmaz, aynı zamanda mühendislerin yaratıcılığı ve düşünme yeteneğiyle de şekillenir. Görsel tekniklerle yapılan görüntü işleme alanında, geçmişte toplanmış ve işlenmemiş ham veriler de önemli bir rol oynar. Analistler, istedikleri ürünleri

tanımlamak için geçmiş işlemlerle ilgili bilgileri sisteme aktarabilirler. Görüntü işleme, bir tür derin öğrenme şekli olarak, geçmiş verilere dayalı olarak çalışır.

Dijital işleme yöntemleri, dijital görüntülerin bilgisayarlar aracılığıyla manipüle edilmesine yardımcı olur. Örneğin, uydu platformundan alınan görüntüler, algılayıcı hataları nedeniyle eksiklikler içerebilir. Bu eksiklikleri gidermek ve verinin bütünlüğünü sağlamak için, farklı işleme aşamalarından geçmeleri gerekmektedir. Her türlü verinin dijital işleme yöntemlerini kullanarak işlenmesi üç ana aşamayı içerir: Ön işleme, geliştirme ve görüntüleme ve bilgi çıkarımı (Anonim-9, 2023).

1.6.4. Derin öğrenmede kullanılan algoritmalar

Her geçen gün gelişen teknolojik ilerlemelere bağlı olarak derin öğrenme algoritmalarının sayısı da artmaktadır. Derin öğrenme mimarileri oluşturulurken kullanılacak algoritmalarda büyük önem kazanmaktadır. Kullanılan bu algoritmalar verinin türüne, boyutuna, hacmine ve yapısına, kullanılacak olan parametrelere göre farklılık gösterebilmektedir. Bu algoritmalar;

- Evrimsel Sinir Ağları (ESA Convolutional Neural Network - CNN)
- Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN)
- Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines-RBM)
- Derin İnanç Ağları (Deep Belief Networks-DBN)
- Otomatik kodlayıcılar, olarak sınıflandırılabilir (Savaş, 2020).

1.7. Kesici Takımlar

Günümüz kesici takımları, modern talaşlı imalat yöntemlerinde kesme işlemlerinde yüksek gerilimlere ve ağır çalışma koşullarına maruz kalmaktadır. Bu koşullar arasında kuru işleme, yüksek hızlı işleme veya yüksek performanslı işleme de yer alır. Yeni işleme yöntemlerinin geliştirilmesi, daha dayanıklı ve uyumlu kesici takımların gerekliliğini ortaya koymaktadır. Bir kesici takım yüksek sertlik, iyi bir tokluk ve kimyasal kararlılığı bir arada bulunduruyorsa bu kesici takım ideal bir kesici takım olarak kabul edilir. Ancak sertlik ve tokluk değerleri arasında zıt bir ilişki vardır ve bu iki niteliği istenilen düzeyde aynı anda bulundurulmuş kesici takımlar nadir bulunurlar (Byrne

1.7.1. Kesici takımların tarihsel gelişimi

19. yüzyıl ile birlikte çeşitli işlemlerle çeliklere uygulanan bazı uygulamalar sonucunda takım çeliklerini üretimi başladı. Bu gelişim süreci ile birlikte o denemin en ideal takım malzemeleri yüksek karbonlu çelikler ve alaşımlı çelikler olarak kabul edildi. Ancak en ideal olarak kabul edilen bu malzemeler belirli bir hızlarında oluşan ısıya karşı bile sertliklerini kaybettiler. Bu nedenlerden dolayı ilk üretilen takımların kullanım ömürleri oldukça kısa oldu. Ayrıca o dönemde ısıt işlemler ve metalürji bilimi henüz yeterince gelişmemişti, bu yüzden takımlar işlem sırasında niteliklerini koruyamıyorlardı. Mushet çeliği, hız çeliğine benzer özellikler taşıyan ve tesadüfen bulunan ilk geliştirilmiş takım malzemesidir. Mangan ile yapılan deneyler sonucunda, çeliğin havada sertleştirilebileceği ve böylece elde edilen alaşımlı çeliklerin karbon çeliklerine kıyasla işleme kapasitesinin daha olduğu keşfedildi. Bu keşif sonucunda geliştirilen malzemeler daha yüksek sıcaklıklarda çalışabilme yeteneği ve daha yüksek hızlarda (yaklaşık 10 m/dk) iş parçalarını işleme yeteneği ile karbon çeliğine göre büyük bir ilerleme kaydetmiştir. 19. yüzyıl ile birlikte Fredrick Taylor tarafından hız çeliğinin bulunması ile kesici takımlarda büyük bir gelişme yaşanmıştır. Bu gelişme ile birlikte 40 m/dk kesme hızı, 1,6 mm/dk ilerleme hızı ve 4,8 mm talaş derinliği gibi yüksek işlem değerlerine ulaşılabilme imkanı oluştu. Keşfedilen bu hız çeliği, talaşlı imalata önemli katkılarda bulunmuştur. Özellikle torna tezgahlarında yüksek hızlı çelik takımların kullanımını teşvik etmiş, aynı zamanda Taylor'un bulduğu takım ömrü bağıntısı günümüzde hala geçerliliğini korumaktadır (Çakır, 2006).

1.7.2. Kesici takımların özellikleri

Talaşlı imalat sürecinde, genellikle iş parçası ile takım malzemesi arasında bir rekabet olduğu söylenebilir. Bu nedenle, takım malzemesinin ve iş parçasının özelliklerinin birbirine zıt olması beklenir. Kesici bir takımda genel itibarıyla aranan özellikler şunlardır.

* Takım malzemesi, yalnızca oda sıcaklığında değil aynı zamanda çalışma sıcaklığında da iş parçasının en sert parçasından daha sert olmalıdır. Takım şeklinin bozulmasını önleyen yüksek kıvırt sertlik, talaş oluşumu sırasında ağır şartlar altında takım geometrisini korumalı ve hatta aşınma direncine destek sağlamalıdır.

- * Aralı kesmede mekanik şoklara dayanabilmesi için istenilen tokluğa sahip olmalıdır.
- * Aralı kesme işlemlerinde hızlı ısınma ve soğumalar oluşacağından yüksek termal şok direncine karşı dayanıklı olmalıdır.
- * Bölgesel kaynak teşekkülünü önlemek için iş parçasına karşı düşük yapışkanlılığa (iş parçası ile tepkime vermemelidir.) sahip olmalıdır.
- * Takım bileşenlerinin iş parçasına difüzyonu, hızlı aşınmaya neden olacaktır. Bu nedenle takımın iş parçasındaki çözünürlüğü düşük olmalıdır.

Kesici takımlarda düşük sertlik ve adezyon, istenmeyen özellikler arasında yer alır. Çünkü istenmeyen bu özellikler takım profilinin bozulmasına neden olabilir ve takım ucu yuvarlaklaşabilir. İdeal olmayan tokluk ve termal şok direnci, takım ağzının talaşlanmasına ve hatta tamamen hasar görmesine yol açabilir. Ancak malzemenin ısı direnci ve sertliği, genellikle tokluğun azalmasıyla elde edilebilir. Bu nedenle, yukarıdaki niteliklerin tamamını aynı anda sağlayan bir takım malzemesi genellikle bulunmaz (Schey, 1987).

1.7.3. Kesici takım malzemeleri

Kesici takımlar, malzemeye şekil verme, kesme ve malzemeyi istenilen ölçüye getirme gibi talaşlı işlemler sırasında çeşitli zorlamalara uygun bir şekilde tepki verme yeteneğine sahip olmalıdır. Günümüzde teknolojinin ilerlemesiyle birlikte her geçen gün artan ihtiyaçları karşılamak amacıyla, farklı malzemelerden üretilen ve ekonomik bir şekilde işlenebilen yeni kesici takımlara olan gereksinim artmıştır. Kesici takımlar günümüz şartlarında yüksek kaliteli, yüksek boyut hassasiyetine sahip ve büyük ölçüde son teknolojik ürünü malzemelerden üretilmektedir.

Kesici takım seçimi yapılırken özellikle işlenecek ham maddenin özellikleri ile kesici takımın işleme sırasında karşılaştığı koşullar da göz önünde bulundurularak yapılmalıdır. Kesici takımlardan yüksek sıcaklıklarda sertliğin, yüksek hızlarda ise aşınma dayanıklılığı ve tokluğun korunması gibi özellikler istenilen ortak özelliklerdir. Bu özellikleri taşıyan kesici takımların daha kaliteli ve uzun ömürlü olmasının yanında aynı zamanda imalat maliyetlerini düşürecektir.

Kesici takımlar; metal, karbür ve seramik esaslı malzemeler olmak üzere genel itibarıyla 3'e ayrılabilir. Günümüz şartlarında en yaygın yüksek hız çelikleri ve sinterlenmiş karbürler kullanılmaktadır. Ayrıca, yüzey kalitesini iyileştirmek ve takım

ömrünü artırmak amacıyla yapılan çalışmaların sonucunda kübik bor nitrür (CBN) ve elmas kesici takımları da kullanılmaya başlanmıştır (Ozdemir ve ark., 2000).

1.7.3.1. Takım çelikleri

Takım çelikleri; metal, plastik, ahşap gibi birçok malzemenin işlenmesi ve şekillenmesinde kullanılmak üzere özel olarak geliştirilmiş çelik türleridir. Bu çelikler, özellikle kimyasal kompozisyonları ve mekanik özellikleri açısından diğer çelik gruplarına kıyasla daha zengin bir yapıya sahiptir. Kimyasal özelliklerine göre alaşımlı, alaşımsız ve yüksek alaşımlı takım çelikleri olarak sınıflandırılırlar. Aynı zamanda kullanım alanları ve çalışma koşullarına göre de sıcak işlem, soğuk işlem, plastik işlem ve yüksek hızlı işlem takım çelikleri gibi farklı alt kategorilere göre de sınıflandırılabilirler (Anonim-11, 2023).

Endüstri devriminden 1860'lı yıllara kadar talaşlı imalatla takım çelikleri büyük ölçüde kullanılmışlardır. Genellikle %0,9-%1,3 arasında karbon elementi içeren çeliklere, manganez, silis, sülfür ve fosfor elementleri gibi diğer alaşım elementleri de eklenerek çelik yapımı kolaylaştırılmıştır. Karbonlu çelikleri genellikle 835 - 850°C arasında olan sıcaklıkta kızıl sıcaklık durumuna kadar ısıtılıp ardından su içinde hızla soğutulularak sertleştirilirler.

Takım çelikleri arasında yer alan yüksek hız çelikleri (YHC), diğer takımlara göre daha ekonomik ve kolay işlenebilirliklerinden dolayı matkap, broş, azdırma çakısı, parmak freze, kılavuz ve benzeri kesici takımlar olarak kullanılmaktadır (Ozdemir ve ark., 2000). Şekil 1.19' da takım çeliklerin yapısını göstermektedir.



Şekil 1. 19. Takım çelikleri (Anonim-11, 2023)

1.7.3.2. Sinterlenmiş karbürler

YHC takımları normal şartlarda 50 m/dk'dan daha küçük kesme hızlarında kullanılırken, 1930'lu yıllarda geliştirilen ve kullanılmaya başlayan sementle edilmiş veya sinterlenmiş karbürler olarak da bilinen karbür takımları daha yüksek sertliğe ve daha yüksek kesme hızlarına ulaşabilmişlerdir. Sinterlenmiş karbür takımların çağımızda tungstenli ve titanyumlu şeklinde iki türü bulunmaktadır (Benhabib, 2003).

Daha düşük sürtünme, takım ve iş parçası arasındaki kimyasal korozyona karşı direncin artırılması gibi mekanik ve termal özelliklerini iyileştirmek amacıyla kaplanan takımlara karbür takımları adı verilir. Tungsten karbür (WC) takımlar üzerine genellikle titanyum karbür (TiC), alüminyum oksit (Al_2O_3), seramik ve hatta sentetik elmas gibi kaplama malzemeleri uygulanır. Bu kaplamalar, kimyasal veya fiziksel buhar biriktirme yöntemleriyle gerçekleştirilirler (Benhabib, 2003). Şekil 1.20' de sinterlenmiş tungsten karbür ve Şekil 1.21' de sinterlenmiş titanyum karbür yapısını göstermektedir.



Şekil 1. 20. Sinterlenmiş tungsten karbür (Anonim-12, 2023)



Şekil 1. 21. Sinterlenmiş titanyum kaplama karbür çapak parmak freze (Anonim-13, 2023)

1.7.3.3. Kaplamalı karbür takımlar

1969'da TiC kaplanmış WC takımın kullanımıyla başlayan kaplamalı takım uygulamaları, kaplamanın takım ömrünü %200-%300 hatta daha fazla artırmasıyla metal işleme endüstrisinin vazgeçilmezi haline gelmiştir. Kesici takımlarda, kesme sırasında iş parçası ile takım arasındaki kimyasal etkileşimi ve aşınmayı engelleyebilmek için takım yüzey malzemesinden abrazif aşınmaya dayanıklılık, sertlik ve kimyasal inertlik beklenir. TiC, TiN veya Al_2O_3 kaplama bu beklentileri karşılayacak niteliklere sahiptir. Kaplama takım gövdesine iyi tutunmalı, talaşın yüzeye yapışmaması için düşük sürtünme katsayısına sahip olmalı, takım ömrünü artıracak kadar kalın ve aynı zamanda gevrek ve kırılgan olmayacak kadar ince olmalıdır. Kaplamalı karbür takımlar pek çok metal kesme uygulamasında geniş bir kullanım alanına sahiptir. Kaplamalı takımlar kaplamasız takımlara kıyasla iki, üç kat daha iyi aşınma direncine sahiptirler (Degarmo ve ark., 2006).

Kesme işleminde, talaşın iş parçasından ayrılması ve talaşın kesme yüzeyinde sıkışmasıyla iç sürtünmeler oluşacağı gibi talaşın takım yüzeyine sürtünerek akmasıyla dış sürtünmeler de meydana gelir. Tüm bu istenmeyen durumlar, kesici takımın ısınmasına ve sonuç olarak sertliğinin azalmasına, takım aşınmasının ve kesme kuvvetinin artmasına yol açar. Kesici takımların kaplanması ile talaşın yüzeyde daha kolay akmasına bağlı olarak sürtünmenin ve açığa çıkan ısının azalması, yüzey sertliğinin artması ile takım aşınması ve gerekli olan kesme kuvvetinin azalması mümkün olur. Bu nedenle, kesici takımların kaplanması, takım tezgahlarının işleme verimini artırarak işlemi daha verimli hale getirir (Şahin, 2000).

1.7.3.4. Seramikler

1950'lerde ilk tanıtılan seramik takımlar, genellikle yüksek sıcaklıklarda ve yüksek sertlik gerektiren işlemlerde kullanılan takımlardır. Bu seramik takımlar, çeliği 700-800 m/dk hızlarında işleyebilme kapasitesine sahiptirler. Amerika'da yaklaşık otuz yılı aşkın bir zaman diliminde yapısal seramikler üzerine önemli araştırmalar yapılmaktadır. Bu çalışmalar sonucunda geniş bir veri tabanı oluşturulmuştur. Yapılan bu çalışmaların büyük bir kısmı yüksek sıcaklık uygulamalarında kullanılma potansiyeli nedeniyle Al_2O_3 ve SiC malzeme ailesine odaklanmıştır. Alümina (Al_2O_3) dayanımını ve sertliğini az sayıda refrakter sinterlenmiş karbürden daha iyi bir şekilde korur (Benhabib ve ark., 2003).

Ford Motor, alümina kesici takımların ticari kullanımına öncülük etmiş ve bu kesici takımları tercihen yüksek kesme hızlarıyla bitirme işlemlerinde kullanarak verimliliği artırmıştır. 1970'lerin başlarında Ford, imalat süreçlerindeki verimliliği artırmayı hedeflemiştir. Bu hedefler doğrultusunda yapısal seramikler üzerine yapılan çalışmalar sonucunda ileri seramiklerin kesici takım malzemesi olarak kullanılması düşünülmüştür. İmalat sektöründe kullanılması düşünülen ileri seramik takımlar geleneksel takımlarla kıyaslandığında sahip oldukları yüksek sertlik ve kimyasal kararlılıkları bağlı daha yüksek kesme hızlarında işlem yapabilme avantajına sahiptirler. Talaşlı imalat yönteminde maksimum verimi elde etmek için kesme hızındaki artış ile takım ömründeki azalış olasılığı ve takım dayanıklılığı arasındaki dengeyi optimize etmek gereklidir (Askeland ve Plule, 2006)

1.7.3.5. Sermetler

Sermetler, seramik ve metal malzemelerin birleşimiyle oluşan kompozit malzemelerdir. Bu malzemelerde, seramiklerin yüksek sertlikleri, yüksek sıcaklık dayanımları ve metallerin tokluk özellikleri bir araya getirilerek ideal bir malzeme yapısı oluşturulmaya çalışılmıştır. Sermetler, fiziksel yapıları bakımından metal matrisli kompozit malzemelere benzerlik gösterirler, ancak hacimlerinin %20'den azı metal içerir. Bu kombinasyon sayesinde Sermetler; yüksek sertlik, yüksek sıcaklık dayanımı ve iyi tokluk özelliklerini bir arada sağlayabilen özel bir malzeme türüdür (şahin, 2000).

Sermetler, özellikle bitirme işlemlerinde oldukça uygun olan, yeni nesil takım malzemeleridir. Bu malzemeler genellikle seramik titanyum karbür (TiC), nikel, kobalt ve tantal nitrür içerir. TiN ve diğer karbürler, bu malzemelerin bağlayıcıları olarak kullanılır. Sermetler, üstün aşınma dayanımına sahip olmalarıyla öne çıkar ve daha uzun takım ömrü sunarlar. Ayrıca yüksek kesme hızlarında da etkili bir şekilde kullanılabilirler. Sermetler, sinterlenmiş karbürlerden daha iyi yüksek sıcaklık sertliği ve oksidasyon direncine sahiptirler. Bu özellikleri sayesinde Sermetler, özellikle demir esaslı malzemelerin bitirme işlemlerinde başarılı sonuçlar elde etmek için tercih edilirler (Degarmo ve ark., 2006).

Kesme hızları sermetli takımlarda oldukça yüksek olabilir. Karbürülü takımlarda yaklaşık 160 m/dk, kaplamalı karbürülü takımlarda 240 m/dk gibi değerler tipikken, sermetli takımlarda bu değerler neredeyse %100'e yakın bir artışla 340 m/dk veya daha

yüksek değerlere çıkabilmektedir. Bu yüksek kesme hızları, sermet takımlarının üstün aşınma dayanımı ve yüksek sıcaklık performansı sayesinde mümkün olmaktadır.

Sermetlerin düşük ısı iletkenliği ve büyük ısı genleşmeleri nedeniyle sıcaklık değişikliklerine duyarlı olduğunu belirtmek mümkündür. Sermet kesici takımlarla gerçekleştirilen talaş kaldırma işlemlerinde soğutma sıvısı kullanılmışsa çok büyük sıcaklık değişiminin olmaması için gerekli tüm önlemler alınmalıdır. Bu bağlamda, yeterli miktarda soğutma sıvısı kullanımı ve sıcaklık kontrolü önemlidir. Sermetlerin sinterlenmiş karbürlere kıyasla daha düşük tokluğa sahip olduğunu belirtmek de mümkündür. Bu nedenle, özellikle frezeleme gibi aralıklı talaş kaldırma işlemleri için Sermetlerin uygun olmadığına dikkat çekilebilir. İşleme parametreleri ve koşullarının Sermet malzemenin özelliklerine uygun şekilde ayarlanması gereklidir (Şahin, 2000).

1.7.3.6. Elmas

Karbon elementinden doğal elmas oluşur. Tek kristalli elmas (MCD) malzemesi en yüksek sertlik değerlerine sahip elmas türüdür. Bu olağanüstü sertlik, kristalin benzersiz atomik düzenlemesinden kaynaklanmaktadır. Elmas malzemesi, düşük sürtünme katsayısı, düşük ısı genleşme katsayısı, yüksek dayanım ve kimyasal aşınma direnci gibi özellikleri ile dikkat çekici bir fiziksel, kimyasal ve mekanik kombinasyon sunar. Bununla birlikte bazı kullanım sınırlamaları da vardır. Oda koşullarında kararlı bir yapıya sahip olsa da 600°C'nin üzerindeki sıcaklıklarda orijinal grafit haline dönüşebilir. Ayrıca, karbonun demirle olan kimyasal etkileşimi nedeniyle elmas kesiciler demir içeren malzemelerde yüksek aşınma oranlarına neden olabilir. Elmas kesici takımların bu özelliklerinden dolayı genellikle demir dışı metallerin ve metal olmayan malzemelerin işlenmesi için uygundur (MEGEP, 2006).

1.7.3.7. Kübik Bor Nitrür (CBN)

Elmasta sonra en sert takım malzemesi olarak kabul edilen bir maddedir. Oldukça sert olmasının yanı sıra kırılgan değildir. Bu nedenle genellikle kaplama malzemesi olarak tercih edilir. Ayrıca CBN, demir esaslı malzemelerin işlenmesi için özellikle uygun bir seçenektir. Bu özelliği demir, çelik ve dökme demir gibi malzemelerin işlenmesinde kullanılmasını sağlar (MEGEP, 2006).

Bor nitrür, farklı kristal yapılarına sahiptir. Daha yaygın olarak "hekzagonal bor nitrür" olarak adlandırılan grafit benzeri yapının yumuşak ve kaygan özelliklerinin aksine, "kübik yapıda bor nitrür" (CBN) sert ve aşındırıcı özelliklere sahiptir ve genellikle kesici takım olarak kullanılır. CBN, elmas ile aynı kristal yapıya sahip olup benzer özellikler sergiler. Kübik bor nitrür, özel seramik bağlayıcı ile birleşen taneciklerden oluşur (Byrne ve ark., 2003).

Ticari anlamda, bor nitrür kesici takımlar ilk kez 1980'li yıllarda lehimlenebilir ve değiştirilebilir uçlar olarak kullanılmaya başlanmıştır. Günümüzde bu tür kesici takımların üretimi sınırlı sayıda firma tarafından gerçekleştirilmektedir. Örneğin, General Electric firması "Borzan (BZN)" adıyla, De Beers firması "Amborite" adıyla ve Subitama firması "Sumiboron" adıyla CBN kesici takım üretimi yapmaktadır (Şahin, 2000).

1.7.3.8. Süper sert kesiciler

Bu takımların gelişimi 1970'li yılların başları ile birlikte çok kristalli elmas kesici takımların tanıtımıyla başladı. Bugüne kadar geliştirilen temel çok kristalli malzemeler arasında çok kristalli kübik bor nitrür (PCBN) ve çok kristalli elmas (PCD) malzemeleridir. Bu malzemelerin pazar payları %1 gibi düşük bir düzeyde olsa da bu kesici takımları geleneksel alternatiflerle karşılaştırılması pek doğru olmaz. Çünkü sektörlerdeki genel eğilim hem PCD'nin hem de PCBN'un kullanımına yönelik bir artış olduğu ve bu artışın giderek artmaya devam ettiğini göstermektedir. Özellikle CBN kesici takımlarının kullanımı, ağır talaşlı imalatındaki artış nedeniyle yıllık %10-%15 oranında büyümektedir.

Her iki süper sert malzeme de ayrı ayrı elmas veya CBN parçacıklarının katı bir kütle içinde veya bir tungsten karbür (WC) altlığı üzerinde demir, nikel veya kobalt katalizörler ile birleştirilmesi yoluyla yüksek sıcaklık ve basınç işlemleri kullanılarak üretilir.

Termal olarak CNB malzemesi 1200 °C'ye kadar kararlıdır ve 1400 °C'ye kadar da iyi kimyasal aşınma direncine sahip olduğu bilinmektedir.

PCD ise belirli elmas parçacıklarının CBN sentezi için özel koşullarda sinterlenmesi ile üretilir. PCD malzemelerin başlıca sorunları 600 °C'nin üzerindeki sıcaklık engelleri, yüksek gerilim altında çalışan parçaları, demir içerikli malzemelerin kimyasal eğilimleri ve sertliklerindeki kayıplarıdır (Grzesik, 2008).

1.7.4. Kesici takım seçim kriterleri

Talaşlı imalatın verimli bir şekilde gerçekleştirilebilmesi ve iş parçasının istenilen kalitede işlenmesi için doğru kesici takım malzemesinin seçimi son derece önemlidir. Bu doğru seçim, imalatın ekonomik açıdan avantajlı olmasını sağlayabilir. Daha yüksek kesme ve ilerleme hızlarında kesici takımların etkili bir şekilde talaş kaldırabilmeleri için belirli önemli özellikleri taşıması gerekmektedir. Bu özellikler şunlardır

a) Aşınma Dayanımı (Aşınma Direnci-WR): Kesici takım malzemesinin yüzeyinin işlem sırasında oluşan sürtünme ve aşınma kuvvetlerine dayanabilme yeteneğidir.

b) Kırılmaya Karşı Mukavemet (Tokluk-T): Kesici takım malzemesinin darbelere ve yüksek yüklere karşı direnç gösterme yeteneğidir. Kesme sırasında ani yüklere karşı tokluk, takımın sağlamlığını etkiler.

c) Yüksek Sıcaklıklarda Sertlik ve Kimyasal Kararlılık (Kızıl Sertlik-HH): Kesici takımın işlem sırasında yüksek sıcaklıklara maruz kaldığında sertliğini ve kimyasal yapısını koruyabilme yeteneğidir.

Uygun bir kesici takım malzemesinin seçimi için kesici takım malzemesi ve geometrisi gibi faktörlerin yanı sıra aşağıda belirtilen faktörlere de bağlıdır.

- İş parçasının malzemesi ve özellikleri
- Kesme ve ilerleme hızı
- Kesme ortamı (soğutma ya da yağlama)
- İş parçasının boyutları ve şekli
- İş parçasının yüzey kalitesi gereksinimleri
- İşleme maliyetleri

Bu faktörler bir araya geldiğinde en uygun kesici takım seçimi yapılabilir ve talaşlı imalat işlemi en verimli şekilde gerçekleştirilebilir (Çakır, 2006).

1.7.5. Kesici takım seçimini etkileyen faktörler

Kesici takım seçimini etkileyen birçok faktör vardır. İşlenecek malzemeye uygun bir kesici takım seçmek oldukça önemlidir. Bir kesici takım seçilirken özellikle bazı özelliklere dikkat edilir. Dikkat edilmesi gereken bu özellikler aşağıdaki gibidir.

a) Üretimde kullanılan malzemenin sertliği: Şekil verme işlemleri genellikle malzemenin yüzeyinden belirli miktarlarda talaş kaldırarak gerçekleştirilir. İstenilen talaş kaldırma miktarlarına ulaşmak, malzemenin sertliğiyle yakından ilişkilidir. Bu nedenle üretim sürecinde kullanılan malzemenin sertliği, doğru kesici takım seçimi için büyük bir önem taşır.

Malzemenin sertliği, kesici takımın performansını ve dayanıklılığını etkiler. Daha sert malzemeler genellikle daha dayanıklı kesici takımlar gerektirir. Çünkü sert malzemeler kesme sırasında daha fazla sürtünme ve aşınma kuvvetine neden olabilir. Bu nedenle, kesici takım seçimi yapılırken malzemenin sertliği dikkate alınmalıdır. Uygun kesici takım seçimi; malzeme sertliği, kesme hızı, kesme derinliği ve diğer işleme parametreleri göz önünde bulundurularak yapılmalıdır. Doğru kesici takım seçimi işlemin daha verimli ve kaliteli bir şekilde gerçekleştirilmesini sağlar.

b) Malzeme üzerinde yapılacak işlemin niteliği: Şekil verme işlemleri genellikle talaş kaldırma yöntemiyle gerçekleştirilir. Ancak her bir işlem sadece niceliksel olarak değil aynı zamanda niteliksel olarak da farklılaşır. Malzeme üzerinde delik delme, kanal açma, tırtıl açma gibi çeşitli işlemler yapılabilmektedir. Bu işlemlerin her biri malzeme üzerinde farklı etkiler yaratır ve farklı kesici takım gereksinimleri ortaya çıkarır. İşlemin niteliği, kesici takım seçiminde büyük bir öneme sahiptir. Her işlem kesici takımın kesme hızı, kesme derinliği, işleme hızı gibi faktörlerini etkileyebilir. Örneğin, delik delme işlemi farklı bir kesici geometrisi ve malzeme gideri gerektirebilirken kanal açma işlemi farklı bir kesici profilini tercih edebilir.

Kesici takım seçimi yapılırken işlemin türü, malzemenin özellikleri, işleme parametreleri ve istenen sonuçlar gibi faktörler dikkate alınmalıdır. Doğru kesici takım seçim işleminin daha etkili, hassas ve verimli bir şekilde gerçekleştirilmesini sağlar.

c) Ulaşılmak istenen pürüzsüzlük: Talaş kaldırma işlemi sonrasında elde edilmek istenen yüzey pürüzlülüğü ya da pürüzlülük değeri malzemenin kullanım amacına göre

farklılık gösterebilir. Bu nedenle, işleme sürecinde kullanılacak kesici takımın özellikleri hedeflenen pürüzsüzlüğe uygun şekilde seçilmelidir. Son işlenen yüzeyin istenen pürüzsüzlük seviyesine ulaşabilmesi için kesici takımın kesme kenarı geometrisi, kesme hızı, besleme hızı gibi parametreler özenle ayarlanmalıdır. Bu parametreler işleme sonrası yüzey kalitesini büyük ölçüde etkiler. Yüzey pürüzsüzlüğü iş parçasının görünümü, fonksiyonelliği ve performansı üzerinde doğrudan etkilidir.

Yüzey pürüzsüzlüğü işlenen malzemenin özellikleri, kesici takımın nitelikleri, işleme hızları ve kesme derinliği gibi faktörlere bağlı olarak değişir. İş parçasının kullanım amacına uygun olarak istenilen sonuca ulaşmak için uygun kesici takım seçimi ve işleme parametrelerinin özenle belirlenmesi gerekmektedir.

d) Malzeme üzerinden koparılabacak talaş oranı: Kesici takım seçiminde etkili olan önemli faktörlerden biri, talaşlı imalat sırasında malzeme üzerinden koparılmak istenen talaş oranıdır. Şekil verme işlemleri genellikle belirli bir miktar talaşın malzemedan kaldırılmasıyla gerçekleştirildiği için, talaş oranı kesici takımın seçiminde dikkate alınması gereken bir parametredir.

Talaş oranı kesici takımın işleme sırasında ne kadar talaş kaldıracağını belirler. Bu kesici takımın kesme hızı, besleme hızı ve kesme derinliği gibi faktörlerle ilişkilidir. İstenen talaş oranı, iş parçasının özelliklerine ve işlemenin amaçlarına göre değişebilir.

Talaş oranının doğru bir şekilde belirlenmesi işlemin verimli ve kaliteli bir şekilde gerçekleştirilmesi için önemlidir. İşleme sonucunda elde edilecek talaş oranı, malzeme koparılması ve yüzey kalitesi üzerinde etkili olabilir. Bu nedenle kesici takım seçimi yapılırken istenen talaş oranının işleme parametreleriyle uyumlu olması gerekmektedir.

e) Malzemenin ve kesici takımın rijitliği: Kesici takım seçiminde, malzeme üzerinden kaldırılmak istenen talaş miktarı ve elde edilmek istenen yüzey pürüzsüzlük oranı kadar kesici takımın sertliği de büyük bir öneme sahiptir. Malzemenin sertliğiyle uyumlu bir kesici takım seçimi başarılı bir işleme sonucu elde etmek için kritik bir faktördür.

Kesici takımın sertliği, malzemenin sertliğine uygun şekilde seçilmelidir. Kesici takım malzemesi işlenen malzemenin özelliklerine ve işleme amacına göre doğru bir şekilde belirlenmelidir. Eğer kesici takım malzemesi işlenen malzemedan daha yumuşaksa takımın hızlı bir şekilde aşınması ve kesici kenarının körelmesi gibi sorunlar ortaya çıkabilir. Aksine kesici takım malzemesi işlenen malzemedan daha sertse kesici takımın kırılma riski artar.

Kesici takımın sertliđi işleme parametreleri, malzeme türü ve işlenen parçanın özellikleri gibi faktörler göz önünde bulundurularak seçilmelidir. Doğru sertlik seviyesine sahip kesici takım istenen talaş kaldırma miktarı ve yüzey pürüzsüzlüğüne ulaşmak için kritik bir rol oynar.

f) İşlenen malzeme başına düşen maliyet: Kapitalist üretim sisteminde endüstriyel üretimin en belirgin özelliklerinden biri kâr amacı doğrultusunda gerçekleştirilmesidir. Üretim, toplumun ihtiyaçlarına cevap verirken aynı zamanda üreticinin kâr elde etmesini hedefler. Bu bağlamda üretim sürecinde harcanan hammadde, malzeme ve emek gücü maliyeti elde edilen ürünün satış fiyatından daha düşük olması beklenir. Bu nedenle kesici takım seçimi sırasında sadece teknik özellikler değil aynı zamanda üretim maliyetleri de önemli bir faktördür. Kesici takımın performansı ve ömrü, üretim sürecinde kullanılan malzemenin türü, işleme parametreleri ve maliyetlerle dengelemelidir.

Üreticinin, kullandığı malzemeyi ve işleme sürecini iyi anlaması kesici takım seçiminde doğru kararlar vermesini sağlar. Ayrıca kesici takım türleri ve özellikleri hakkında bilgi sahibi olması da önemlidir. Bu sayede hem üretim kalitesi hem de maliyet etkinliđi gözetilerek kesici takım seçimi yapılabilir.

Kesici takım seçimi işletmenin genel üretim stratejisi ve ekonomik hedefleriyle uyumlu olmalıdır. Bu hem verimlilik hem de kârlılık açısından önem taşır ve endüstriyel üretimde başarılı sonuçlar elde edilmesini sağlar (Anonim-14, 2023).

2. LİTERATÜR TARAMASI

2.1. Derin Öğrenme ile İlgili Yapılan Bazı Çalışmalar

Abu-Mahfouz (2005) yaptığı çalışmada normal durum şartlarında çalışan diş kutusunun aşınması, arıza ve oluşan hasarların tespit edilmesi ve sınıflandırmasının yapılabilmesi için ileri beslemeli geri yayılım (FFBP), fonksiyonel bağlantı ağı (FLN) ve öğrenen vektör parçalama (LVQ) algoritmaları olmak üzere üç farklı yapay sinir ağı (YSA) mimarisi eğitilmiştir. Geliştirilen bu yapay sinir ağlarının sonuçlarına genel bir bakış açısı sunmuştur. Ayrıca, titreşim sinyalleri kullanılarak elde edilen veriler üzerine, kasıtlı olarak şanzımana eklenen gevşek bir anahtar, tek diş yan aşınması ve tam diş kırılması gibi üç yapay kusurun analizi yapılmıştır. Yapılan bu kapsamlı deneylerde, YSA'lara besleme amacıyla zaman ve frekans alanında kullanılan tanımlayıcı özellik vektörleri kullanılmıştır. Çalışmanın sonuçları FLN algoritmasının daha hızlı öğrenme yeteneği ve operasyon sırasında FFBP veya LVQ'ya göre daha doğru sonuçlar ürettiğini göstermektedir. LVQ algoritması FFBP'ye göre daha hızlı yakınsama sağlamış ancak yanlış sınıflandırmalar konusunda daha duyarlı olmuştur.

Denil ve ark. (2013) gerçekleştirdikleri çalışmada derin öğrenme yöntemleri ile ilgili yapılan değişken atamalarında önemli bir fayda sağladığını belirlemişlerdir. Her bir özelliğin değerlerine bakarak diğer değerleri doğru bir şekilde tahmin edebildiğini göstermişlerdir. Ayrıca çalışmada diğer değişkenlerin öğrenilmeden tahmin edilebileceğini öne sürmüşlerdir. Değişkenlerin eğitim ve test edilmesi sonucunda geriye kalan mimarinin en iyi ihtimal durumunda %95 gibi bir oranda tahmin yapabildiğini göstermişlerdir.

Sladojevic ve ark. (2016) yaptıkları bir çalışmada evrişimli sinir ağları kullanılarak görüntü sınıflandırmasında büyük bir yol kat ettikleri vurgulanmıştır. Bu çalışmada bitkilerin yaprak şekillerine bakılarak hastalıklarının tespit edilmesinde derin öğrenme yöntemlerinin kullanılmasıyla dijital tarım alanında daha verimli bitki yetiştirme imkanlarının oluştuğu ifade edilmiştir. Çalışma, geliştirilen bir model aracılığıyla bitki yapraklarının çevresinden ayrıştırılma yeteneği sayesinde sağlıklı yapraklardan 13 farklı bitki hastalığının tanımlanabileceğini göstermiştir. Bu yöntem bitki hastalıklarının tanınmasında önerilen ilk yöntem olma özelliği taşımaktadır. Görüntülerden hastalık tespiti için Berkley Vision and Learning Centre tarafından geliştirilen Caffé derin öğrenme çerçevesi kullanılarak bir hastalık tanıma modeli geliştirilmiştir.

Gerçekleştirilen deneysel çalışma sonucunda yaprak hastalıklarını ayrı sınıflarda test etmek için yaklaşık %91-%98 gibi yüksek bir doğruluk oranında sonuçlar elde edilmiştir.

İnik ve Ülker (2017) derin öğrenme hakkında ayrıntılı bilgiler sunulmuşlardır. Çalışmalarında evrişimli sinir ağı (ESA) mimarisi tarafından kullanılan katmanlar detaylı bir şekilde ele alınmıştır. Bu katmanlar arasında konvolüsyon, havuzlama, ReLU (Rectified Linear Unit), dropout, tam bağlantılı ve sınıflandırma katmanları bulunmaktadır. Her bir katmanın işlevleri ve nasıl çalıştığı ayrıntılı olarak açıklanmıştır. Aynı zamanda, derin öğrenme alanında temel kabul edilen mimariler de detaylı bir şekilde açıklanmıştır. Bu kapsamda, AlexNet, ZFNet, GoogLeNet, Microsoft ResNet ve R-CNN gibi önemli mimarilere üzerinde yoğunlaşmıştır. Bu mimarilerin nasıl çalıştığı, hangi bileşenlerden oluştuğu ve hangi problemleri çözmek için kullanıldığı anlatmıştır.

Coşkun ve ark. (2017) yaptığı çalışmada, derin öğrenme (DÖ) kavramlarına odaklanıldığı görülmüştür. Makine öğrenimi alanındaki yaklaşımlardan biri olarak kabul edilen derin öğrenmenin genel kavramlarına, gelişimine ve mevcut uygulamalarına genel bir bakış açısı sunulmuştur. Yapılan bu çalışmada tipik derin öğrenme algoritmaları olarak kabul edilen CNN (Convolutional Neural Network), RNN (Recurrent Neural Network), RBM (Restricted Boltzmann Machine) ve otomatik kodlayıcılar gibi algoritmaların temel kavramları ve işleyiş mekanizmaları detaylı bir şekilde açıklanmıştır.

İbte haz ve Rahman (2020) tarafından yapılan araştırmada U-Net modelinin yerine daha gelişmiş model olan MultiResUnet modeli ile ilgili çalışmalar yapmışlardır. Bu gelişmiş olan mimariyi tıbbi görüntülerle eğitilmiştir. İki farklı mimari karşılaştırılmış ve değerlendirilmiştir. Çalışmada beş farklı veri kümesi kullanılmıştır. Elde edilen sonuçlara göre, performans yüzdeleri sırasıyla %10,15, %5,07, %2,63, %1,41 ve %0,62 olarak bulunmuştur. Bu çalışmada, tıbbi görüntü bölüntülüne de derin öğrenme modellerinin hastalık tespiti ve önlemede öncü bir rol oynayabileceği konusunda öngörüler sunmuşlardır.

Villacres ve AuatCheein (2020) yaptıkları çalışmada özellikle faster R-CNN yöntemi ile kiraz algılama, sınıflandırma ve sayma için derin öğrenme stratejilerinin kullanılabilirliği gösterilmişlerdir. Yapılan çalışma için belirli zaman aralıklarında farklı saat ve aydınlanma koşullarında toplamda 15.000'e kadar RGB görüntüsü elde edilmiştir. Görüntü veri tabanı, bir araca monte edilen bir kamera yardımıyla 25 deneme sürüşü

sırasında toplanmıştır. Bu veriler kullanılarak kirazları sayma konusundaki başarı oranının %85 olduğu bulunmuştur.

Lin ve Guo (2020) tarafından yapılan çalışmada insansız hava araçları (İHA) görüntülerini kullanarak sorgum salkımı algılama ve sayma yöntemleri geliştirilmiştir. Bu çalışmada görüntü segmentasyonu ve CNN (Convolutional Neural Network) modeli entegrasyonu ile sorgum salkımı tespiti ve sayımı gerçekleştirilmiştir. RGB kameralı bir İHA kullanılarak görüntüler elde edilmiş ve bu elde edilen görüntülerden eğitim veri tabanı oluşturulmuştur. Oluşturulan algoritma, sorgum salkımlarını tahmin edilen bir maske ile sayıp tespit etmektedir. Bu işlemde Tensorflow kütüphanesi ile Python programlama dili kullanılmıştır. Sorgum salkımı sayım işlemi ise OpenCV mimarisi ile gerçekleştirilmiştir. Çalışma sonucunda eğitim doğruluğunun görüntü sayısı ile birlikte artış gösterdiği görülmüştür. Bu algoritma 1000 eğitim görüntüsü için yapılan denemede en iyi performansı %95,5 oranında doğruluk ve 2,5 ortalama karekök hatası (RMSE) elde edilmiştir. Yapılan bu çalışma sonucunda sorgum salkımı sayılı için görüntü segmentasyonu ve U-Net CNN yönteminin uygun olduğunu göstermiştir. Bu yöntemin doğru tahmini sayesinde sorgum salkımının yetiştirilmesine önemli bir fırsat sunmaktadır.

Çıtlak ve ark. (2021) gerçekleştirdikleri çalışmada duman borusu sistemlerindeki ısı transferini artırmak amacıyla derin öğrenme yöntemini incelemiştir. Çalışmada 125.000 kcal/saat ısı kapasitesine sahip 42 mm çapında duman borusu 230 mm baca çapı ve 65 mm su giriş ve çıkış çapına sahip farklı tipte yakıtlar kullanılabilen bir katı yakıtlı kazan kullanılmıştır. Bu çalışmada kazanların ısı transfer verimliliğinin artırılması hedeflenmiştir. Deneylerde fan debisi damper ayarı ile değiştirilmiş ve Reynolds sayısı 18,000 ile 28,000 aralığında hesaplanmıştır. Isı transferi artış değerleri için yapılan hesaplamalar sonucunda elde edilen veriler ışığında makine öğrenimi algoritmaları olan Destek Vektör Makinesi (SVM) ve Karar Ağacı Makinesi (M5P model ağacı) kullanılarak tahminlerde bulunulmuştur.

Lu ve ark. (2022) yürüttükleri araştırmada, derin öğrenme yöntemi ile soya fasulyesinin verimini ve ağırlığını tahmin etmeye çalışmışlardır. Araştırma, soya fasulyesi bitkilerinin büyüme sezonu boyunca gerçekleştirilen bir ekim ortamında yapılmıştır. Genelleştirilmiş Regresyon Sinir Ağı (GRNN) yöntemi ile tarla içeriğini tahmin etmek amacıyla derin öğrenme yöntemi önerilmişlerdir. Yüksek hassasiyete sahip tanıma dedektörleri fasulye kapsüllerini tanımak için kullanılmıştır. Tanıma doğruluğu ve hızı göz önünde bulundurularak R-CNN ağı ile YOLO algoritması seçilmiştir. Ekim

yapılan bölgelerdeki soya fasulyesinin ağırlıkları, tohum sayıları ve yaprak geometrileri belirlenmiş ve sonrasında bu veriler kullanılarak eğitilmiştir. Elde edilen ortalama doğruluk oranı %97,43'e kadar yükseltilmiş ve görüntülerin tahmini başarıyla gerçekleştirilmiştir. Böylelikle yapay sinir ağları, soya fasulyesindeki verimini mükemmel bir doğrulukla tahmin edebilmiştir.

2.2. Görüntü İşleme ile İlgili Yapılan Bazı Çalışmalar

Demircioğlu ve ark. (2013) yaptıkları bir çalışmada; görüntü işleme yöntemi, çeşitli alanlarda nesnelerin kameralar aracılığıyla görüntülenerek veri seti oluşturulması amacıyla kullanmışlardır. Bu yöntem, endüstriyel sistemlerin kontrolü, güvenlik sistemleri, kalite kontrol, stok yönetimi, otomasyon sistemleri, otonom hareketli araçlar, tarımsal faaliyetler ve tıbbi uygulamalar gibi farklı alanlarda geniş bir kullanım alanı bulmaktadır.

Kannan ve kumar (2021) yaptığı çalışmada öncelikle talaşlı imalat kalitesini etkileyen ve görüntüsü alınabilen boyut, renk ve sıcaklık gibi faktörler üzerinde yapılan araştırmaları mevcuttur. Talaşlı imalatın ürün kalitesini boyutsal ve yüzeysel olarak etkileyen faktörlerden biri uygun kesici takım seçimidir. Kesici takım seçimi, kalite sorunlarına yol açabileceği gibi işleme parametreleriyle de yakından ilişkili olduğundan otomasyon sistemleriyle de bağlantılıdır. Bu nedenle, uygun kesici takımın seçimi ve tespiti büyük önem taşır. Kesici takım seçiminin görüntü işleme yöntemiyle tespiti, kesici takımın belirlenmiş standartlara uygun olup olmadığının tespit edilmesini içerir. Bu amaçla, görüntülerin elde edilmesi, elde edilen görüntülerin işlenebilir hale getirilmesi ve görüntüdeki nesnelerin boyut ve uzaklık bilgilerinin alınması gibi adımlar uygulanır. Bu konuyla ilgili literatürde farklı alanlarda sabit görüntü üzerinden kalite kontrol ve dinamik görüntü analizi çalışmaları da yer almaktadır. Yapılan çoğu çalışma, talaşlı imalat sonrası ürünlerin kalite kontrolü amacıyla görüntü işleme yöntemlerinin kullanılmasını ele almaktadır.

Xu ve ark. (2019) profil taşlama işlemi için CNC tezgâhta görüntü işleme tabanlı geometrik kontrol çalışması gerçekleştirmişlerdir. İşlem öncesinde tezgâha bir kamera entegre edilmiş ve entegre edilen bu kamera ile iş parçasının görüntüsü kaydedilmiş ve bu görüntüler görüntü işleme yöntemleriyle analiz edilerek profil geometrisi belirlenmiştir. Aynı yöntemle kesici kenarın görüntüsü de kaydedilmiştir. Taşlama esnasında elde edilen görüntüler ile referans görüntüler karşılaştırılmış ve böylece

profilde oluşan hatalar ve kesici kenarın aşınması yorumlanmıştır. Bu değerlendirmeler sonucunda hatayı telafi edici parametreler hesaplanmış ve istenilen profil geometrisi elde edilmiştir.

Lins ve ark. (2020) yapığı bir çalışmada CNC delme tezgahında görüntü işleme yöntemiyle takım aşınmasını belirlemek çalışmışlardır. Bu çalışmada, delme işlemi sırasında takımda meydana gelen aşınma ve bu aşınmanın neden olduğu yüzey form hatalarını önceden tespit etmeyi amaçlayan bir model geliştirilmiştir. ISO 3685 standardına uygun, kesme ağızı üzerindeki aşınma alanının genişliği 0,3 mm'ye kadar olan bir takımın kullanılabileceğı öngörülmüştür. Yapılan bu çalışmada, takımdan alınan görüntülerde kesici ağızda meydana gelen ve düz kenardan sapma şeklinde görülen aşınma bölgeleri tespit edilmiştir. Kenar tespit yöntemi kullanılarak bu bölgelerin genişliği ölçülmüştür. Aşınma genişliği 0,3 mm'ye ulaştığında takım değiştirilerek delme performansı ve yüzey kalitesi artırılmıştır. Bu çalışmalarda frezeleme işleminde görüntü işleme yöntemi kullanılarak takım aşınması araştırılmıştır. İşlem sonucunda mikroskopla alınan aşınma görüntüleri işlenerek takım aşınma alanının büyüklüğü belirlenmiştir. Tekrarlı deneyler yapılarak takım aşınmasının en az olduğu frezeleme parametreleri hesaplanmıştır.

Q.B. Zhang ve Zhao (2013), kaya malzemesinin değişken yükler altındaki dayanımını ve mekanik özelliklerini belirlemek amacıyla dinamik görüntü korelasyonu yöntemini kullanmışlardır. Kaya numunelerine gerilme ölçer sensörler yerleştirilerek yük uygulanmış ve taramalı elektron mikroskopu altında değişkenler incelemişlerdir. Bu yöntemle, gerilime bağılı olarak çatlak ilerleme hızı ve yayılma şekli detaylı olarak incelemişlerdir.

Kesemen ve ark. (2017) yaptıkları çalışmada, malzeme kontrolünde kullanılan çekme deneyinin dinamik görüntü işleme metoduyla modellemesini gerçekleştirmişlerdir. Bu çalışmada, lastik bir malzeme üzerine referans çizgileri çizilerek çekme deneyi gerçekleştirilmiştir. Deney sırasında kaydedilen görüntüler, görüntü işleme yöntemi kullanılarak analiz edilmiştir. Referans çizgilerin bir sonraki aşamasını tahmin etmek için görüntü piksel değerlerinin korelasyonu hesaplanmıştır. Atılan her adımda korelasyon hesaplaması yapılarak çizgi takibi gerçekleştirilmiştir. Bu yöntemle çekme deneyinin sonucunda, lastiğın kopmadan önceki son uzama miktarı hesaplanmıştır.

Zou ve Chen (2018) çalışmalarında, kaynak robotunun dikiş kalitesini incelemek amacıyla dinamik bir görüntü işleme sistemi oluşturmuşlardır. Altı eksenli bir kaynak robotu çalışırken, kaynak noktası lazer kamerasıyla görüntülenmişlerdir. Kaynağın

gerçekleşmesi gereken koordinatlarla kaynağın gerçekleştiği koordinatlar karşılaştırılarak herhangi bir hata düzeltilmiştir. Kaynak noktasının hemen sonrasındaki dikişin boyut ve şekli de görüntü işleme yöntemleri kullanılarak kontrol edilmiştir. Bu sayede kaynak işlemi ve sonrasındaki dikişin kalitesi görsel olarak izlenmiş ve gerektiğinde düzeltilmiştir.

Peng ve ark. (2017), aşındırmaya bağlı makine ömrü belirleme sürecinde, aşınma oranını ve mekanizmasını araştırmak için dinamik görüntü işleme yöntemlerini kullanmışlardır. Çelik bilyelerin metal yüzeyleri aşındırması sırasında oluşan parçacıkların sayısı, dinamik görüntü işleme yöntemleriyle belirlenmiş ve aşınma oranı hesaplanmıştır. Bununla birlikte, parça üzerindeki kalıntılar ve çukurların boyutları, şekilleri ve renkleri de görüntü işleme ile elde edilmiş ve aşınma direnci ile derinlemesine aşınma analizi gerçekleştirilmiştir. Sonuç olarak aşındırma sürecinin görsel analizi yoluyla makine parçalarının ömrünün belirlenmesine ve aşınma mekanizmasının anlaşılmasına katkı sağlamaktadır.

Talaşlı imalat sektöründe görüntü işleme ile ilgili yapılabilecek çalışmalar, diğer alanlara göre daha fazla ayrıntılı veriye ve yakın mesafeden görüntü alma yeteneğine ihtiyaç duymaktadır. Özellikle dinamik görüntü işleme çalışmalarında talaşlı imalat süreçlerinin titreşim, parlama, dönme gibi potansiyel bozucu etkileri, veri elde etme sürecini zorlaştırabilir. Ancak bu olumsuz etkiler teknolojik gelişmeler ve yazılım sistemlerinin iyileşmesiyle çözülmektedir. Bu gelişmelerin hız kazanmasıyla birlikte literatürde talaşlı imalat alanında görüntü işleme metodunun kullanımının artması beklenmektedir. Görüntü işleme teknolojisinin talaşlı imalat alanındaki uygulamaları kalite kontrol, kesici takım izleme, aşınma tespiti ve iş parçası ölçümü gibi birçok alanda verimliliği artırabilir ve üretim süreçlerinin daha hassas ve doğru bir şekilde yönetilmesine yardımcı olabilir.

Literatürdeki bu çalışmalar ışığında talaşlı imalat süreçlerinde kullanılan kesici takımların görüntü işleme yöntemiyle sınıflandırılması ve tespit edilmesi amacını taşımaktadır. Literatürde hali hazırda mevcut olan yöntemlerden farklı olarak bu çalışma talaşlı imalata özgü olan kesici takımların görüntülerini kullanarak yeni bir yaklaşım sunmayı amaçlamaktadır. Bu yöntem kesici takımların ISO standartlarına göre adlandırılmasının sınıflandırılması ve çekilen kesici takım görüntüsünde hangi ISO standart takım gruba dahil olduğunun tespiti amaçlanmıştır.

Bu tür bir çalışma endüstriyel üretimde önemli bir yere sahip olan kesici takımların verimliliğini artırmak ve kaliteyi sağlamak açısından büyük potansiyel

taşımaktadır. Görüntü işleme teknikleri kullanılarak kesici takımların durumu hakkında bilgi elde etmek sürekli izleme ve öngörü yapma yeteneğini artırabilir. Bu da üretim süreçlerinin optimize edilmesi, hataların hızla tespit edilmesi ve üretim maliyetlerinin düşürülmesi gibi avantajlar sağlayabilir.


Sonuç olarak talaşlı imalat alanında kesici takımların görüntü işleme ile sınıflandırılması ve tespit edilmesi amacıyla gerçekleştirilecek bu çalışma endüstriyel uygulamalarda yenilikçi bir yaklaşım sunabilir ve kesici takım teknolojisinin gelişimine katkı sağlayabilir. Bunun yanında kesici takımların farklı özellikleri de tanımlanarak daha ayrıntılı bir kesici takım seçimi yapılabilir.




3. MATERYAL VE YÖNTEM

3.1. Kesici Takım Verilerinin Oluşturulması


Yapılan bu tez çalışmasında ISO (ISO 1832:2017) standartlarına göre sınıflandırılan A, B, C, D, E, R, S, Q vb. sınıflardan toplam 140 (yüz kırk) adet kesici takımın fotoğrafı çekilmesi için internet üzerinden alınan fotoğraflarla bir veri seti bankası oluşturulmuştur. Bu veri seti bankasının oluşturulması için Google Chrome kullanılmıştır. ISO standartlarına göre sınıflandırılan ve bu tez çalışmasında kullanılan bazı kesici takımlardan alınan birer kesitleri Şekil 3.1 ve Şekil 3.2’ de C sınıfı, Şekil 3.3 ve Şekil 3.4’ de D sınıfı, Şekil 3.5 ve Şekil 3.6’ da R sınıfı, Şekil 3.7 ve Şekil 3.8’ de S sınıfı, Şekil 3.9 ve Şekil 3.10’ da T sınıfı, Şekil 3.11 ve Şekil 3.12’ de V sınıfı, Şekil 3.13 ve Şekil 3.14’ de ise W sınıfı kesici takımlar verilmiştir.




Şekil 3. 1. ISO standartlarına göre C sınıfı kesici takımlar (Anonim-15, 2023)




Şekil 3. 2. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı C sınıfı kesici takımların gösterimi (Anonim-15, 2023)



Şekil 3. 3. ISO standartlarına göre D sınıfı kesici takımlar (Anonim-16, 2023)




Şekil 3. 4. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı D sınıfı kesici takımların gösterimi (Anonim-16, 2023)



Şekil 3. 5. ISO standartlarına göre R sınıfı kesici takımlar (Anonim-17, 2023)




Şekil 3. 6. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı R sınıfı kesici takımların gösterimi (Anonim-17, 2023)




Şekil 3. 7. ISO standartlarına göre S sınıfı kesici takımlar (Anonim-18, 2023)




Şekil 3. 8. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı S sınıfı kesici takımların gösterimi (Anonim-18, 2023)



Şekil 3. 9. ISO standartlarına göre T sınıfı kesici takımlar (Anonim-19, 2023)




Şekil 3. 10. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı T sınıfı kesici takımların gösterimi (Anonim-19, 2023)



Şekil 3. 11. ISO standartlarına göre V sınıfı kesici takımlar (Anonim-20, 2023)



Şekil 3. 12. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı V sınıfı kesici takımların gösterimi (Anonim-20, 2023)



Şekil 3. 13. ISO standartlarına göre W sınıfı kesici takımlar (Anonim-21, 2023)



Şekil 3. 14. ISO standartlarına göre sınıflandırılan ve veri setine alınan bazı W sınıfı kesici takımların gösterimi (Anonim-21, 2023)

Kesici takım görüntülerinden elde edilen veri setinden çeşitli ağ yöntemleri ile eğilerek bu kesici takımların eğitimi ve testi yapılmıştır. İlk denemelerde kesici takım

sayılarının az olmasından dolayı gerçekleştirilen eğitim sonuçları genel olarak düşük seviyelerde olduğu gözlemlenmiştir. Bundan dolayı elde edilen veri setinden faydalanarak görüntü sayıları farklı açılarda döndürülerek görüntü sayıları artırılmıştır. Artırılan kesici takım görüntü sayıları CNN, ResNET, LeNET, AlexNET gibi derin öğrenme ağları ile eğitilmiş ve test edilmiştir.

3.2. Elde Edilen Verilerin İşlenmesi

Kesici takımların seçimi için derin öğrenme yöntemi kullanılarak oluşturulan veri seti bankasının eğitimi için Python programı kullanılmıştır. Bu programın geliştirilmesi aşamasında Anaconda sistemi tercih edilmiştir. Verilerin işlenmesi ve modele entegre edilmesi için Tensorflow2 kütüphanesi kullanılarak verilerin işlenmesi sağlanmıştır. Ayrıca bu tez çalışmasında kullanılan bazı programlar aşağıda listelenmiş ve gerekli açıklamalar yapılmıştır.

3.2.1. Python:

Python, genel amaçlı bir programlama dilidir ve kolay okunabilir ve anlaşılabilir sözdizimi ile tanınır. Guido van Rossum tarafından 1980'lerin sonlarında geliştirilmeye başlanan Python, basit ve temiz kod yazımını teşvik etmek amacıyla tasarlanmıştır. Geniş bir standart kütüphane içerir ve çeşitli alanlarda kullanılabilir. Python'un temel özellikleri şunlardır.

- a) Okunabilir ve Anlaşılabilir Sözdizimi:** Python'un sözdizimi, insanlar tarafından kolayca anlaşılabilir bir yapıdadır. Bu, kodun daha hızlı yazılmasını, hataların daha kolay bulunmasını ve iş birliği yapmayı kolaylaştırır.
- b) Çeşitli Kullanım Alanları:** Python, web geliştirme, veri bilimi, yapay zeka, makine öğrenimi, bilimsel hesaplama, otomasyon, oyun geliştirme gibi birçok farklı alanda kullanılabilir. Bu nedenle geniş bir kullanıcı kitlesi bulunmaktadır.
- c) Yüksek Seviyeli Bir Dil:** Python, düşük seviyeli detaylardan uzaklaşarak daha yüksek seviyeli bir soyutlama sağlar. Bu da kodun daha hızlı yazılmasını ve daha az karmaşık olmasını sağlar.
- d) Çapraz Platform Desteği:** Python, farklı işletim sistemlerinde (Windows, MacOS, Linux vb.) sorunsuz bir şekilde çalışabilir.

e) Zengin Kütüphane Desteği: Python'un geniş bir standart kütüphanesi vardır. Ayrıca, üçüncü taraf paketler ve kütüphaneler, farklı görevleri hızla yerine getirmenize yardımcı olur.

d) Topluluk Desteği: Python, büyük ve aktif bir topluluğa sahiptir. Bu topluluk, sorularınıza cevap bulmanız, kaynaklara ulaşmanız ve projelerinizde destek almanız konusunda size yardımcı olabilir.

Python, özellikle öğrenmeye yeni başlayanlar için iyi bir seçenektir çünkü karmaşıklığı azaltarak programlama mantığını anlamalarına yardımcı olur. Aynı zamanda deneyimli geliştiriciler için de güçlü bir araçtır çünkü farklı alanlarda kullanılabilecek geniş bir ekosistem sunar (Anonymous-2, 2023).

3.2.2. Anaconda

Anaconda, veri bilimi ve makine öğrenimi gibi alanlarda kullanılan açık kaynaklı bir Python dağıtımıdır. Temel olarak Python programlama dilinin çeşitli paketlerini, kütüphanelerini ve araçlarını içeren bir platform olarak işlev görür. Veri analizi, bilimsel hesaplama, istatistik, veri görselleştirme, yapay zeka ve makine öğrenimi gibi birçok alanda kullanılır. Anaconda'nın önemli özellikleri şunlardır.

a) Paket yönetimi: Anaconda, birçok popüler Python kütüphanesini önceden yüklenmiş olarak içerir. Bunlar arasında NumPy, Pandas, Matplotlib, SciPy, scikit-learn ve daha birçok önemli kütüphane bulunur. Bu, veri analizi ve bilimsel hesaplamalar gibi görevler için hızlı ve kolay bir başlangıç yapmanızı sağlar.

b) Sanal ortamlar: Anaconda, sanal ortamlar oluşturmaya izin verir. Sanal ortamlar, farklı projeler veya çalışma alanları için izole edilmiş Python ortamlarıdır. Bu, farklı projelerde farklı kütüphane sürümleri veya bağımlılıkları kullanmanızı sağlar.

c) Anaconda navigator: Bu, grafik ara yüze sahip bir yönetim aracıdır. Paketleri yönetmek, ortamlar oluşturmak ve Jupyter Notebook gibi araçları kullanmak için kullanışlı bir ara yüzdür.

d) Jupyter notebook entegrasyonu: Anaconda, Jupyter Notebook'u destekler. Jupyter Notebook, etkileşimli kod yazma, veri analizi yapma, sonuçları görselleştirme ve belgeler oluşturma için kullanılan güçlü bir araçtır.

e) Çapraz platform desteği: Anaconda, Windows, MacOS ve Linux gibi farklı işletim sistemlerinde çalışabilir.

f) Veri Bilimi ve makine öğrenimi için optimize edilmiş: Anaconda, veri bilimi ve makine öğrenimi alanında çalışanlar için optimize edilmiş bir ortamdır. Bu nedenle, bu alanlarda çalışanların gereksinimlerini karşılamak için gerekli kütüphaneler ve araçlar önceden dahil edilmiştir.

Anaconda, veri odaklı projelerde çalışanlar için büyük bir kolaylık ve hız sağlar. Veri analizi, model eğitimi, tahminleme, sınıflandırma, kümeleme gibi birçok veri işleme görevini kolaylaştıran geniş bir ekosisteme sahiptir (Anonmous-3, 2023).

3.2.3. Conda

Conda bir paket, bağımlılık yöneticisi ve sanal çevre oluşturma veya yönetme yazılımıdır. İlk etapta Python için çıkmış olmasına rağmen şu anda Python, R, Ruby, Lua, Scala, Java, JavaScript, C/ C++, FORTRAN gibi dillerin her biri için çalışır ve destekler. Windows, MacOS, ve Linux gibi tüm platformlarda çalışır. Conda hızlı bir şekilde yüklediğimiz paketler/kütüphaneler için yüklenmiş olması gereken (Bağımlılık Yönetimi) paketleri yükler, çalıştırır ve günceller.

Conda pip gibi birtakım kodlarla çalışır ve bu kodlar, Anaconda Navigator yazılımında CMD.exe Prompt adı verilen komut istemcisinde veya PyCharm, VSCode gibi gelişmiş IDE'lerin terminallerinde çalıştırılabilir.

3.2.4. Tensorflow2

TensorFlow2 (TF2), Google tarafından geliştirilen açık kaynaklı bir makine öğrenimi çerçevesidir. TensorFlow, özellikle derin öğrenme ve yapay sinir ağları gibi karmaşık makine öğrenimi modellerinin geliştirilmesi ve dağıtılması için kullanılan bir platformdur. TensorFlow2, TensorFlow'un ikinci büyük sürümüdür ve kullanım kolaylığı, okunabilirlik ve hız gibi konularda önemli geliştirmeler getirmiştir. TensorFlow2'nin özellikleri ve avantajları şunlar.

a) Eklenti desteđi ve kolay kullanım: TensorFlow2, önceki sürümlere kıyasla daha düşük seviyeli ayrıntıları gizler ve daha yüksek seviyeli API'lar sunar. Bu, kullanıcıların daha hızlı ve daha basit kod yazmalarına yardımcı olur.

b) EagerExecution: TensorFlow2'de "EagerExecution" (Hemen Çalıştırma) özelliđi varsayılan olarak etkindir. Bu özellik, hesaplamaların hemen sonuçlarını döndüren etkileşimli bir modda kod yazmanıza olanak tanır.

c) Katkıda bulunma kolaylıđı: TensorFlow2, geliştiricilerin çekirdek kütüphaneye ve ek modüllere daha kolay bir şekilde katkıda bulunmasını sağlayacak şekilde tasarlanmıştır.

d) Kolay model eğitimi ve deđerlendirmesi: Yüksek seviyeli API'lar sayesinde, model eğitimi ve deđerlendirmesi daha hızlı ve daha anlaşılır hale gelir.

e) Entegrasyon ve dağıtım kolaylıđı: TensorFlow2, TensorFlow Serving, TensorFlow Lite ve TensorFlow.js gibi farklı platformlara ve cihazlara modellerin kolayca entegre edilmesini ve dağıtılmasını destekler.

f) Görselleştirme ve hata ayıklama imkanları: TensorFlow2, modelin iç yapısını ve çalışma süreçlerini daha iyi anlamak için görselleştirme ve hata ayıklama araçları sunar.

TensorFlow2, derin öğrenme projeleri geliştirmek isteyen mühendisler, veri bilimciler ve araştırmacılar için güçlü bir araçtır. Hem başlangıç seviyesindeki kullanıcılar için hem de deneyimli makine öğrenimi uzmanları için uygun ve esnek bir platform sunar (Anonim-22, 2023).

3.2.5. Keras

Python program dilinde yazılmış açık kaynaklı bir sinir ağı kütüphanesidir. Hızlı deney yapabilmek için tasarlanan ve herkes tarafından erişimine açık ve sürekli geliştirilebilir bir sinir ağı kütüphanesidir. Ayrıca birçok program ile uyum içerisinde çalışmaktadır. TensorFlow, Microsoft Cognitive Toolkit, Theano, ve PlaidML gibi programlar keras ile uyum içerisinde çalışan programlar arasında yer alır.

3.2.6. Spyder

Spyder, Python programlama dili ile yazılmış ve Python programlamak için kullanılan açık kaynak kodlu bir IDE olup ücretsiz bir şekilde sunulmaktadır. Spyder

arayüzleri ve kullanımı ile rahat bir deneyim sağlar. Gelişmiş bir hata ayıklama ve etkileşimli test özellikleri ile Python dili için güçlü bir geliştirme ortamı sağlar. Ekstra olarak popüler kütüphaneleri sayesinde sayısal bir hesaplama ortamı sağlar. Kullanımı oldukça kolaydır. Otomatik olarak fonksiyonları tamamlar ve işlemlerinizi otomatik olarak renklendirir. Hata yaptığınız bir noktada hatanın altını çizerek ve sebebini anında söyler. Bu özelliklerinden dolayı oldukça pratiklik sağlar.

3.3. Python Kütüphanesi


Derin öğrenme ile kesici takımların sınıflandırılması ve tespitinin analizi için bir Python kütüphanesine ihtiyaç duyulmuştur. Yapılan bu çalışmada paket programlar kullanılmıştır. Kullanılan bu paket programlardan bazıları şunlardır. Numpy, Pandas, Matplotlib, Seaborn, OpenCV, Os, ScikitLearn, Random ve benzeri gibi programlar kullanılmıştır.

3.4. R-CNN Mimarisi ile Görüntü Alanını Belirleme

Bu tez çalışmasında kullanılan görüntüler tam evrişimli ağda R-CNN mimarisi ile segmentasyonu sonucunda eğitilmiştir. Görüntüsü alınan ve Tensorflow2 sistemi yardımıyla Python programına alınan kesici takımdan her kesici takımdan rast gele 6'er adet alınarak yeni bir veri seti oluşturulmuş ve görüntü alanı belirlenmiştir.

3.5. Xception Mimarisi

Xception mimarisi Inception modellerine küçük katkılar yapılarak yeniden inşa edilmiş bir ağ yapısı olarak bilinir ve “Extreme Inception (Aşırı Inception)” olarak da adlandırılabilir. InceptionV3 üzerine eklediği katkı ise evrişim çıkış kanalına tekrardan evrişim işlemi uygulamasıdır. Buda klasik Inception modülünün tamamen eşdeğer bir versiyonudur. Xception modülünde kullanılan bir diğer farklılık ise değiştirilmiş derinlikle ayrılabilir evrişim (modified depthwise convolution) olarak adlandırılır. Şekil 3.18’ de Xception ağının genel yapısı gösterilmiştir.




Şekil 3.18. Xception ağının genel yapısının şematik gösterimi (Chollet, 2017)

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

ISO kodlama sistemine göre sınıflandırılan kesici takımlardan (C, D, R, S, T, V, W) rast gele seçilen ve her bir kesici takımdan 20 adet olmak üzere toplam 140 (yüz kırk) adet kesici takımın fotoğrafı bilgisayar ortamında çekilip kayıt altına alınmıştır. Daha sonra görüntülerin sayısını artırmak için görüntülerin çoğaltılması (augmentation) yapılarak kesici takımların farklı açılarda görüntüleri çoğaltılarak veri sayısı artırılmıştır. Görüntülerin sınıflandırılması için her bir görüntü farklı bir klasörde olacak şekilde kesici takımlar ISO standartlarına göre bu klasörlere yerleştirilmiştir. Görüntülerin işlenmesi ve kodların yazımı için Anconda programı kullanılmıştır. Bu yazılım geliştirmenin altında bulunda “Spyder” bölümünde kodlar yazılmıştır. Çoğaltılan veriler farklı ağ mimarileri ile eğitilmiş ve karmaşıklık matrisi ile doğrulamaları yapılmıştır. Bu çalışmada kullanılan ağ mimarileri ve sonuçları aşağıda sunulmuştur.

4.1. CNN Ağ Mimarisi Sonuçları


CNN ağ mimarisi ile eğitilen kesici takım görüntülerine ait doğruluk değişim grafiği Şekil 4.1’ de verilmiştir.



Şekil 4. 1. CNN ağı ile eğitilmiş doğruluk grafiği


CNN ağ mimarisi ile elde edilen Şekil 4.1’deki grafik incelendiğinde, eğitim ve doğrulama değerlerinin kabul edilebilir bir aralıkta olduğu görülmektedir. Grafikten anlaşılaçağı üzere eğitim ve doğrulama değerleri 0,7 ve 1 aralığındaki değerlerde bir değişimi göstermektedir. Eğitilen kesici takım görüntülerinin test sonucu 0,9113

değerindedir. Bu değer kabul edilebilir bir aralıktadır. CNN mimarisi ile elde edilen hata oranlarını gösteren grafik Şekil 4.2’ de verilmiştir.



Şekil 4. 2. CNN ağı ile eğitilmiş doğruluk grafiği

Şekil 4.2’ deki CNN hata değişimini gösteren grafiğine bakıldığında eğitim verileri düşük bir değerde iken doğrulama değerleri hata oranları değişimi daha yüksek bir aralıkta olduğu görülmektedir. Bu ağ mimarisi ile eğitilen kesici takımların hata oranları değeri ise 0,4935 olarak tespit edilmiştir. CNN ağının kesici takımları ne doğrultuda tahmin ettiğini gösteren bir diğer grafik ise Şekil 4.3’ deki karmaşıklık matrisinde verilmiştir.



Şekil 4. 3. CNN karmaşıklık matrisi

Şekil 4.3' teki karmaşıklık grafiği incelendiğinde, her 7 kesici takımın tahmin sonuçlarında hata oranları oluşmuştur. Bu ağın kesici takım geometrilerini doğru olarak tahmin etmediği ve birçok şekli birbirine karıştırmış olduğu sonucuna varılabilir. Karmaşıklık test sonuçları değerleri ise aşağıdaki sınıflandırma raporu olarak Çizelge 4.1' de verilmiştir.


Çizelge 4. 1. CNN sınıflandırma raporu

Kesici Takım	Precision	Recall	F1-score	Support
CNMG	0,89	0,82	0,85	57
DNMG	0,90	0,86	0,88	81
RNMG	0,89	0,99	0,94	67
SNMG	0,90	0,91	0,91	81
TNMG	0,93	0,94	0,94	69
VNMG	0,96	0,93	0,95	74
WNMG	0,91	0,91	0,91	67

Çizelge 4.1' deki değerler incelendiğinde f1-score değerinin precision ve recall değerlerinin ağırlıklı ortalamalarına eşit olduğu bilinmektedir. Precision kesici takımların tahmin değerini vermektedir. Recall değeri karmaşıklık matrisindeki pozitif olarak tahmin edilen değeri ifade etmektedir. Karmaşıklık tablosu sınıflandırma raporunda en iyi tahminleri VNMG kesici takımında olduğu görülmektedir. En kötü tahmini ise CNMG kesici takıma ait olduğu görülmektedir. CNMG değerinin diğerlerine göre daha düşük değerlerde çıkmasının sebebi CNMG kesici takım geometrisinin SNMG ve DNMG kesici takım geometrilerine benzer olmasından kaynaklandığı düşünülmektedir.


4.2. Xception Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti

ISO standartlarına göre referans alınan görüntüler Xception ağ mimarisi ile eğitilmiştir. Bu modelden elde edilen kesici takım verilerinden elde edilen tahmin sonuçlarına ait grafik Şekil 4.4' te verilmiştir.




Şekil 4. 4. Xception mimarisi ile eğitimi ve doğrulama

Şekil 4.4’ deki grafik incelendiğinde mavi çizgi eğitim (train) turuncu renkli çizgi ise doğrulama (validation) çizgisini göstermektedir. Eğitilen verilen verilerin 0,95 üstü olduğu ve büyük bir çoğunluğun 0,99 aralığında olduğu görülmektedir. Bu da derin öğrenme yöntemi ile eğitilen kesici takımların yüksek başarı oranında tahminler yaptığı ve endüstriyel uygulamalarda kullanıma uygun olduğunu göstermektedir. Aynı şekilde doğrulama deneyleri sonuçlarının da aynı değer aralığında yani 0,99 olduğu görülmektedir. Xception ağ mimarisi ise eğitilen kesici takım görüntülerinin test sonucu 0,9913 değerindedir. Doğrulama deneyleri ile de sonuçların güvenilirliği test edilmiş ve kesici takımların ISO standartlarına göre seçiminin başarılı olduğu sonucuna varılmıştır. Eğitilen resimlerin hata oranlarını gösteren grafik Şekil 4.5’ te verilmiştir.



Şekil 4. 5. Xception hata değişimi gösterimi


Şekil 4.5’ teki kayıp değişimi ya da başka bir ifade ile hata miktarlarını gösteren grafik incelendiğinde mavi çizgi eğitim iken turuncu çizgi ise doğrulama kayıp miktarlarını göstermektedir. Grafiğin değerlendirilmesinde hata oranları ne kadar düşükse gerçekleştirilen ağ mimarisi ve elde edilen tahmin sonuçlarının o kadar başarılı olduğu bilinmektedir. Kayıp miktarlarının hem eğitim hem de doğrulama değerlerinde çok düşük olduğu görülmektedir. Kayıp değeri 0,02069 olarak elde edilmiştir. Bu da kesici takımların sınıflandırılmasında ve seçiminde doğru bir derin öğrenme yöntemi ile kesici takımların tahmini yapılacağını göstermektedir. Sonuç olarak ISO standartları geometrik şekillerine göre sınıflandırılan ve eğitilen kesici takımların tam otomasyon sistemlerine geçerek CNC torna tezgahlarında kullanılmasına imkân sunmaktadır. ISO standartlarına göre sınıflandırılan kesici takımların gösterimini ve tahmin sonuçlarını gösteren karmaşıklık tablosu Şekil 4.6’ da verilmiştir.



Şekil 4. 6. Xception karmaşıklık matrisi

Şekil 4.6’ da gerçek ve tahmini etiketlere göre tahmin edilen kesici takım geometrilerinin tablosu incelendiğinde, gerçek değerlerin çok yüksek sayılarda ve doğruluk oranlarında tahmin edildiği açık bir şekilde görülmektedir. Fakat CNMG insert adlı kesici takım ile SNMG insert adlı kesici takım tahminlerinde bir karışıklık olmuş olup bu da 3 adet olarak gerçekleşmiştir. CNMG ve SNMG takım geometrileri birbirine oldukça yakın geometrilerde olduğundan dolayı bu hatanın gerçekleşmiş olduğu

düşünülmektedir. Bu karışıklığa sebep olan kesici takımların gösterimine örnek aşağıda verilmiştir.



Şekil 4. 7. SNMG ve CNMG kesici takımların geometrisi

Çizelge 4. 2. Xception sınıflandırma raporu


Kesici Takım	Precision	Recall	F1-score	Support
CNMG	0,98	0,95	0,96	57
DNMG	1	1	1	81
RNMG	1	1	1	67
SNMG	0,96	0,99	0,98	81
TNMG	1	1	1	69
VNMG	1	1	1	74
WNMG	1	1	1	67

Çizelge 4.2’ deki grafik sonuçlarına göre SNMG ve CNMG kesici takımlara ait değerlerin birbirine karıştırıldığı için bu değerler çıktığı söylenebilir. Sınıflandırma raporu sonucuna göre en düşük tahmini CNMG ve ardından CNMG kesici uça ait olduğu görülmektedir.

4.3. ResNet Ağ Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti


Farklı geometrik şekillere göre sınıflandırılan kesici takımların görüntülerinden elde edile veriler ile ResNet ağ mimarisi ile eğitilen kesici takımlara ait eğitim, doğrulama ve karmaşıklık matrisi test sonuçları sunulmuştur. ResNet ağ mimarisi ile elde edilen

kesici takım verilerinden elde edilen tahmin sonuçlarına ait grafik Şekil 4.8' de verilmiştir.




Şekil 4. 8. ResNet mimarisi ile eğitimi ve doğrulama

Şekil 4.8' deki grafikte yer alan eğitim ve doğrulama çizgileri bize sonuçların hangi aralıkta yer aldığını göstermektedir. Mavi çizgi eğitim (train) turuncu renkli çizgi ise doğrulama (validation) çizgisini ifade etmektedir. ResNet ağ mimarisi ile eğitilen verilen pekte iyi olduğu söylenemez. Eğitimin gerçekleşmediği ya da programın kesici takım şekillerini algılayamadığı için burada yer alan eğitim ve doğrulama sonuçlarının kötü çıktığı düşünülmektedir. ResNet ağ mimarisi ile eğitilen kesici takım görüntülerinin test sonucu 0,135 değerindedir. Bu değer eğitimin tam olarak yapılamadığını göstermektedir. Eğitilen resimlerin hata oranlarını gösteren grafik Şekil 4.9' de verilmiştir.



Şekil 4. 9. ResNet hata değişimi gösterimi

Şekil 4.9’ da kayıp değişimi ya da başka bir ifade ile hata miktarlarını gösteren grafik incelendiğinde hata oranları ne kadar düşükse gerçekleştirilen ağ mimarisi ve elde edilen tahmin sonuçlarının o kadar başarılı olduğunu göstermektedir. Eğitilen ağın kayıp değeri 1,9444 olarak elde edilmiştir. Eğitim kayıp miktarlarının çok yüksek olduğu görülmektedir. Bu durum kesici takımların büyük bir bölümünün eğitime girmeden atladığını göstermektedir. Bu da kesici takımların sınıflandırılmasında ve seçiminde ResNet derin öğrenme yöntemi ile kesici takımların tahmini çokta iyi sonuçlar vermediğini göstermektedir. ResNet ağ mimarisi ile eğitilen ve ISO standartlarına göre sınıflandırılan kesici takımların gösterimini ve tahmin sonuçlarını gösteren karmaşıklık tablosu Şekil 4.10’ da verilmiştir.



Şekil 4. 10. ResNet karmaşıklık matrisi

Şekil 4.10’ da gerçek ve tahmini etiketlere göre tahmin edilen kesici takım geometrilerinin tablosu incelendiğinde, gerçek değerlerin pekte tahmin edilemediği görülmektedir. Gerçek ve tahmin edilen kesici takım görüntülerinin birbirini karşılamamakta sadece RNMG kesici takım görüntülerinin doğru bir şekilde tahmin edildiği görülmektedir. Sınıflandırma raporu değerleri de Çizelge 4.3’ te verilmiştir.


Çizelge 4. 3. ResNet sınıflandırma raporu

Kesici Takım	Precision	Recall	F1-score	Support
CNMG	0	0	0	57
DNMG	0	0	0	81
RNMG	0,14	1	0,24	67
SNMG	0	0,99	0,98	81
TNMG	0	0	0	69
VNMG	0	0	0	74
WNMG	0	0	0	67

Çizelge 4.3’ teki grafik sonuçlarına göre RNMG kesici uç hariç diğer kesici takım görüntülerinin tahminin yapılamadığı söylenebilir.

4.4. LeNet Ağ Mimarisi Sonuçları


LeNet ağ mimarisi ile eğitilen kesici takımlara ait görüntülerden elde edilen doğruluk değişim grafiği Şekil 4.11’ de verilmiştir.



Şekil 4. 11. LeNet ağı ile eğitilmiş doğruluk grafiği


LeNet ağ mimarisi ile elde edilen Şekil 4.11’ deki grafiğe bakıldığında eğitim ve doğrulama değerlerinin çokta kabul edilebilir bir aralıkta olmadığı görülmektedir. Eğitim ve doğrulama çizgilerinin birbirinden uzak olduğu ve 0,9 ile 1 aralıklarında uzak olduğu görülmektedir. LeNet ile eğitilen kesici takım görüntülerinin test sonucu 0,6069 değerindedir. Bu değer eğitilen kesici takım görüntülerinin yaklaşık olarak %61

değerinde başarılı bir şekilde eğitildiğini ve doğrulandığını göstermektedir. Hata oranlarını gösteren grafik ise Şekil 4.12’ de verilmiştir.



Şekil 4. 12. LeNet hata değişimi

Şekil 4.12’ deki LeNet hata değişimini gösteren grafik incelendiğinde hem eğitim hem de doğrulama hata değerlerinin değişiminin yüzdesel olarak %40 yakın bir aralıkta olduğu görülmektedir. Bu durum, LeNet ağına kesici takımları tahmin etmede başarılı olmadığını göstermektedir. Eğitilen kesici takımların kayıp değerinin ise 2,2271 olarak tespit edilmiştir. LeNet mimarisinin kesici takımları ne doğrultuda tahmin ettiğini gösteren bir diğer grafik ise Şekil 4.13’ deki karmaşıklık matrisinde verilmiştir.



Şekil 4. 13. LeNet karmaşıklık matrisi

Şekil 4.13’ teki karmaşıklık grafiği incelendiğinde her 7 kesici takımın tahmin sonuçlarında hata oranları oluşmuştur. Bu ağına kesici takım geometrilerini doğru olarak

tahmin etmediği ve birçok şekli birbirine karıştırmış olduğu sonucuna varılabilir. Karmaşıklık test sonuçları değerleri ise aşağıdaki sınıflandırma raporu olarak Çizelge 4.4’ te verilmiştir.


Çizelge 4. 4. LeNet sınıflandırma raporu

Kesici Takım	Precision	Recall	F1-score	Support
CNMG	0,51	0,44	0,47	57
DNMG	0,65	0,62	0,63	81
RNMG	0,59	0,82	0,69	67
SNMG	0,65	0,57	0,61	81
TNMG	0,57	0,65	0,61	69
VNMG	0,69	0,55	0,62	74
WNMG	0,57	0,58	0,58	67

Çizelge 4.4’ teki değerler incelendiğinde LeNet karmaşıklık tablosu sınıflandırma raporunda en iyi tahminleri RNMG kesici takımda olduğu görülmektedir. En kötü tahmini ise CNMG kesici takıma ait olduğu görülmektedir. Diğer kesici takım tahmin değerlerinin birbirine yakın olduğu da ayrıca görülmektedir.


4.5. AlexNet Ağ Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti

ISO standartlarına göre referans alınan kesici takım görüntüleri AlexNet ağ mimarisi ile eğitilmiştir. Bu modelden elde edilen kesici takım verilerinden elde edilen tahmin sonuçlarına ait grafik Şekil 4.14’ te verilmiştir.




Şekil 4. 14. AlexNet mimarisi ile eğitimi ve doğrulama

Şekil 4.14’ teki grafik AlexNet ile eğitilen verilerin 0,95 üstü olduğu ve büyük bir çoğunluğun 0,99 aralığında olduğu görülmektedir. Bu da AlexNet derin öğrenme yöntemi ile eğitilen kesici takımların yüksek başarı oranında tahminler yaptığı ve endüstriyel uygulamalarda kullanıma uygun olduğunu göstermektedir. Aynı şekilde doğrulama deneyleri sonuçlarının da aynı değer aralığında yani 0,99 olduğu görülmektedir. AlexNet ağ mimarisi eğitilen kesici takım görüntülerinin test sonucu 0,9758 değerindedir. Doğrulama deneyleri ile de sonuçların güvenilirliği test edilmiş ve kesici takımların ISO standartlarına göre seçimi başarılı olduğu sonucuna varılmıştır. Bu ağ mimarisi bir diğer yüksek oranda tahminlerde bulunan Xception ağ mimarisi gibi yüksek oranlarda başarı sağlamıştır. Eğitilen kesici takım görüntülerinin kayıp oranlarını gösteren grafik Şekil 4.15’ te verilmiştir.




Şekil 4. 15. AlexNet hata değişimi gösterimi

Şekil 4.15’ teki kayıp değişimini veren grafik incelendiğinde mavi çizgi eğitim iken turuncu çizgi ise doğrulama kayıp miktarlarını göstermektedir. Grafiğin değerlendirilmesinde hata oranları ne kadar düşükse gerçekleştirilen ağ mimarisi ve elde edilen tahmin sonuçlarının o kadar başarılı olduğunu göstermektedir. Kayıp miktarlarının hem eğitim hem de doğrulama değerlerinde çok düşük olduğu görülmektedir. AlexNet ile eğitilen kesici takımların kayıp değerinin ise 0,1402 olarak tespit edilmiştir. AlexNet ile kesici takım görüntülerinin ISO standartlarına göre sınıflandırılan karmaşıklık matrisi gösterimi ve tahmin sonuçları tablosu Şekil 4.16’ te verilmiştir.



Şekil 4.16. AlexNet karmaşıklık matrisi

Şekil 4.16’ deki gerçek ve tahmini edilen kesici takım geometrilerine göre tahmin verilen tablo incelendiğinde, gerçek değerlerin çok yüksek sayılarda ve doğruluk oranlarında tahmin edildiği açık bir şekilde görülmektedir. Ancak CNMG adlı kesici takım ile SNMG adlı kesici takım tahminlerinde bir karmaşıklık olmuş olup bu da 6 adet olarak gerçekleşmiştir. CNMG ve SNMG takım geometrileri birbirine oldukça yakın geometrilerde olduğundan dolayı bu hatanın gerçekleşmiş olduğu düşünülmektedir. Ayrıca birkaç kesici uç takımında da karmaşıklık oluşmuştur. Bu durum test sonucunun bir miktar düşük çıkmasına sebebiyet vermiştir. Benzer şekilde bu karmaşıklığa sebep olan CNMG ve SNMG kesici takımların gösterimine örnek aşağıda Şekil 4.17’ de verilmiştir.



Şekil 4.17. CNMG ve SNMG insertlerin karşılaştırılması


Çizelge 4. 5. AlexNet sınıflandırma raporu

Kesici Takım	Precision	Recall	F1-score	Support
CNMG	0,96	0,89	0,93	57
DNMG	1	0,96	0,98	81
RNMG	1	1	1	67
SNMG	0,96	0,98	0,95	81
TNMG	0,99	0,99	0,99	69
VNMG	0,99	1	0,99	74
WNMG	0,97	1	0,99	67

Çizelge 4.5’ teki grafik sonuçlarına göre en iyi tahmin sonuçlarının RNMG kesici takım iken en kötü tahmin sonuçları CNMG kesici takıma ait olduğu anlaşılmaktadır. Geriye kalan kesici takımlarda yüksek güven aralığında çok az miktarda hata yapılarak tahmin edilmiştir. Söz konusu bu durum AlexNet ağ mimarisinin de kesici takımların geometrik olarak tespitinde ve sınıflandırılmasında güvenli bir şekilde kullanabileceğini göstermektedir.


4.6. GoogleNet Ağ Mimarisi ile Kesici Takımların Sınıflandırılması ve Tespiti

Farklı geometrik şekillere göre sınıflandırılan kesici takımlara ait görüntülerden elde edile veriler GoogleNet ağ mimarisi ile eğitim, doğrulama ve karmaşıklık matrisi test sonuçları aşağıda verilmiştir. GoogleNet mimarisi ile eğitilen ve doğrulanan kesici takım görüntülerinden elde edilen tahmin sonuçlarına ait grafik Şekil 4.18’ de verilmiştir.




Şekil 4. 16. GoogleNet mimarisi ile eğitimi ve doğrulama

Şekil 4.18’ deki grafik incelendiğinde mavi çizgi eğitim (train) turuncu renkli çizgi ise doğrulama (validation) çizgisini ifade ettiği görülmektedir. Grafiğe bakıldığında GoogleNet ağ mimarisi ile eğitilen verilen pekte iyi olduğu söylenemez. Eğitimin gerçekleşmediği ya da programın kesici takım şekillerini algılayamadığı için burada yer alan eğitim ve doğrulama sonuçlarının kötü çıktığı düşünülmektedir. Bu doğrultuda GoogleNet ağ mimarisi ile eğitilen kesici takım görüntülerinin test sonucu 0,1351 değerindedir. Bu değer eğitimin tam olarak yapılamadığını göstermektedir. Bu ağ mimarisi ile eğitilen resimlerin kayıp oranlarını gösteren grafik Şekil 4.19’da verilmiştir.



Şekil 4. 179. GoogleNet hata değişimi gösterimi

Şekil 4.19’ deki kayıp değişimi ya da başka bir ifade ile hata miktarlarını gösteren grafiğe bakıldığında hata oranları ne kadar düşükse gerçekleştirilen ağ mimarisi ve elde edilen tahmin sonuçlarının o kadar başarılı olduğunu göstermektedir. Eğitim kayıp miktarlarının çok yüksek olduğu görülmektedir. Bu durum kesici takımların büyük bir bölümünün eğitime girmeden atladığını göstermektedir. Bu da kesici takımların sınıflandırılmasında ve seçiminde GoogleNet derin öğrenme yöntemi ile kesici takımların tahmini çokta iyi sonuçlar vermediğini göstermektedir. GoogleNet ağ mimarisi ile eğitilen ve ISO standartlarına göre sınıflandırılan kesici takımların gösterimini ve tahmin sonuçlarını gösteren karmaşıklık tablosu Şekil 4.20’ de verilmiştir.



Şekil 4. 18. GoogleNet karmaşıklık matrisi

Şekil 4.20’ deki gerçek ve tahmini etiketlere göre tahmin edilen kesici takım geometrilerinin tablosu incelendiğinde, gerçek değerlerin pekte tahmin edilemediği görülmektedir. Gerçek ve tahmin edilen kesici takım görüntülerinin birbirini karşılamamakta sadece RNMG kesici takım görüntülerinin doğru bir şekilde tahmin edildiği Şekil 4.20’ deki üçüncü sütunda görülmektedir. GoogleNet mimarisi ile elde edilen sınıflandırma raporu değerleri Çizelge 4.6’ da verilmiştir.

Çizelge 4. 6. GoogleNet sınıflandırma raporu

Kesici Takım	Precision	Recall	F1-score	Support
CNMG	0	0	0	57
DNMG	0	0	0	81
RNMG	0,14	1	0,24	67
SNMG	0	0	0	81
TNMG	0	0	0	69
VNMG	0	0	0	74
WNMG	0	0	0	67

Çizelge 4.6’ deki sonuçlarına göre RNMG kesici uç hariç diğer kesici takım görüntülerinin tahminin yapılamadığı söylenebilir. Çünkü eğitilen ağ mimarisinde test edilen diğer görüntü sayılarının sıfır olduğu görülmektedir. Gerçek ve tahmin değerlerin RNMG kesici uç hariç birbiri ile örtüşmediği anlaşılmaktadır.

5. SONUÇ VE ÖNERİLER

5.1. Sonuçlar

Bu tez çalışmasında torna tezgahlarında kullanılan ve ISO standartlarına göre gruplara ayrılan kesici takımların görüntüleri geometrik şekillerine göre sınıflandırılmış ve CNN, Xception, ResNet, LeNet, AlexNet ve GoogleNet ağ mimarileri ile kesici takım görüntüleri eğitilmiş, test edilmiş ve doğrulamaları yapılmıştır. Derin öğrenme yöntemleri ile eğitilen kesici takım görüntülerinden elde edilen sonuçlar aşağıdaki şekilde özetlenebilir.

Kesici takımların görüntüleri ISO standardında yer alan kodlara göre (C, R, S, Q vb) göre sınıflandırılmış ve görüntülerin tahmini de buna göre yapılmıştır. Bu ağ mimarilerinde en iyi sonuçları veren Xception, CNN ve AlexNet olduğu görülmüştür. ResNet, LeNet ve GoogleNet ile eğitilen görüntülerin başarı oranının düşük olduğu sonucuna varılmıştır.

- Kesici takım görüntüleri CNN, Xception, ResNet, LeNet, AlexNet ve GoogleNet ağ mimarileri ile eğitilerek elde edilen kesici takım görüntülerinin doğrulama değerleri sırasıyla %91, %99, %13, %60, %97 ve %13 olarak elde edilmiştir. Burada başarılı sonuçlar elde edilen ağ mimarileri olmuştur.
- En iyi ağ mimarisi Xception %99 oranında yüksek başarı düzeyinde torna kesici takımlarının görüntülerini ISO standartlarına göre başarılı bir şekilde tahmin ettiği sonucuna ulaşılmıştır. Aynı zamanda %0,2069 kayıp oranında kesici takım görüntülerini test edilmiştir.
- En kötü tahminleri yapan Resnet ve GoogleNet ağ mimarileri olduğu %13 doğruluk oranında kesici takım görüntülerini tahmin etmişlerdir. Bu derin öğrenme yöntemleri veri sayısının az olması ve daha karmaşık görüntülerde daha başarılı olduğu sonucuna varılmıştır.

- Sonuç olarak kesici takımların görüntülerinde geliştirilen ve eğitilen derin öğrenme tornalamada ne tür bir kesici takım kullanıldığı tahmin eden ve işleme yöntemine göre sınıflandırılan bir yöntem geliştirilmiştir.
- Geliştirilen bu görüntü işleme yöntemi ile kesici takımların farklı özellikleri kullanarak sınıflandırılması ve otomasyon sistemlerinde etkin bir şekilde kullanılarak gün geçtikçe daha da dijitalleşen sanayi sektörüne katkıda bulunulacaktır.

5.2. Öneriler

Yapılan bu tez çalışması sonucunda elde edilen veriler ışığında aşağıda çalışma alanları ve endüstriyel uygulamalarda faydalı olabileceği düşünülen konular sırayla önerilmiştir.

- Talaşlı imalat yönteminde talaş kaldırma işlemi sonucunda malzemeden koparılarak ortaya çıkan talaşların görüntüleri derin öğrenme yöntemleri kullanarak sınıflandırılabilir.
- Kesici takımlarda bulunan talaş kırıcı formların derin öğrenme yöntemi kullanılarak sınıflandırılabilir.
- Derin öğrenme yöntemi ile talaşlı imalat işlemi sırasında kullanılan kesici takımlarda meydana gelen kusurlar tespit edilebilir.

Anonim-21, 2023, Wnmng İnsert, [online], https://www.google.com/search?q=Wnmng+insert&tbm=isch&ved=2ahUKEwj8tISDrN-AAxXVNOwKHx85BnYQ2-cCegQIABAA&oq=Wnmng+insert&gs_lcp=CgNpbWcQAzIECCMQJzIHCAAQExCABDIHCAAQExCABDIHCAAQExCABDIHCAAQExCABFDTDfiOEWCbGWgAcAB4AIABoAGIAcUDkgEDMC4zmAEAoAEBqgELZ3dzLXdpei1pbWfAAQE&sclient=img&ei=nMrbZPz2ONXpsAf_8piwBw&bih=835&biw=1536&rlz=1C1YTUH_trTR1069TR1069 [Ziyaret Tarihi: 09 Ağustos 2023].

Anonim-22, 2023, TensorFlow2 ile Derin Öğrenme, [online], <https://tirendazakademi.medium.com/tensorflow-2-ile-derin-%C3%B6%C4%9Frenmeye-giri%C5%9F-a1cb466a473c> [Ziyaret Tarihi: 10.08.2023].

Anonymous-1, 2023, Google SemanticSegmentation Network DeepLab v3 plusdesignideasandarchitecture, [online], Programmer Sought, <https://programmersought.com/article/67484433091/> [Ziyaret Tarihi: 01 Şubat 2023].

Anonymous-2, 2023, What is Python? – What is Python UsedFor? [online], <https://codingcompiler.com/what-is-python/> [Ziyaret Tarihi: 10 Ağustos 2023].

Anonymous-3, 2023, Anaconda (Python Distribution), [online], [https://en.wikipedia.org/wiki/Anaconda_\(Python_distribution\)#:~:text=Anaconda%20is%20a%20distribution%20of,and%20Travis%20Oliphant%20in%202012](https://en.wikipedia.org/wiki/Anaconda_(Python_distribution)#:~:text=Anaconda%20is%20a%20distribution%20of,and%20Travis%20Oliphant%20in%202012) [Ziyaret Tarihi: 10 Ağustos 2023].

Atılğan, Ç., 2019, Yüz İfadelerine Göre Otomatik Duygu Tespiti, Yüksek Lisans Tezi, *Fırat Üniversitesi, Fen Bilimleri Enstitüsü*.

Askeland, D.R. ve Plule, P.P., 2006, The Science and Engineering of Materials, Fifth Edition, Thomson Canada Limited.

Aydın, Şamil Emre 2017. *Yapay Zekâ Teknolojisi (Yapay Zekâların Dünyü Bugünü Yarını)*. s. 12-13.

Benhabib, B., 2003, Manufacturing, Design, Production, Automationand Integration, University of Toronto, Marcel DekkerInc., ISBN: 0-8247-4273-7, Ontario, Canada.

Bora, D. J., 2017, Importance of imageenhancementtechniques in colorimagesegmentation: A comprehensiveandcomparativestudy, arXivpreprint arXiv:1708.05081.

Byrne, G., Dornfeld, D. ve Denkena, B., 2003, “Advancing Cutting Technology”, CIRP Annals – Manufacturing Technology, 52 (2): 483-507.

Choy, K.L. ve Felix, E., 2000, “FunctionallyGradedDiamond-Like Carbon Coatings on Metallic Substrates”, Materials Science and Engineering A, (278): 162–169.

Chollet, F. 2017. Xception: Deep learning with depthwise separable convolutions. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition1251-1258.

Coşkun, M., Yıldırım, Ö., Uçar, A. ve Demir, Y., 2017, An overview of popular deep learning methods, *European Journal of Technique (EJT)*, 7(2), 165-176.

Çakır, M.C., 2006, Modern Talaşlı İmalatın Esasları, Nobel Yayınları, Ankara.

Çağlar, O.. 2022, Aktivasyon Fonksiyonu Nedir? [online], <https://www.elektrikport.com/haber-roportaj/aktivasyon-fonksiyonu-nedir/23511#ad-image-0> [Ziyaret Tarihi: 03 Şubat 2023].

Çıtlak, A., ve Demirpolat, A. B., 2021, Effects of Different Turbulators on Heat Transfer in Smoke Tube Boilers and Modeling of These Effects with Machine Learning Algorithms. *Journal of the Institute of Science and Technology*, 11(1), 474-489.

Demircioğlu, P., Böğrekçi, İ., Çerçi, Y., ve Durakbaşı, M. N., 2013, Kesici Takım Endüstrisinde Mühendislik Uygulamaları ile Mikro/Nanoteknolojinin Termal ve Görüntü İşleme ile Analizi. https://www.mmo.org.tr/sites/default/files/95db6151c06bc78_ek.pdf [Ziyaret Tarihi: 11 Ağustos 2023].

Denil, M., Shakibi, B., Dinh, L., Ranzato, M. A., ve De Freitas, N., 2013, Predicting parameters in deep learning, *Advances in neural information processing systems*, 26.

Degarmo, E. P., Black, J.T. ve Kohser, R.A., 2006, Materials and Processes in Manufacturing, Ninth Edition, ISBN:0-471-65653-4, Wiley Inc.

Egmont-Petersen, M., de Ridder, D., ve Handels, H., 2002, Image processing with neural networks—a review. *Pattern recognition*, 35(10), 2279-2301.

Erickson, B. J., Korfiatis, P., Akkus, Z., Kline, T., ve Philbrick, K., 2017, Toolkits and libraries for deep learning, *Journal of digital imaging*, 30(4), 400-405.

Esmeray, F., 2014, Açık Kaynak Kodlu Görüntü İşleme Uygulamaları, Yüksek Lisans Tezi, *Fırat Üniversitesi, Fen Bilimleri Enstitüsü*.

Fitzsimmons, M. ve Sarin, V.K., 2001, “Development of CVD WC-Co Coatings”, *Surface and Coatings Technology*, (137): 158-163,

Grzesik, W., January 2008, *Advanced Machining Processes of Metallic Materials*, Elsevier, ISBN: 0-08-044534-9

İnik, Ö. ve Ülker E., 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, C. 6, Sayı 3, 85-104.

Ibtehaz, N., ve Rahman, M. S., 2020, MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical images segmentation, *Neural Networks*, 121, 74-87.

Jinsakul, N., Tsai, C. F., Tsai, C. E., ve Wu, P., 2019, Enhancement of deep learning in image classification performance using exception with the sigmoid activation function for colorectal polyp preliminary screening, *Mathematics*, 7(12), 1170.

Kamilaris, A., ve Prenafeta-Boldú, F. X., 2018, Deep learning in agriculture: A survey, *Computers and electronics in agriculture*, 147, 70-90.

Kannan, A., ve Kumar, S., 2021, *Fault Detection of Mechanical Components Using Image Processing*.

Kashtalyan, M. ve Menshykova, M., 2006, “Three-dimensional Elastic Deformation of a Functionally Graded Coating/Substrate System”, *International Journal of Solids and Structures*, Elsevier

Kesemen, O., Tezel, O., Ozkul, E., ve Kesim, M., 2017, Dinamik Görüntülerde Mikro Değişimlerin Gerçek Zamanlı Ölçülmesi. *2017 25th Signal Processing and Communications Applications Conference, SIU 2017*. <https://doi.org/10.1109/SIU.2017.796054> [Ziyaret Tarihi: 11 Ağustos 2023].

Kızrak, A.. 2019, Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması [online], <https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd> [Ziyaret Tarihi: 03 Şubat 2023].

Kour, A., Yadav, V.K. et al, 2020, A Review on Image Processing Techniques, *International Journal of Electronics Communication and Computer Engineering*, C. 4, Sayı 1, 270–275.

Lins, R. G., Guerreiro, B., Marques De Araujo, P. R., & Schmitt, R., 2020, In-process tool wear measurement system based on image analysis for CNC drilling machines. *IEEE Transactions on Instrumentation and Measurement*, 69(8), 5579–5588.

Lin, Z., ve Guo, W., 2020, Sorghum panicle detection and counting using unmanned aerial system images and deep learning. *Frontiers in Plant Science*, 11, 1346.

Lu, W., Du, R., Niu, P., Xing, G., Luo, H., Deng, Y., ve Shu, L., 2022, Soybean Yield Preharvest Prediction Based on Bean Pods and Leaves Image Recognition Using Deep Learning Neural Network Combined With GRNN, *Frontiers in Plant Science*, 12, 791256.

MEGEP, Makine Teknolojisi, 2006, CNC Tezgahlar ve Kesici Takımlar, Ankara

Ngo, T., 2021, Deep Learning for Wireless Signal Parameter Predictions (Doctoral dissertation).

Nwankpa, C., Ijomah, W., Gachagan, A., ve Marshall, S., 2018, Activation functions: Comparison of trends in practice and research for deep learning.

Ozdemir, O., İpek, M. ve Zeytin, S., Ağustos 2000, “Kesici Takım Malzemeleri” MMO Muhendis ve Makine, 41 (487)

Peng, Y., Wu, T., Wang, S., ve Peng, Z., 2017, Wearstateidentificationusingdynamicfeatures of weardebrisfor on-linepurpose. *Wear*, 376–377, 1885–1891.

Savaş, S., 2020, Derin Öğrenme Algoritmaları, [online], <https://medium.com/yapay-zeka-makine-%C3%B6%C4%9Frenmesi-derin-%C3%B6%C4%9Frenme/derin-%C3%B6%C4%9Frenme-algoritmalar%C4%B1-8dea99d9b41f> [Ziyaret Tarihi: 09 Şubat 2023].

Schey, J.A., 1987, Introductionto ManufacturingProcesses, Second Edition, McGraw-HillBookComp., New York, 472-477.

Sharma, S., Sharma, S., ve Athaiya, A., 2017, Activation functions in neural networks, *Towards Data Science*, 6(12), 310-316.

Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., ve Stefanovic, D., 2016, Deep neural Networks based recognition of plantdiseasesbyleafimage, *classification, Computationalintelligenceandneuroscience*.

Soother, D. K., Daudpoto, J., Harris, N. R., Hussain, M., Mehran, S., Kalwar, I. H., ... ve Memon, T. D., 2021, Theimportance of featureprocessing in deep-learning-basedconditionmonitoring of motors, *Mathematical Problems in Engineering*.

Şahin, Y., 2000, Talaş Kaldırma Prensipleri 1, Nobel Yayın Dağıtım, Ankara.

Tumer, A. E. Ve Edebali, S., 2015, An ArtificialNeural Network Model forWastewaterTreatmentPlant of Konya, *International Journal of IntelligentSystems and Applications in Engineering*, 3 (4), 131-135.

Turan, B., 2017, Görüntü İşleme Algoritmalarının Eş Zamanlı Süreçlere Ayrılarak Kablosuz Ağ Üzerinden Gerçeklenmesi ve Performans Analizleri, Yüksek Lisans Tezi, *Maltepe Üniversitesi, Fen Bilimleri Enstitüsü*.

Villacrés, J. F., ve AuatCheein, F., 2020, Detection and characterization of cherries: A deeplearningusabilitycasestudy in Chile, *Agronomy*, 10(6), 835.

Yaman, K., Sarucan, A. ve Atak, M., 2001, Dinamik Çizelgeleme için Görüntü İşleme ve Arama Modelleri Yardımıyla Veri Hazırlama, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, C. 16, Sayı 1, 19–40.

Zhang, C., ve Lu, Y., 2021, Study on artificial intelligence: Thestate of the art and future prospects, *Journal of Industrial Information Integration*, 23, 100224.

Zhang, Q. B., ve Zhao, J., 2013, Determination of mechanical properties and full-fieldstrainmeasurements of rock material under dynamic loads. *International Journal of RockMechanicsandMiningSciences*, 60, 423–439.

Zou, Y., ve Chen, T., 2018, Laservisionseamtrackingsystembased on imageprocessingandcontinuousconvolutionoperatortracker. *OpticsandLasers in Engineering*, 105, 141–149.

Xu, L. M., Fan, F., Zhang, Z., Chen, Y., Hu, D. J., ve Shi, L., 2019, Methodology and implementation of a vision-oriented open CNC system for profile grinding. *International Journal of Advanced Manufacturing Technology*, 100(5–8), 2123–2131.

