

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE MEKANİK
PARÇALARIN 3 BOYUTLU TASARIMLARININ
SINIFLANDIRILMASI**

HAZIRLAYAN

IŞIL ATASOY

YÜKSEK LİSANS TEZİ

ANKARA- 2024

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE MEKANİK
PARÇALARIN 3 BOYUTLU TASARIMLARININ
SINIFLANDIRILMASI**

HAZIRLAYAN

IŞIL ATASOY

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ ÇAĞATAY BERKE ERDAŞ

ANKARA- 2024

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Işıl ATASOY tarafından hazırlanan bu çalışma, aşağıdaki jüri üyeleri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 20 / 09 / 2024

Tez Adı: Makine Öğrenimi Teknikleri İle Mekanik Parçaların 3 Boyutlu Tasarımlarının Sınıflandırılması

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)	İmza
Dr. Öğretim Üyesi İclal ÇETİN TAŞ, Ostim Teknik Üniversitesi	
Dr. Öğr. Üyesi Didem ÖLÇER, Başkent Üniversitesi	
Dr. Öğr. Üyesi Çağatay Berke ERDAŞ, Başkent Üniversitesi	

ONAY

Prof. Dr. Dilek ÇÖKELİLER SERDAROĞLU
Fen Bilimleri Enstitüsü Müdürü
Tarih: ... /.../

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 12 / 09 / 2024

Öğrencinin Adı, Soyadı: Işıl ATASOY

Öğrencinin Numarası: 22120173

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği Tezli Yüksek Lisans

Danışmanın Unvanı/Adı,Soyadı: Dr. Öğr. Üyesi Çağatay Berke ERDAŞ

Tez Başlığı: Makine Öğrenimi Teknikleri İle Mekanik Parçaların 3 Boyutlu Tasarımlarının Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 50 sayfalık kısmına ilişkin, 12 / 09 /2024 tarihinde tez danışmanım tarafından “Turnitin” adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %14’tür. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: 12 / 09 /2024

Dr. Öğr. Üyesi Çağatay Berke ERDAŞ

TEŞEKKÜRLER

Yüksek lisans eğitimim boyunca ve bu tezin çalışmasında zamanını, tecrübesini ve desteğini esirgemeyen bu tezin oluşturulmasında büyük emeği geçen tez danışmanım Dr. Öğr. Üyesi Çağatay Berke ERDAŞ'a teşekkürlerimi sunarım. Her zaman yanımda olan sevgili ailem ve arkadaşlarımdan destekleri ve yardımları ile yüksek lisans eğitimimi tamamlamış bulunuyorum. Bu nedenle en çok da annem Dilek Atasoy'a teşekkür ederim. Değerli çalışma arkadaşlarımdan ve yöneticilerime bu süreçte bana zaman ve imkân tanıdıkları ve başarılı olacağıma her zaman inandıkları için de ayrıca teşekkürlerimi sunuyorum.

ÖZET

Işıl ATASOY

MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE MEKANİK PARÇALARIN 3 BOYUTLU TASARIMLARININ SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

2024

Makine öğrenmesi teknikleri kullanılarak geliştirilen veri işleme uygulamaları son yıllarda oldukça büyük bir hız ile gelişme kat etmekte ve farklı alanlarda birçok probleme çözümler sunmaktadır. Yazılım destekli çözümleri kullanan tüm sektörlerden alınan veriler incelendiğinde sonuç olarak verimliliklerin arttığı, insan kaynaklı hataların ve gecikmelerin önüne geçildiği gözlemlenmiştir. Bu çalışmada üretim ve tasarım endüstrisinde kullanılan standart mekanik parçaların derin öğrenme algoritmaları kullanılarak sınıflandırılması amaçlanmaktadır. Buna ek olarak, çalışmada kullanılan modellerin performansları karşılaştırılacaktır. Çalışma kapsamında iki aşamalı bir deney kurulmuştur. Deneyin aşamaları birbirinden bağımsız olup, sonuçları da bağımsız olarak değerlendirilmiştir. İlk aşamada civata, pim, somun, rondela mekanik parçalarının dijital tasarımlarından oluşan hazır bir veri seti kullanılmıştır. Bu veri seti her parçadan eşit sayıda 224x224x3 boyutlarında görseller içerecek şekilde toplamda 7616 adet örneklemden oluşmaktadır. İkinci aşamada ise aynı tasarım görsellerine ek olarak mekanik parçaların gerçek fotoğrafları da eklenip toplamda 1600 adet örnekten oluşan yeni bir veri seti oluşturulmuştur. Daha sonra deneyin her iki adımında da parçaların tanınma problemine çözüm bulmak için AlexNet, VGG, DenseNet, ResNet ve Xception sınıflandırma modelleri tercih edilerek, sonuçlar kaydedilmiştir. İlk adımda modeller sırasıyla ortalama 0.25, 0.25, 0.60, 0.69 ve 0.75 doğruluk oranları sunmuştur. İkinci adımda ise sırasıyla ortalama 0.27, 0.25, 0.65, 0.85 ve 0.96 doğrulukla başarı elde etmişlerdir. Çalışmanın sonuçlarında modellerin performans karşılaştırmaları belirtilmiştir.

ANAHTAR KELİMELER: Bilgisayar Bilimi, Makine Öğrenimi, Görüntü İşleme, Derin Öğrenme, Evrimsel Sinir Ağları.

ABSTRACT

Işıl ATASOY

CLASSIFICATION OF 3D DESIGNS OF MECHANICAL PARTS USING MACHINE LEARNING TECHNIQUES

**Başkent University Institute of Sciences
Computer Engineering Major Science
2024**

Machine learning techniques and data processing applications have been developing rapidly in recent years and offer solutions to many problems in different fields. Efficiency has increased in all sectors using software-supported solutions, and human errors and delays have been prevented. This study aims to classify standard mechanical parts used in the production and design industry using deep learning algorithms. In addition, the performances of the models used in the study will be compared. A two-stage experiment was established within the scope of the study. The stages of the experiment were independent from each other and the results were evaluated independently. In the first stage, a ready-made data set consisting of digital designs of mechanical parts of bolts, pins, nuts and washers was used. This data set consists of 7616 samples in total, including an equal number of 224x224x3 images from each piece. In the second stage, in addition to the same design visuals, real photographs of mechanical parts were added and a new data set consisting of 1600 samples in total was created. Then, in both steps of the experiment, AlexNet, VGG, EfficientNet, ResNet and Xception classification models were preferred to find a solution to the problem of recognition of parts, and the results were recorded. Then, in both steps, AlexNet, VGG, EfficientNet, ResNet and Xception models were preferred to list the broken ones and the results were generated. Initial replacement models offered average accuracy rates of 0.25, 0.25, 0.60, 0.69 and 0.75, respectively. Secondary renewal was successful with an average accuracy of 0.27, 0.25, 0.65, 0.85 and 0.96, respectively. The results of the study are stated in the comparison performances of the models.

KEYWORDS: Computer Science, Machine Learning, Deep Learning, Image Process, CNN.

İÇİNDEKİLER

ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
TABLO LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	x
SİMGELER VE KISALTMALAR LİSTESİ.....	xi
1. GİRİŞ	1
1.1. Problemin Tanımı	1
1.2. Genel Bakış	2
1.2.1. Standart Mekanik Parçalar Nelerdir	2
1.2.2. Bilgisayar Destekli Tasarım Nedir?	8
1.2.3. Alandaki ilgili Diğer Çalışmalar	9
2. KULLANILAN VERİ KÜMESİ	12
2.1. Veri Toplama.....	12
2.2. Verilere Uygulanan Ön İşlemler	14
3. EVRİŞİMSEL SİNİR AĞLARI	15
3.1. Bileşenler ve Temel Kavramlar	15
3.2. Kullanılan Mimariler	19
3.3. Kullanılan Kütüphaneler	20
4. KULLANILAN YÖNTEM.....	22
4.1. Çapraz Doğrulama	22
4.2. Performans Ölçütleri	23
4.3. Deneysel Kurulum	24
4.4. Deney Sonuçları	26
4.5. Çalışmanın Katkısı	38
4.6. Geleceğe Yönelik Çalışmalar ve Sonuç	40
5. KAYNAKLAR.....	42

TABLÖLAR LİSTESİ

	Sayfa
Tablo 1.1. Veri seti etiketleri.....	14
Tablo 4.1. Karışıklık matrisi	23
Tablo 4.2. Model Sonuçları Karşılaştırması	30
Tablo 4.3. Model Sonuçları Karşılaştırması	30
Tablo 4.4. Model Sonuçları Karşılaştırması	35
Tablo 4.5. Model Sonuçları Karşılaştırması	36
Tablo 4.6. Model Sonucu Performans Ölçütleri	37
Tablo 4.7. Model Sonucu Performans Ölçütleri	38

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Altı köşe başlı cıvata örneği.....	3
Şekil 1.2. Allen başlı cıvata örneği.....	3
Şekil 1.3. Havşa başlı cıvata örneği	4
Şekil 1.4. Tornavida başlı cıvata örneği.....	4
Şekil 1.5. Yıldız tornavida başlı cıvata örneği.....	5
Şekil 1.6. Somun örnekleri	6
Şekil 1.7. Pim örnekleri	7
Şekil 1.8. Rondela örnekleri	7
Şekil 2.1 Dijital Tasarım Örnekleri (cıvata, pim, somun, rondela)	12
Şekil 2.2. Gerçek Parça Fotoğrafları (cıvata, pim, somun, rondela).....	13
Şekil 3.1. Evrişimsel Sinir Ağları Mimarisi	15
Şekil 3.2. Konvolüsyon işlemi.	16
Şekil 3.3. Havuzlama Katmanı.....	16
Şekil 3.4. Tam Bağlı Katman.....	17
Şekil 3.5. Relu Katmanı.....	17
Şekil 3.6. Bırakma Katmanı	18
Şekil 4.1. Model Sonuçları Karışıklık Matrisleri	26
Şekil 4.2. Model Sonuçları Doğruluk Oranları	27
Şekil 4.3. Model Sonuçları Karışıklık Matrisleri	28
Şekil 4.4. Model Sonuçları Doğruluk Oranları	29
Şekil 4.5. Model Sonuçları Karışıklık Matrisleri	31
Şekil 4.6. Model Sonuçları Doğruluk Oranları	32
Şekil 4.7. Model Sonuçları Karışıklık Matrisleri	33
Şekil 4.8. Model Sonuçları Doğruluk Oranları	34
Şekil 4.9. Karışıklık Matrisi	37
Şekil 4.10. Karışıklık Matrisi	37

SİMGELER VE KISALTMALAR LİSTESİ

ESA	Evrişimsel Sinir Ağı
CNN	Convolutional Neural Networks
CAD	Computer Aided Design
YSA	Yapay Sinir Ağları
DP	Doğru Pozitif
DN	Doğru Negatif
YN	Yanlış Negatif
YP	Yanlış Pozitif
ReLU	Rectified Linear Unit
ILSVRC	Büyük Ölçekli Görsel Tanıma Yarışması

1. GİRİŞ

1.1. Problemin Tanımı

Hemen hemen her sektörde Dijital Dönüşümün önemi gün geçtikçe artmaktadır. İşletmeler yazılım destekli programlar için büyük bütçeler ayırmaktadır, bunun karşılığında ise verim artışı ve kişi kaynaklı hataların önüne geçilmesini hedeflemektedir.

Üretim endüstrisinde işlerin standardizasyonu hem kalite hem de konfigürasyon yönetiminde büyük önem arz etmektedir. Aynı işlemi her çalışanın farklı yöntemle yapmaya çalışması hem hatalara ihtimal açmakta hem de iş gücü kaybı yaratmaktadır. Bu sebeple dijitalleştirilmiş sistemler kurulması önemlidir. Bu tarz yazılım destekli sistemler çalışanın gündelik işlerine yardımcı olurken, işletme için de maddi avantaj sağlamaktadır.

Üretim sektöründe verimliliği ve ürün kalitesini arttırmak için birçok model ve yöntem belirlenmiştir. Bu yöntemler ile tasarım ve üretim gibi ana süreçlerin yanı sıra, konfigürasyon ve varyant yönetimi, depolama ve lojistik yönetimi, satın alma ve stok yönetimi gibi ek süreçler de iyileştirilmekte ve geliştirilmektedir.

Tüm yöntemlerin özellikle vurguladığı noktalardan biri tekrarlı çalışma (rework) ve tekrar kullanım (reuse) kavramlarıdır. Rework, iş akış süreçlerindeki çeşitli adımlarda yaşanan analiz veya planlama eksikliği, yanlış tasarım veya malzeme seçimi gibi herhangi bir sebepten ötürü hatalı gerçekleşen işlemlerin tekrardan yapılmasıdır. Bu durum işgücüne bağlı hem zaman hem maddi kaynak kaybına sebep olmaktadır. Birikimli olarak işletmeye büyük bir maddi zarar ile sonuçlanmaktadır. Reuse ise aynı veya çok benzer bir işlemin tekrar tekrar yapılmaması için önceden yapılmış olanın kullanılmasıdır. Daha önceden oluşturulmuş bir belgelendirme benzer bir işlemde tekrar kullanılabilir veya bir parça en baştan üretilmek yerine muadil olarak yerine geçebilecek başka bir parça seçilebilir. Reuse işletmelere işgücü ve maddi verimlilik sağlamaktadır.

Dünya çapında kabul gören yöntemlerde bu iki kavramın uygulanabilmesi için işletmelerde mutlaka standart parça yönetiminin yapılması gerektiği belirtilmektedir. Standart parça yönetimi özetle, tasarım ve üretim süreçlerine sıklıkla kullanılan parçaların

belirlenip sınıflandırılması, sınıflarına göre isimlendirilmesi ve bu parçaları kullanacak kişilerin en kolay şekilde erişebileceği bir sistematik ile depolanmasının sağlanmasıdır. Tasarım süreçlerinde birçok yazılım aracı kullanılmaktadır. İşletmede standart parça yönetimi yapılmıyorsa, her tasarımcı kullanacağı parçayı tekrar tekrar tasarlamak durumunda kalmaktadır. Bu durum hem rework yaratır hem de reuse'a aykırıdır. Ek olarak çok büyük bir veri kirliliği yaratıp altyapısal sorunlara da yol açmaktadır. Başka bir açıdan, tasarımcı modelini tekrar tasarlamak durumunda kalmasa bile aradığı doğru parçaya ulaşması uzun zaman ve çaba alabilir. Bu da yine verimliliği düşürecek ve hatalara yol açacaktır. Bu noktada kullanılan tasarım araçlarındaki standart parçaların sınıflandırılması ve uygun isimlendirmelerinin belirlenen kurallara uygun olarak yapılması çok kritiktir.

Bu tez çalışması ile üretim endüstrisinde sıklıkla kullanılan standart mekanik parçaların sınıflandırılması hedeflenmektedir. Sınıflandırma işlemi için Derin ESA algoritmalarından AlexNet, VGG, ResNet, DenseNet ve Xception modelleri kullanılmış olup, mekanik parçaların dijital tasarım görselleri ve gerçek fotoğrafları birlikte kullanılıp eğitim ve test işlemleri gerçekleştirilmiştir. Bu çalışma bağlamında seçilen ESA algoritmaları parametrikleri değiştirilerek deneylerde kullanılmış olup performansları karşılaştırılarak problemin çözümüne en uygun yöntem araştırılmıştır.


1.2. Genel Bakış

1.2.1. Standart Mekanik Parçalar Nelerdir

Mekanik ürün tasarım ve üretiminde büyük parçaları birbirine bağlamak, parçalar arasında destek sağlamak veya sağlamlığını ve güvenilirliğini arttırmak amacıyla çeşitli aracı parçalar kullanılır. Bu aracı parçalar evrensel standartlar ile tasarlanıp üretilmektedir. Kullanım alanları bu genel standartlarca belirlenmektedir. Bu sebeple de standart mekanik parça olarak adlandırılmaktadırlar [1]. Bu tez çalışmasında kurulacak olan deneylerde kullanılmak üzere sanayide en çok tercih edilen parçalar olan cıvata, somun, pim ve rondela seçilmiştir.

Somun kullanılarak mekanik parçaları sökülebilir şekilde birleştiren, çok çeşitli başlıklara sahip ve gövdesine vida dişi açılmış silindirik bağlantı elemanlarına cıvata denilir. Başlıklarının şekillerine isimlendirilmektedirler. Örnek olarak altı köşe başlı, allen başlı, havşa başlı, tornavida başlı ve yıldız tornavida başlı cıvatalardan bahsedilebilir.

Altı köşe başlı cıvatalar makine parçalarının birleştirilmesinde veya montajında sıkça kullanılan cıvatalardır. Kullanım alanının gerekliliklerine göre cıvataların dişleri normal veya ince yapılıdır [1].



Şekil 1.1. Altı köşe başlı cıvata örneği

Cıvata başının oturacağı alanın somun anahtarı sığmayacak kadar dar olduğu yerlerde veya cıvata başının dışarıda kalmasının istenmediği durumlarda Allen başlı cıvatalar tercih edilir.



Şekil 1.2. Allen başlı cıvata örneği

Havşa başlı cıvataların başları silindiriklere göre daha incedir. İnce malzemeler birleştirilirken cıvata başının dışarıda kalması istenmiyorsa bu cıvatalar kullanılır.



Şekil 1.3. Havşa başlı cıvata örneği

Tornavidalarla sıkılıp açılarak kullanılan ve başında tornavida kanalı açılmış silindirik başlı cıvatalara tornavida başlı cıvatalar denir. Diğer türlere göre gövdeleri ve başlıkları daha küçüktür.



Şekil 1.4. Tornavida başlı cıvata örneği

Yıldız tornavida ağızlı cıvatalar aynı ölçüdeki tornavida ağızlı cıvatalara göre daha kuvvetli sıkılmaktadırlar. Yıldız tornavida ağızlı cıvataların en önemli faydası sıkılırken ya da çözülürken ağız kısmının formunu korumasıdır.



Şekil 1.5. Yıldız tornavida başlı cıvata örneği

Çeşitli parçalarda kullanılan cıvataların sağlam bir şekilde sıkışmasını ve birbirine bağlanmasını sağlayan ara parçalara somun adı verilmektedir. Cıvatalardan sonra en kritik ve en çok kullanılan yardımcı parça olan somunlar, özellik ve şekillerine göre birçok çeşitte üretilmektedir. İşlevsel olarak cıvata ile birbirini tamamlayacak şekilde kullanılırlar [2].

Somunlar kullanım alanına ve birlikte kullanılacak olan malzemeye uygun olarak üretilmiş olan çeşitleri mevcuttur. En fazla tercih edilen çeşitleri şu şekildedir:

- Altı Köşe Somunlar
- Altı Köşe Kör Somun
- İnce Taçlı Somun
- Kare Somun
- Kare Kaynak Somunu
- Boru Dişi Somun vb.



Şekil 1.6. Somun örnekleri

Birbirine bağlanacak veya birbiri içine geçen parçaların kaymasını engelleyen, genellikle silindirik olan ara makine parçalarına pim adı verilir [3]. Birçok sektörde çelik pimler kullanılır ancak farklı olarak ahşap pimler de tercih edilmektedir. Pimlerin boylarına göre çapları daha küçüktür. Bu parçanın en önemli özelliklerinden biri, söküldükten sonra ilk konumlarındaki hasarsız ve kullanılmamış şekillerinin elde edilebilmesidir.

Silindirik pimler, yuvarlak, konik ve düz uçlu çeşitleri vardır. Yüzeyleri düz ve pürüzsüzdür ancak kullanıldıkları konumlardaki titreşimden gevşeyebilecekleri için güvenli değildir. Çoğunlukla merkezleme işleminde kullanılırlar.

Konik pimler; konik ölçüde yapılırlar ve tekrar kullanıma uygundurlar. Gevşemeye karşı daha güvenlidirler. Merkezleme işlemi için en iyi sonucu veren pimlerdir.

Yay tipi pimler; takıldığı yerde yaylanarak mekanik parçaların emniyette kalmasını sağlayan pim türüdür.

Çentikli pimler, pim çevresinde çentikler bulunan türüdür. Çentik boyutları değişebilir. Birden fazla kez sökülüp takılabilme özelliği vardır. Silindirik veya konik olarak yapılabilirler fakat konikler merkezleme işleminde silindirik olanlar kadar iyi sonuç vermezler.



Şekil 1.7. Pim örnekleri

Cıvata, somun gibi makine ara parçalarında kullanılan ve parçaların uç kısımlarının temas yüzeyini genişleterek bağlandığı yüzeyde meydana gelebilecek zararı önleyen ve kurulan bağlantının zaman içerisinde gevşemesini engelleyen ara parçalara rondela denilir. Ek olarak birlikte kullanıldıkları makine parçalarındaki yüzey alanını arttırdığı için parçalara yüklenen basıncı azaltmaktadır. Ortası delik bir daire şeklindedir bu sebeple pul da denilmektedir. Endüstride çoğunlukla kullanılan cıvatanın gevşemesini önleyen yaylı tipi tercih edilir [4].



Şekil 1.8. Rondela örnekleri

Rondela bakır, elik, pirin, alminyum ve kurşun gibi malzemeler kullanılarak retilmektedir. ok eřitli malzemelerden retilmesindeki temel ama ise rondelanın baėlı olduėu mekanik paradan daha yumuřak olması gerekmesidir. Bu sebepten dolayı rondelaların trleri de retildikleri malzemededen malzemeye deėiřebilmektedir.

1.2.2. Bilgisayar Destekli Tasarım Nedir?

Bilgisayar destekli tasarım (Computer Aided Design- CAD), retim endstrisinde tasarım srelerinde tasarımcılara yardımcı olmak amacıyla eřitli zel yazılımların kullanılmasıdır. CAD yazılımları, eřitli sektrlerde alıřmakta olan mhendisler ve tasarımcılar tarafından sıklıkla kullanılmaktadır. CAD yazılımı, iki boyutlu izimler veya  boyutlu modeller tasarlamakta kullanılabilir.

CAD'in kullanım amacı, tasarımcının iř akıřlarını optimize etmek ve dzenlemek, verimini artırmak, tasarımlarındaki kaliteyi ve izimlerindeki ayrıntıları iyileřtirmek, belgelendirme ve paylařımlı alıřmayı kolaylařtırmak ve genellikle bir retim tasarımı veri tabanına katkı saėlamaktır. CAD yazılımının ıktıları, retim srelerinde kullanılmak zere elektronik dosyalar biimindedir. CAD yazılımları genellikle retim sreleri dijitalleřtirilmiř olan organizasyonlarda kullanılır. [5]

Geleneksel manuel teknik izim ile karřılařtırıldıėında, CAD tasarım yazılımlarının kullanılması mhendisler ve tasarımcılara birok nemli avantaj sunmaktadır.

- retim maliyetlerini dřrrken, tasarım srelerinin verimli kullanılmasına olanak sunarken projelerin hızlı tamamlanmasını saėlamaktadır.
- Tasarımlar kk deėiřiklikler yapılarak tekrar kullanılabilir.
- Hesaplamalar daha detaylı ve kontroll olacaėından daha keskin detaylara sahip tasarımlar yapılabilir.
- Arřivlemeyi ve belgelemeyi kolaylařtırır, okunurluėu ve eriřilebilirliėi arttırır.
- Dijital ıktılar verdiėi iin iř akıřındaki diėer uygulamalara girdi oluřtırmakta kolaylık saėlar [5].

1.2.3. Alandaki ilgili Diğer Çalışmalar

Literatürde görüntü işleme ve sınıflandırma konularında derin öğrenme algoritmaları kullanarak birçok çalışma mevcuttur.

Philip ve arkadaşları yapmış oldukları çalışmada rulman, somun, dişli ve cıvatalardan oluşan bir veri setinin derin öğrenme algoritmaları kullanılarak sınıflandırmışlardır. Derin öğrenme algoritmalarından AlexNet, DenseNet, ResNet, ve SqueezeNet tercih etmişlerdir. Sonuç olarak DenseNet kullanılan modeller arasında 0.98'lik doğruluk, 0.95'lik hassaslık, 0.98'lik özgüllük ile en başarılı model olmuştur [6].

Sajjad ve arkadaşları, oluşturulan veri kümeleri üzerinde bilgisayar görüşü ve makine öğrenimini kullanarak bağlantı elemanlarını otomatik olarak sınıflandırmak için bir sistem geliştirmiştir. Sonuç olarak çalışma, 20 cıvata ve 14 rondelayı 0.99 doğrulukla sınıflandırmıştır [7].

Amit ve arkadaşları, otomotiv ve mekanik endüstrilerindeki somun ve cıvataları tanıyan bir sistem tasarlamıştır. Bu sistemin işlenmesi için girdi olarak somun ve cıvataların boyut ve ebatlarıyla birlikte normalize edilmiş görüntüsü alınır ve tespit için kullanılabilir. Sistem farklı algoritmalar kullanılarak tasarlanabilmekte ve bu algoritmaların tümü MATLAB yazılımı kullanılarak entegre edilmektedir. Görüntü işleme algoritması, görüntüleri kırmak için kullanılabilecek dalgacık dönüşümü kullanılarak geliştirilecek ve bu görüntüler ayrıca işleme için uygun bir girdi olarak kullanılabilir. Tanıma sistemi geliştiricisinin görevi, bir sensörden veya yüksek performanslı bir kameradan veri alan bir sistem tasarlamak ve örneğin somun veya cıvata gibi bir sınıf atamaktır. Bu görüntü daha sonra temel bileşen analizi kullanılarak özellik çıkarımı için uygulanır. Bir nesnenin tespiti için Yapay zekâ sistemi kullanılır. Özellik çıkarımının sonucu, nesnenin tespiti için Yapay zekaya verilir ve daha sonra gerekli uygulamaya uygulanır [8].

Amol ve arkadaşları, yapay sinir ağını (YSA) kullanarak cıvata ve somunu tanıyan bir yöntem geliştirmişlerdir. Deney görüntü alımıyla başlamış ve görüntüler yüksek çözünürlüklü kamera kullanılarak çekilmiştir. Ön işleme aşamasında görüntüler gri skalaya dönüştürülüp ve yeniden boyutlandırılmıştır. Özellik çıkarımı için Temel Bileşen Analizi

(PCA) kullanılmıştır. Çalışma kurulan sistem nesneleri doğru bir şekilde sınıflandırması ile sonuçlanmıştır [9].

Rucco ve arkadaşları, endüstride kullanılan mekanik parçaların sınıflandırılması için hızlı ve hafif bir uygulama geliştirmişlerdir. Sundukları çözüm ile geçici bir sınıflandırma şemasıyla denetimli çok katmanlı bir yapay sinir ağının nasıl kurulacağını göstermiştir. Çözümü 875 özellik tarafından tanımlanan 2354 öğeden oluşan bir veri kümesi üzerinde test edip sonuçları paylaşmışlardır [10].

Matteo ve arkadaşları, mekanik bileşenlerin otomatik sınıflandırılması için makine öğrenimini kullanmışlardır. Her nesne bir özellikler paketiyle temsil edilmiş ve veri seti 15 alt kategoriye ait 2354 görsel ve 875 özellikten oluşturulmuştur. Test veri seti 606 görüntü içermektedir. Sonuç olarak çalışmada benzerlik katsayılarına göre ROC eğrileri altında ortalama alan elde edilmiştir [11].

Teuku ve arkadaşlarının yapmış olduğu çalışma, başta otomotiv endüstrisi olmak üzere çeşitli endüstrilerdeki uygulamalar için cıvata ve somunun gerçek zamanlı olarak tanınması sistemine odaklanmaktadır. Bu çalışmanın amacı, Geri Yayılım Sinir Ağı kullanılarak öğrenme sürecine uygun girdi olacak normalize edilmiş kırpılmış görüntüleri elde etmek için görüntü işleme algoritması geliştirmektir. Test, gerçek zamanlı bir görsel tanıma sistemi kullanılarak yapılır. Sonuçlar, sistemin bantlı konveyör üzerindeki hareketli nesneyi 9 cm/sn hızla 0.92 doğrulukla doğru bir şekilde algılayabildiğini göstermektedir [12].


Amraee ve arkadaşları yaptıkları çalışma ile, vidalar, somunlar, anahtarlar ve madeni paralar dahil olmak üzere küçük metal nesneleri sınıflandırmak için iki özellik çıkarma yönteminin etkinliğini ele almaktadır: yönlendirilmiş gradyanların histogramı (HOG) ve yerel ikili desen (LBP). Çalışma kapsamında etiketlenen görüntüler için istenen özellikler öncelikle çıkarılıp bir özellik matrisi biçiminde kaydedilir. Üç farklı sınıflandırma yöntemi (parametrik olmayan K-en yakın komşu algoritması, destek vektör makinesi ve saf Bayesian yöntemi) kullanılarak görüntüler dört farklı sınıfa sınıflandırılır. Daha sonra ortaya çıkan karışıklık matrisi incelenerek HOG ve LBP yaklaşımlarının performansları bu dört sınıf için karşılaştırılmıştır. Bu iki yöntemin etkinliği, derin öğrenmeye dayanan “YOLO” ve daha hızlı bölge tabanlı evrişimli sinir ağı yaklaşımlarıyla da karşılaştırılmıştır. Toplanan görüntü

seti 800 etiketli eğitim görüntüsü ve 180 test görüntüsü içermektedir. Sonuçlar, HOG kullanımının LBP kullanımından daha verimli olduğunu göstermektedir. Üstelik HOG ve LBP'nin bir kombinasyonu, her ikisinin de tek başına olmasından daha iyi sonuçlar sağlar [39].

2. KULLANILAN VERİ KÜMESİ

2.1. Veri Toplama

Tez çalışmasında ilk aşama olarak Derin Öğrenme Algoritmaları ile sınıflandırılmak amacıyla endüstride en sık kullanılan standart mekanik parçaların dijital tasarım görüntülerinden oluşan hazır bir veri kümesi kullanıldı [13]. Bu veri kümesi Şekil 9'da her parçanın birer örneğinin gösterildiği 224x224x3 boyutlarında 1904 adet cıvata, pim, somun ve pul görselinden oluşmaktadır. Her sınıftan eşit sayıda örnek içeren dengeli bir kümedir. Görseller aynı modelleme yazılımı ile tasarım standartlarına uygun olacak şekilde çizilmiş olup, aynı formatta kaydedilmiştir. Tasarımlar aynı parçaların farklı çeşitlerini içermekte olup, farklı açılardan ve boyutlardan çizilmiştir. Bu nedenle bazı görsellerde parçaların birbirine benzer görünmesi öğrenme sürecine karmaşıklık katmaktadır. Oluşması beklenen karmaşıklık çalışmanın ESA modellerinin performansını karşılaştırma hedefine katkı sağlayacaktır.



Şekil 2.1. Dijital Tasarım Örnekleri (cıvata, pim, somun, rondela)

Daha sonra kullanılan ESA modellerinin eğitimine destek vermek ve sınıflandırma adımının karmaşıklığını arttırmak amacıyla veri kümesi oluşturulurken aynı standart mekanik parçaların dijital tasarımları ve bu standart parçaların gerçek fotoğraflarından oluşan görseller birleştirilmiştir. Çalışmanın ilk aşamasında kullanılan hazır veri kümesinden her sınıfta 300'er adet olacak şekilde örnekler rastgele olarak seçilmiştir. Daha sonra aynı mekanik parçalara ait 100 adet fotoğraf çekilip, tasarım görsellerinden oluşan listeye eklenmiştir. Fotoğraflar mümkün olduğunca arka plan düz ve benzer olacak şekilde ve farklı açılardan çekilmiştir. Işık yansımalarına dikkat edilmiştir. Ayrıca dijital tasarım görsellerinden oluşan veri setinde kullanılan parça çeşitlerinin seçilmesine dikkat edilmiştir. Parçaların gerçek fotoğraflarının her sınıfından bir örnek görsel Şekil 2.1'de gösterilmiştir. Sonuç olarak toplamda her sınıfta bulunan mekanik parçaların her birinden 400 adet örnek görsel içeren nihai veri kümesi oluşturulmuştur.



Şekil 2.2. Gerçek Parça Fotoğrafları (cıvata, pim, somun, rondela)

2.2. Verilere Uygulanan Ön İşlemler

Her iki grup verideki görseller de CNN modellerine uygun girdi oluşturmak amacıyla 224x224x3 boyutlarına getirilmiştir. Daha sonra çalışmanın ilk aşamasında kullanılacak olan veri kümesindeki görsel sınıflarının her biri dikey olarak birleştirilerek 224x224x3 boyutlarında 7616 örneklik bir girdi elde edilmiştir. Örnek kontrol için dizi elemanlarından gelen görüntü sınıfı doğrulanmıştır. Ayrıca sınıflandırma sürecinde kullanılmak üzere etiket verilerini içeren bir giriş listesi oluşturulmuştur. Tablo 2.1’de gösterildiği üzere cıvata görselleri 0 ile, pim 1, somun 2 ve rondela 3 ile etiketlenmiştir.

Tablo 2.1. Veri seti etiketleri


Sınıf	Etiket
Civata	0
Pim	1
Somun	2
Rondela	3

Çalışmanın ikinci deneyinde kullanılacak olan veri kümesindeki görseller önceden belirlenmiş olan sınıflarına göre sıralanmış ve dikey olarak birleştirilmiştir. İşlem sonucunda 1600 satırdan oluşan bir liste elde edilmiştir. Son olarak, ESA modellerinde kullanılmak üzere belirlenen sınıflara ait etiket bilgilerini içeren yeni bir liste görsellerden oluşan veri kümesiyle paralel olacak şekilde yeniden yaratılmıştır.

3. EVRİŞİMSEL SİNİR AĞLARI

3.1. Bileşenler ve Temel Kavramlar


Evrişimsel Sinir Ağları derin öğrenme uygulamalarında sundukları başarılar sayesinde çoğu çalışmada tercih edilmektedir. ESA, geçmiş çalışmalarda kullanılan sinir ağı modellerinden farklı olarak bir öznitelik verisine ihtiyaç duymadan veri kümelerindeki görsellerin özniteliklerini basitten karmaşığa doğru sıralayıp tanımlayabilmektedir. Modeller başlangıç olarak daha kolay tespit edilebilecek özellikleri belirleyip sırasıyla diğer öznitelikleri katmanlarına ekler [14]. ESA mimarileri 7 ana aşamadan oluşmaktadır, bu aşamalar sırasıyla Girdi (Input), Evrişim(Convolution), Havuz (Pooling), Tam Bağlı (Fully Connected), Bırakma (Dropout), Düzleştirme (Flattening) ve Sınıflandırma (Classification) olarak tanımlanmıştır.



Şekil 3.1. Evrişimsel Sinir Ağları Mimarisi


Evrişim adımı bir görselde yer alan ayırt edici özellikleri çıkartır. Kenarlar, köşeler, kıvrımlar belirgin noktalar bu işlem ile ortaya çıkar. Evrişim işlemi görüntü matrisi üzerinde çeşitli boyutlardaki küçük matrisler gezdirilerek oluşturulur. Seçilen küçük matrisler tüm matris üzerinde gezdirilerek girdi görüntüsündeki öznitelikler belirginleştirilir ve işlem sonucunda orijinal girdi boyutunda yeni bir görüntü matrisi elde edilmiş olur. Çok katmanlı

bir mimariye sahip olan ESA algoritmalarında her katmanda farklı bir işlem uygulanarak bir sonraki katmana veriler iletilir [40].



Şekil 3.2. Konvolüsyon işlemi. a) Görüntü Matrisi b) Filtre c) Filtre çıktısında oluşan görüntü matrisi


Havuzlama katmanı genellikle evrişim işlemi sonrasında uygulanan bir katmandır [41]. Bu katmanda girdi görüntüde $N \times N$ boyutunda küçük bir matris oluşturulur. Bu boş küçük matris girdi matrisi üzerinde gezdirilerek sınırları içerisindeki en büyük değeri seçer ve yeni bir matrisin yeni bir değerini oluşturmuş olur. Şekil 3.3'te bir örnek sunulmuştur.



Şekil 3.3. Havuzlama Katmanı


Ortalama havuzlama yönteminde ortalama değeri, minimum havuzlama yönteminde en küçük değeri, maksimum havuzlama yönteminde de ise en büyük değeri seçilmektedir. Toplam havuzlama yönteminde ise değerlerin toplamı alınmaktadır. Kullanılan modellerin özelliklerine göre havuzlama yöntemi değişmektedir.

Tam Bağlı (Full-Connected) Katman, önceki adımlarda işlenen veriler bu katmanda tek boyutlu bir matris olacak şekilde konumlandırılmaktadır. Bu katmanda bulunan her bir nöron sinir ağında kendisinden sonra gelen nöron ile tamamen bağlanır. Bu sebeple tam bağlı katman olarak adlandırılmaktadır [42]. Bu katmandaki nöronların bağlantıları Şekil 3.4'te gösterilmiştir.




Şekil 3.4. Tam Bağlı Katman

Relu (Rectified Linear Unit) Katmanı, aktivasyon fonksiyonunun uygulandığı katmandır. Bu katmandaki işlem sonucunda elde edilen veriler aktivasyon fonksiyonuna girdi oluşturur. Bu katmanda kullanılan birden çok aktivasyon fonksiyonu vardır. Örnek olarak step, eşik değeri, hiperbolik tanjant, sinüs, fonksiyonları gösterilebilir [43]. Şekil 3.5 ile bu katmana bir örnek sunulmuştur.



Şekil 3.5. Relu Katmanı

Bırakma (Dropout) Katmanı, ESA katmanlarındaki aşırı öğrenmeyi engellemek amacıyla kullanılan bir katmandır. Sinir ağı içerisinde aşırı öğrenmeye neden olabilecek bağlantıları koparmaktan sorumludur. Böylelikle modelin ezber yapması engellenir, doğru tercihler yapabilmekteki performansını arttırılmış olur [44][45]. Şekil 3.6’da bir yapay sinir ağı bağlantıları ve bırakma uygulanmış ağ yapısının sonucu gösterilmektedir.



Şekil 3.6. Bırakma Katmanı

Derin ESA algoritmalarında ağı normalize edilmesi modelin performansını etkilemektedir. Normalizasyon (Ölçeklendirme) Katmanı, model boyunca uygulanan katmanlarda uygulanan işlemlerden elde edilen çıktıları düzenlemektedir. Katmanlara girdi olan veriler beklenenden daha büyük veya daha küçük değerler içerebilir. Bu değerlerin ölçeklendirilerek edilerek belirli bir değer aralığında tutulması daha tutarlı sonuçlar elde edilmesine yardımcı olmaktadır [46].

Entropi (Softmax) Katmanını, önceki katmanlardan çıkan değerleri kullanarak sınıflandırma işleminde oluşacak olasılıksal değerlerin üretildiği aşamadır. Sınıflandırma yapılırken verinin hangi sınıfa daha benzer olduğuna dair olasılıksal değerler üretir ve sonuç olarak uygulanan modelin tahmin sonuçları belirlenmiş olur [46].

3.2. Kullanılan Mimariler

Tez çalışmasında derin öğrenme algoritmaları ile sınıflandırma işlemlerinde sıklıkla tercih edilen algoritmalar olan AlexNet, VGG, ResNet, DenseNet ve Xception modelleri kullanılmıştır.

AlexNet evriřimli bir sinir ağıdır. Alex Krizhevsky ve diğeri tarafından 2012 yılında geliştirildi. Beř evriřim katmanı, üç alt örnekleme katmanı ve üç tam bağlantılı katmandan oluşan derin bir ESA'dır. AlexNet lineer olmayan işlem aşamalarında aktivasyon fonksiyonu olarak ReLu kullanmaktadır. Daha eski nöral ağlarda tanh veya sigmoid kullanılmaktaydı. ReLu'nun, sigmoid'e göre avantajlı olmasının sebebi, modelin daha hızlı eğitilmesidir. AlexNet'in eğitimi, 1000 farklı nesneyi tanımlamak için 1,3 milyon yüksek çözünürlüklü görüntü kullanılarak yapıldı. AlexNet, 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasına (ILSVRC) katılmıştır AlexNet, çeşitli tıbbi görüntülerin sınıflandırılması problemlerinde büyük bir gelişme elde etmiştir [22].

VGG modeli, Karen Simonyan, Andrew Zisserman ve diğeri tarafından Oxford Üniversitesi'nde geliştirilen başka bir CNN mimarisidir. VGG, milyonlarca parametreye ile ve milyarlarca örnek girdi görüntü üzerinde eğitilmiş olan 16 katmanlı bir ESA'dır. VGG modeli verimlidir ve birçok bilgisayarlı görme işlemlerindeki tekrar kullanılabilirliği ve farklı makine öğrenme yöntemleri ile olan uyumluluğu sayesinde birçok uygulamaya sağlam bir temel olarak bilinir [23].

Residual neural network (ResNet) 2015 yılında Kaiming ve diğeri tarafından geliştirildi. Ağ, artık blokların üst üste istiflenmesiyle geliştirildi. Mimariler arasında toplu normalizasyon ve Düzeltmiş Doğrusal Birim (ReLU) içeren iki veya üç katman üzerindeki bağlantıların atlanmasıyla gerçekleştirildi. Diğer CNN modelleriyle karşılaştırıldığında ResNet'in eğitim yeteneği daha iyi ve hesaplamalar daha hafiftir. ResNet-50, 2015 yılında ILSVRC'yi 0.3 hata oranıyla kazanılmıştır. Mimarisi 48 evriřim katmanı, bir maksimum havuz katmanı ve bir ortalama havuz katmanından oluşmaktadır [24]. Modeller daha çok gizli katman içermeye başladığında değeri öğrenme çok daha zor ve karmaşık olmaya başlamaktadır. Bu ağda bağlantıları atlamak olarak adlandırılan bir yöntemden yararlanılmıştır. Bu yöntem, modellerdeki birkaç katmanı atlar ve doğrudan çıktı katmanına bağlanır. Böylece ağı aşırı büyük/küçük değeri üretmesi probleminin önüne geçilmiştir.

Densely connected convolutional networks (DenseNet) Zhuang Liu, Gao Huang ve ekibi tarafından 2017 yılında geliştirildi. Her DenseNet katmanının orijinal giriş görüntüsüyle doğrudan bağlantısı vardır ve gereksiz özellik haritalarını öğrenmez. Beř evriřim katmanı, beř havuzlama katmanı, üç geçiş katmanı ve yüz yirmi bir algılayıcıdan oluşan 24 katmanlı bir evriřimli sinir ağıdır. DenseNet, ilk deneylerinde ResNet'te olduğu

gibi tek evriřimli katmanı ve maksimum ortaklama katmanını kullanmaktaydı. Daha sonra, ResNet'in kullandığı artık bloklardan oluşan dört yoğun blok kullanmaya başlamıştır. ResNet'le benzer şekilde, her yoğun blokta kullanılan evriřimli katmanların sayısını da ayarlanabilmektedir [25].

Extreme Inception veya Xception modeli, paralel çalışan evriřim katmanlarına sahiptir. Genellikle derin ESA'lar kanal dağıtımı ve uzamsal konularla ilgilenir, ancak Xception modeli ayrıca derinlemesine ve noktasal evriřim problemlerinin çözümünü da dikkate alır. Xception, standart başlangıç modeli derinlemesine ayrılabilen konvolüsyon katmanlarıyla başlangıç mimarisinin bir uzantısıdır. Ek olarak bu model birden fazla girdi sınıfını sınıflandırabilmektedir. Girdi verileri öncelikle giriş katmanından, daha sonra sekiz kez tekrarlanan orta katmandan ve son olarak çıkış katmanından geçer. Model içerisindeki tüm katmanlar toplu normalleştirme yöntemini uygulamaktadır. Xception modelinin görüntü işleme çalışmalarında derin faydaları vardır [26].

3.3. Kullanılan Kütüphaneler

Bu çalışmada keras, tensorflow, Pandas, numpy, matplotlib kütüphanelerinden faydalanılmıştır.

Pandas kütüphanesi verilerin okuması ve yazılması için kullanılan bir kütüphanedir. Bu kütüphane sayısal tabloları ve zaman etiketli serileri işlemek için bir veri yapısı oluşturur ve analiz işlemlerini kurmuş olduğu bu yapı üzerinde gerçekleştirir. Çalışmada veri çekme işlemleri için kullanılmıştır [27].

NumPy kütüphanesi, matrisler kullanılarak çalışmaya yardımcı olarak Python programlama dilinde çok boyutlu dizilerle işlemler yapmakta kullanılmaktadır. Matris veri yapıları ve çok boyutlu dizileri içerir. Dizilerde matematiksel, istatistiksel ve cebirsel operasyonlarda kullanılır. Tez çalışmasında dizi ve matris veri yapısından yararlanmak amacıyla kullanılmıştır [28].

Matplotlib, verilerin görselleştirmesinde kullanılan bir Python kütüphanesidir. Çok boyutlu grafiksel çizimler yapılmasını sağlar. Bu çalışmada çıktı sonuçlarını grafiksel olarak görselleştirmede kullanılmıştır [29].

Keras, Tensorflow kullanan bir kütüphanedir. Python dilinde yazılmıştır. ESA modellerini tanımlama ve eğitmek için kullanılmaktadır. Tez çalışmasındaki yazılımlarda tensorflow kullanılmıştır. Seçilen ESA modellerinin oluşturulması ve eğitilmesi aşamalarında Keras kütüphanesinden faydalanılmıştır [30].

TensorFlow sayısal hesaplamalar yapmayı sağlar. Keras kütüphanesinde modellerin yüklenmesinde ve veri kümesinde bulunan görsellerin ön işlemlerden geçirilme aşamasındaki hesaplarda kullanılmıştır. [31].

4. KULLANILAN YÖNTEM

Makine Öğrenimi algoritmaları, tanımlanan bir problemin çözümü için kullanılır ve benzer bilinmeyenler için sonuç tahmin etmek için kullanılır. Bu sonuç tahmin yöntemlerinden en sık kullanılanı sınıflandırma işlemidir. Sınıflandırma, işlem sonucunda verilerin ait olduğu sınıfı belirtir. Her bir girdi verisi için bir sınıf öngörür. Birden daha fazla girdinin olduğu durumlarda, sınıflandırma modeli yine birden daha fazla sonucun değerini tahmin etmeye çalışacaktır. Bu tahmin işleminin performansını ve doğruluğunu ölçmek amacıyla eğitilmiş modeller test işlemlerine tabi tutulur. Bazı durumlarda kullanılan algoritmalar kurulan modeldeki girdi verisini ezberleyerek yüksek doğruluk oranı sunmaktadır. Bu durum aşırı öğrenme olarak adlandırılmaktadır. Bu durumda test veri kümesinin doğruluk oranı, eğitim veri kümesinin doğruluk oranına göre düşük bir sonuç sunmaktadır. Aşırı öğrenmeyi engellemek amacıyla bu tez çalışmasında k-kez çapraz doğrulama (k-fold Cross Validation) tekniğinden yararlanılmıştır. Ayrıca seçilen algoritmaların performansları farklı performans ölçütleri ile sunulmuştur. Bu ölçütler ile ilgili açıklama ve formüller aşağıda detaylandırılmıştır.

4.1. Çapraz Doğrulama

Çapraz doğrulama (k-fold Cross-Validation), makine öğrenimi ile desteklenen veri analizi çalışmalarında yaygın olarak tercih edilen bir doğrulama yöntemidir. Temel amacı, bir modelin performansını değerlendirmektir. Modelin performansını en etkili şekilde değerlendirebilmek için öncelikle veri kümesi algoritmaların hesaplamalarına uygun girdi oluşturması için alt kümelerle ayrılır [32]. Bu ayırmadaki amaç, test kümesindeki verilerin eğitim kümesindeki verileri görüp öğrenmemesidir. Ayrılan alt kümeler eğitim ve test olarak iki alt kümeye daha ayrıldıktan sonra, eğitim kümesi ile eğitilen model, test alt kümesi ile test edilir [32]. Girdi veri kümesi belirlenen k katsayısı kadar alt kümeye bölünür ve her küme yine k katsayısı kadar model oluşturulur. Bu işlemlerin sonucunda test alt kümesindeki tercihlerin doğruluk oranlarının toplamı k değerine bölünür ve nihai sonuç elde edilir. K katsayısı, doğruluk tahminlerinin güvenilirliğini sağlayabilmek için yeterli büyüklükte belirlenmelidir. Öte yandan katsayı seçilirken işlem yükü ve zaman maliyetlerini de dikkate almak önemlidir. K için belirlenen zayıf bir değer, modelin ölçülen başarı performansının

gerçeğinden daha yüksek bir değer olarak tahmin edilmesine veya seçilen eğitim kümesindeki girdi değerlerine bağlı olarak büyük aralıklarda değişmesine neden olabilir.

4.2. Performans Ölçütleri

Sınıflandırma işlemlerinde performans ölçütlerinin hesaplamalarında kullanılmakta olan gerçek değer ve tahmin edilen sonuç karışıklık matrisi örnek alınarak hesaplanır. Tablo 4.1’de gösterilen karışıklık matrisindeki alanların anlamları aşağıda detaylandırılmıştır [33], [34].

Tablo 4.1. Karışıklık matrisi

		GERÇEK SINIF	
		Negatif	Pozitif
TAHMİN EDİLEN SINIF	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

DN (Doğru Negatif): Aslında Negatif olarak sınıflandırılan (0) verilere Negatif sınıf tahmini yapılarak sonucu doğru tahmin edilen verilen oranını göstermektedir.

DP (Doğru Pozitif): Aslında Pozitif olarak sınıflandırılan (1) verilere Pozitif sınıf tahmini yapılarak doğru tahmin edilen verilen oranını göstermektedir.

YP (Yanlış Pozitif): Aslında Negatif olarak sınıflandırılan (0) verilere Pozitif sınıf tahmini yapılarak yanlış tahmin edilen verilen oranını göstermektedir.

YN (Yanlış Negatif): Aslında Pozitif olarak sınıflandırılan (1) verilere Negatif sınıf tahmini yapılarak yanlış tahmin edilen verilen oranını göstermektedir.

Doğruluk (Accuracy): Sınıflandırma işlemi sonucunda tahmin edilen değerlerin doğruluk oranını gösterir. Dengesiz veri kümeleri kullanıldığında yeterince öğrenememiş modellerde yanıltıcı sonuçlar sunabildiği için tek başına güvenilir bir değer değildir. Denklem 1 ile hesaplanmaktadır.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Kesinlik (Presicion): Veri setinde tahmin edilen değerler sonucunda pozitif olarak sınıflandırılan verilerin doğruluk oranını göstermektedir. Denklem 2 ile hesaplanmaktadır.

$$Kesinlik = \frac{DP}{DP+YP} \quad (2)$$

Duyarlılık (Recall): Doğru sınıf olarak tahmin edilen pozitif değerlerin gerçekteki tüm pozitif sınıfa olan oranını göstermektedir. Duyarlılığın düşük oranlı yanlış tahminlerin fazla olduğunu, doğruların az olduğunu, duyarlılığın yüksek oranlı çıkması doğru tahminlerin fazla, yanlışların daha az olduğu anlamına gelmektedir. Denklem 3 ile hesaplanmaktadır.

$$Duyarlılık = \frac{DP}{DP+YN} \quad (3)$$

F1 Skor (F1 Score): F1 Skor duyarlılık ve kesinlik değerlerinin harmonik ortalamasını verir. F1 skoru, birden fazla modelin performansının karşılaştırıldığı çalışmalarda modellerin kesinlik ve doğruluk değerleri hesaplandıktan sonra en iyi modeli seçmek için kullanılmaktadır. Denklem 4 ile hesaplanmaktadır.

$$F1\ Skor = 2 * \frac{Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (4)$$

4.3. Deneysel Kurulum

Tez çalışması iki adımda gerçekleştirilmiş olup ilk adımda mekanik parçaların dijital tasarım görsellerinden oluşan hazır ve dengeli veri seti, ikinci adımda ise aynı parçaların gerçek fotoğrafları ile tasarım görselleri harmanlanıp oluşturulan veri seti kullanılmıştır.

Her iki adımda da oluşturulan veri setlerindeki görüntüleri sınıflandırmak için seçilen derin öğrenme modelleri iki farklı parametre grubu ile eğitilmiştir. Seçilen modellerin

performanslarını karşılaştırmak amacıyla epoch ve batch parametreleri değiştirilerek modelleme işlemi tekrarlanmıştır.

Modeller kurulurken pozitif değerleri ön plana çıkardığı için aktivasyon yöntemi olarak ReLU, optimizasyon yöntemi olarak da büyük veri setlerinde daha başarılı olduğu için Adam yöntemi seçilmiştir. Loss parametresi için de “categorical_crossentropy” seçilmiştir [35][36].

Modeller seçilen parametreler kullanılarak kurulduktan sonra veri görselleri ve sınıf etiketlerden oluşan girdi listeleri 5-kez çapraz-doğrulama metodu kullanılarak eğitim ve test veri kümelerine ayrılmıştır.

Bu tez çalışmasında sunulan görsellerin sınıflandırılması deneyinde uygulanmak üzere seçilen ESA modelleri iki farklı parametre grubu ile eğitilmiştir. Modellerin performanslarını karşılaştırmak amacıyla eğitim işlemi seçilen parametre grubundaki değerler değiştirilerek tekrarlanmıştır.

Tüm modeller başlangıçta parametrik olarak epoch 20 ve batch 8 olacak şekilde ayarlanmıştır ve öğrenme oranı değeri 0.001 olarak belirlenmiştir. Daha sonra hepsi 5 kat çapraz doğrulama ile eğitilmiştir. Her ESA modelinden hesaplanan doğruluk, kesinlik puanı, hatırlama/duyarlılık puanı, F1 puanı ve özgüllük puanı kaydedilmiştir.

Daha sonra yine aynı modeller epoch değeri 50 ve batch değeri 8 olarak değiştirilip tekrar kurulduktan sonra veri setlerindeki görseller kullanılarak 5-kez çapraz doğrulama ile eğitilmiş ve sınıflandırma sonuçlarındaki ölçümleri kaydedilmiştir.

Deneyin iki adımında da kullanılan veri setleri aynı parametre değişimleri ile oluşturulan aynı modellere girdi olarak kullanılmış ve sınıflandırma işlemleri tekrarlanmıştır.

4.4. Deney Sonuçları

Deneyin ilk aşamasında, sırasıyla seçilen parametrelerle eğitilen modeller dijital tasarım görsellerinden oluşan veri grubunun sınıflandırılması için uygulanmış ve sonuçlar tablolarda belirtilmiştir. Daha sonra ikinci veri setine yine aynı parametre grupları ile eğitilen modeller uygulanmış ve sonuçlar tablolarda belirtilmiştir. Tüm modellerde epoch parametresi 20 olarak ayarlanmış ve sınıflandırma sonuçlarından elde edilen karışıklık matrisleri Şekil 4.1 ile gösterilmiştir.

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	381	761	381	381
Pim	380	762	381	381
Somun	381	762	381	380
Rondela	381	761	381	381

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	0	762	762	380
Pim	0	761	762	381
Somun	0	762	761	381
Rondela	0	761	762	381






Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	1868	3	33	0
Pim	21	1319	17	547
Somun	304	106	1485	9
Rondela	23	1434	19	428

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	1173	10	698	23
Pim	0	214	365	1325
Somun	24	3	1870	7
Rondela	0	285	362	1257

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	1903	0	1	0
Pim	0	765	0	1139
Somun	12	1	1889	2
Rondela	0	787	0	1117

Şekil 4.1. Model Sonuçları Karışıklık Matrisleri (AlexNet – VGG – DenseNet – ResNet – Xception)

Tüm modellerin deney sonuçlarında elde ettiği doğruluk oranları Şekil 4.2.’de gösterilmiştir.



Şekil 4.2. Model Sonuçları Doğruluk Oranları (AlexNet – VGG – DenseNet – ResNet – Xception)

Bu sonuçlardan anlaşılacağı üzere tüm modeller 2 ve 4 olarak etiketlenen pim ve rondela görsellerini ayırt etmekte zorlanmaktadır. Ayrıca AlexNet ve VGG modelleri bu veri setini sınıflandırmakta başarılı olamamıştır. Tamamen karışık tahminlerde bulunmuş ve bir sonuca ulaşamamıştır. Diğer modeller ise daha tutarlı tahminlerde bulunmuş ve anlamlı sonuçlar sunmuştur.

Daha sonra tüm modellerde epoch parametresi 50 olarak ayarlanmış ve sınıflandırma sonuçlarından elde edilen karışıklık matrisleri Şekil 4.3 ile gösterilmiştir.

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	380	0	381	1143
Pim	381	0	381	1142
Somun	381	0	381	1142
Rondela	381	0	381	1142

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	0	1143	0	761
Pim	0	1143	0	761
Somun	0	1142	0	762
Rondela	0	1142	0	762


Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	1148	100	23	333
Pim	0	1218	0	686
Somun	31	141	1423	309
Rondela	0	1247	2	655

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	1178	2	676	48
Pim	0	623	6	1275
Somun	7	2	1894	1
Rondela	0	947	3	954

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	1904	0	0	0
Pim	1	728	0	1175
Somun	9	1	1893	1
Rondela	0	1053	0	851

Şekil 4.3. Model Sonuçları Karışıklık Matrisleri (AlexNet – VGG – DenseNet – ResNet – Xception)

Tüm modellerin deney sonuçlarında elde ettiği doğruluk oranları Şekil 4.4.’te gösterilmiştir.



Şekil 4.4. Model Sonuçları Doğruluk Oranları (AlexNet – VGG – DenseNet – ResNet – Xception)

Bu sonuçlardan anlaşılacağı üzere epoch değerini arttırmak modellerin tahmin başarısını arttırmıştır. Ayrıca modellerin başarısı oransal olarak artsa da başarı sıralaması değişmemiştir. İlk iki model yine anlamlı sonuçlar üretememiştir. Tablo 4.2’de epoch 20 parametresi ile kurulan modellerin ürettiği ortalama skorlar, Tablo 4.3’te ise epoch 50 parametresi ile kurulan modellerin ürettiği ortalama skorlar karşılaştırılmıştır.

Tablo 4.2. Model Sonuçları Karşılaştırması

Model	F1	Doğruluk	Duyarlılık	Keskinlik
AlexNet	0.24	0.28	0.25	0.25
VGG	0.20	0.25	0.25	0.24
DenseNet	0.55	0.30	0.55	0.65
ResNet	0.45	0.56	0.60	0.60
Xception	0.73	0.75	0.98	0.74

Bu sonuçlar incelendiğinde, ilk iki modelin neredeyse hiç eğitilmeden rastgele tahminlerde bulunduğu gözlemlenebilir. DenseNet modelinin ise tam anlamıyla güvenilir sonuçlar sunmadığı söylenebilir. Xception modelinin ise seçilen modeller arasında en güvenilir sonucu ürettiği görülmektedir.

Tablo 4.3. Model Sonuçları Karşılaştırması

Model	F1	Doğruluk	Duyarlılık	Keskinlik
AlexNet	0.20	0.27	0.24	0.18
VGG	0.16	0.25	0.29	0.12
DenseNet	0.63	0.35	0.61	0.68
ResNet	0.60	0.61	0.63	0.63
Xception	0.70	0.75	0.70	0.70

Epoch değeri yükseldikten sonra modellerin başarılı tahminlerde bulunma oranlarında artış gözlemlenmiştir ancak yine de ilk iki modelin çalışmadan sunulan problemin çözümde güvenilir bir yöntem olmadığı anlaşılmaktadır.

Çalışmanın devamında ikinci veri seti kullanılarak tekrardan tüm modellerde epoch parametresi 20 olarak ayarlanmış ve sınıflandırma sonuçları karışıklık matrisleri Şekil 4.5 ile gösterilmiştir.

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	103	80	147	70
Pim	80	110	143	67
Somun	94	82	155	69
Rondela	81	85	157	77

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	160	80	160	0
Pim	160	80	160	0
Somun	160	80	160	0
Rondela	160	80	160	0


Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	223	32	110	25
Pim	3	380	7	10
Somun	19	42	332	7
Rondela	7	22	34	327

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	243	22	118	17
Pim	1	384	11	4
Somun	23	38	332	7
Rondela	5	25	25	345

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	394	1	5	0
Pim	4	392	1	3
Somun	28	3	369	0
Rondela	1	4	0	395

Şekil 4.5. Model Sonuçları Karışıklık Matrisleri (AlexNet – VGG – DenseNet – ResNet – Xception)

Tüm modellerin deney sonuçlarında elde ettiği doğruluk oranları Şekil 4.6.’da gösterilmiştir.



Şekil 4.6. Model Sonuçları Doğruluk Oranları (AlexNet – VGG – DenseNet – ResNet – Xception)

Bu sonuçlardan anlaşılacağı üzere standart mekanik parçaların dijital tasarımlarına gerçek fotoğraflarının eklenmesi modellerin sınıflandırma başarılarını gözle görülür şekilde arttırmıştır. Yine VGG ve AlexNet modellerinin bu problemin çözümünde geride kaldığı anlaşılmıştır.

Daha sonra yine tüm modellerde epoch parametresi 50 olarak ayarlanmış ve sınıflandırma sonuçları karışıklık matrisleri Şekil 4.7 ile gösterilmiştir.

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	7	1	312	80
Pim	0	5	313	82
Somun	3	0	317	80
Rondela	1	0	318	81

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	80	80	160	80
Pim	80	80	160	80
Somun	80	80	160	80
Rondela	80	80	160	80


Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	369	18	3	10
Pim	9	381	2	8
Somun	58	32	290	20
Rondela	5	72	3	322

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	378	20	1	1
Pim	4	390	0	6
Somun	64	40	293	3
Rondela	4	77	2	317

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	389	1	9	1
Pim	0	391	2	7
Somun	10	4	386	0
Rondela	1	4	2	393

Şekil 4.7. Model Sonuçları Karışıklık Matrisleri (AlexNet – VGG – DenseNet – ResNet – Xception)

Tüm modellerin deney sonuçlarında elde ettiği doğruluk oranları Şekil 4.8.’de gösterilmiştir.



Şekil 4.8. Model Sonuçları Doğruluk Oranları (AlexNet – VGG – DenseNet – ResNet – Xception)

Bu sonuçlardan da anlaşılacağı üzere epoch değerini arttırmak ikinci veri setindeki görsellerin sınıflandırılmasındaki başarıyı da arttırmıştır. Ayrıca yine modellerin başarı sıralaması değişmemiştir. Farklı olarak dijital tasarım veri setindeki pim ve rondela örneklerindeki tahmin başarısızlığı gerçek görseller eklendiğinde çözülmüştür. Her parçada benzer tahmin başarıları alındığı gözlemlenmiştir.

Tablo 4.4'te ikinci veri seti kullanıldığında, epoch 20 parametresi ile kurulan modellerin ürettiği ortalama skorlar, Tablo 4.5'te ise epoch 50 parametresi ile kurulan modellerin ürettiği ortalama skorlar karşılaştırılmıştır.

Tablo 4.4. Model Sonuçları Karşılaştırması

Model	F1 Skor	Doğruluk	Duyarlılık	Keskinlik
AlexNet	0.25	0.27	0.29	0.28
VGG	0.26	0.25	0.30	0.25
DenseNet	0.60	0.65	0.65	0.75
ResNet	0.85	0.81	0.85	0.85
Xception	0.96	0.96	0.96	0.97

Tablo sonuçları karşılaştırıldığında modellerin başarı sıralamasının değişmediği ancak parçaların gerçek fotoğraflarının eğitim kümesine eklenmesinin özellikle son 3 modelin performansında büyük etkisi olduğu gözlemlenmiştir. Xception modelinin doğruluk oranı 0.75'ten 0.96'ya yükselerek neredeyse tamamıyla doğru tahminlerde bulunup başarılı bir sınıflandırma işlemi sağlamıştır.

Tablo 4.5. Model Sonuçları Karşılaştırması

Model	F1 Skor	Doğruluk	Duyarlılık	Keskinlik
AlexNet	0.33	0.26	0.01	0.28
VGG	0.25	0.25	0.20	0.25
DenseNet	0.92	0.67	0.92	0.75
ResNet	0.85	0.86	0.85	0.85
Xception	0.97	0.97	0.97	0.97

Epoch değerinin yükseltilmesi ilk veri kümesinde olduğu gibi gerçek fotoğraflar eklendiğinde de modellerin başarısına pozitif katkıda bulunmuştur. İlk 2 modelin bu katkılara rağmen problemin çözümünde kullanılabilir olmadığı kanıtlanmıştır. DenseNet modeli ise başarı oranını ilk deneye göre arttırmış olsa da ResNet ve Xception modellerinin gerisinde kaldığı gözlemlenebilir. Deneyler sonucunda anlaşılmıştır ki, problemin çözümü için bir model seçilecekse son 2 model arasından biri tercih edilebilir ve modellerin eğitimi mutlaka gerçek parça fotoğraflarıyla desteklenmelidir. Epoch parametresinin arttırılması bir miktar katkıda bulunsun da kaynak kullanımı açısından da tartışılıp karar verilmesi gereken bir işlem olarak anlaşılmıştır.

Tez çalışmasının ikinci aşamasında kurulan deneyde kullanılan veri kümesine mekanik parçaların gerçek fotoğraflarının eklenmesinin sınıflandırma işleminin başarısına katkısından emin olmak adına deneyler çeşitlendirilerek tekrarlanmıştır. Yapılan deneyler içerisinde en başarılı sonucu veren modelin epoch 50 parametresi ile kurulmuş olan Xception modeli olduğu anlaşıldıktan sonra kullanılan veri kümesi içerisindeki gerçek fotoğrafların oranı düşürülerek sınıflandırma başarıları gözlemlenmiştir. İlk olarak veri kümesi 80 fotoğraf ve 320 dijital tasarım görseli olacak şekilde ayarlanmıştır ve Xception modeli ile sınıflandırma işlemi gerçekleştirilmiştir. Deney sonucunda modelin doğruluk oranı 0.94'e gerilemiştir. İşlemin sonuçlarında elde edilen karışıklık matrisi Şekil 4.9. ile, performans ölçütleri ise Tablo 4.6 ile sunulmuştur.

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	378	5	10	7
Pim	8	380	4	8
Somun	35	3	359	3
Rondela	5	6	2	387

Şekil 4.9. Karışıklık Matrisi

Tablo 4.6. Model Sonucu Performans Ölçütleri

Model	F1 Skor	Doğruluk	Duyarlılık	Özgünlük	Hassasiyet
Xception	0.94	0.94	0.94	0.94	0.94

Sonrasında veri kümesi 40 fotoğraf ve 360 dijital tasarım görseli olacak şekilde ayarlanmıştır ve Xception modeli ile sınıflandırma işlemi gerçekleştirilmiştir. Bu deneyin sonunda ise modelin doğruluk oranı 0.90'a gerilemiştir. İşlemin sonuçlarında elde edilen karışıklık matrisi Şekil 4.10. ile, performans ölçütleri ise Tablo 4.7. ile sunulmuştur.

Sınıf	Cıvata	Pim	Somun	Rondela
Cıvata	381	5	11	3
Pim	3	379	5	13
Somun	19	8	366	7
Rondela	5	9	12	374

Şekil 4.10. Karışıklık Matrisi

Tablo 4.7. Model Sonucu Performans Ölçütleri

Model	F1 Skor	Doğruluk	Duyarlılık	Özgünlük	Hassasiyet
Xception	0.90	0.90	0.91	0.91	0.90

Son deneylerin sonuçlarından yola çıkarak anlaşılmıştır ki mekanik parçaların görsellerinin sınıflandırılmasında sadece dijital tasarım verileri yeterli olmamıştır. Küme içerisindeki gerçek fotoğraf oranı düştükçe modellerin tahminlerinin başarı oranı da düşmektedir. Böylelikle dijital tasarım görsellerinin mekanik parçaların gerçek görüntülerinin yerini tutamayacağından emin olunmuştur.

4.5. Çalışmanın Katkısı

Bu tez çalışması ile literatürde sıklıkla tercih edilen ESA modellerinin, mekanik parçalara ait görüntülerin sınıflandırılması probleminin çözümündeki performansları karşılaştırılmıştır. Modellerin sunulan problemin çözümündeki güçlü ve zayıf yanları gözlemlenmiştir. Bu amaçla deneysel çalışma iki adımda tamamlanacak şekilde tasarlanmıştır. İlk adımda standart mekanik parçaların dijital tasarım görsellerinden oluşan bir veri kümesi hazırlanmıştır. Bu veri kümesi civata, pim, somun ve rondela olacak şekilde 4 sınıfa ayrılmış ve sırasıyla etiketlenmiştir. Seçilen ESA modelleri kullanılarak girdi görselleri sınıflandırılmıştır. İşlem sonuçları değerlendirildiğinde Xception modeli 0.76'lık doğruluk skoru ile en başarılı model olurken, VGG 0.25'lik doğruluk ile en başarısız model olmuştur.

Çalışmanın ikinci aşamasında ise ilk sette kullanılan tasarım görselleri ile aynı parçalara ait gerçek fotoğraflar birleştirilerek yeni bir veri seti hazırlanıp tekrardan 4 sınıf olacak şekilde gruplanıp etiketlenmiştir. Aynı ESA modelleri yine aynı parametreler ile tekrardan sınıflandırma işlemi gerçekleştirilmiştir. İşlem sonuçları değerlendirildiğinde

Xception 0.97'lik doğruluk oranı ile en başarılı model olurken, VGG 0.25'lik doğruluk oranı ile en başarısız model olmuştur.

Deneylerin sonuçlarından yola çıkarak anlaşılmıştır ki, görece daha eski algoritmalar ile kurulmuş olan VGG ve AlexNet modelleri bu problemin çözümünde yeterli başarıyı yerine getirememiştir. ESA modellerinde zaman içinde yapılan çalışmaların desteğiyle elde edilen gelişmeler olumlu sonuçlar doğurmuştur ve her yeni çalışma görüntü işleme ve makine öğrenme teknolojilerine katkı sağlamaktadır [37][38]. Xception modelinin başarısı diğer modellere göre daha derin evrişim katmanları içeren bir algoritmaya sahip olması ve kullandığı özneteliklerin kullanılan görselleri sınıflandırmaya daha uyumlu olması olarak yorumlanabilir. Eski modellerin ise farklılıkları daha kolay ayırt edilebilecek veriler üzerinde başarılı olurken, çok sınıflı ve benzerlikler içeren veri kümelerinde yeterince başarılı olamayacağı söylenebilir.

Ayrıca deneyin ikinci adımında alınan sonuçların daha başarılı olduğu gözlemlenmiştir. Buradan da parçaların dijital tasarımları ne kadar gerçeğine uygun yapılsa bile gerçek fotoğrafların öğrenme algoritmalarına sağladığı katkı kadar başarılı sonuçlar vermediğini söylenebilir.

Ek olarak ikinci adım göstermiştir ki, sadece dijital tasarım görselleri kullanıldığında modeller pim ve rondela parçalarını ayırt etmekte zorlanırken, gerçek fotoğraflar eklenen ikinci veri setinde modeller bu zorluğu aşmış ve sınıflandırmada başarı sağlamıştır. Bu ayrımındaki zorluğun sebebi ise dijital tasarım verilerindeki ışık ve gölge eksikliklerinden ötürü bazı açılardan pim ve rondela görsellerinin oldukça benzer olması olarak yorumlanabilir. Fotoğraf çekildiğinde ise parlak ve gölge alanlar parçaların kıvrımlarını ve asıl şekillerini belirginleştirmektedir.

İki aşamadan oluşan ve farklı parametre grupları kullanılarak kurulan deneyler sonucunda yapılan hesaplamalar ışığında en yüksek sonuçlar elde edilen model Xception modeli olmuştur. Bu modelin hesap sonuçları en yüksek değer olmasına rağmen çalışma süresi ve kaynak kullanımı açısından diğer modellere göre daha fazla harcama yapmıştır. Bu nedenle çalışmada sunulan problemin çözümünde en başarılı model olarak nitelendirilemez. Modellerin başarısı problemin çözümündeki isterler ile ortam ve kaynak değişkenleri ile birlikte değerlendirilmelidir.

Sonuç olarak, birçok sektörde meydana gelen günlük problemlerin çözümüne derin öğrenme algoritmaları katkı sağlayabilecek seviyeye gelmiştir. Mekanik tasarım ve üretim endüstrisinde hemen her gün kullanılan standart parçaları sınıflandırabilen yazılımlar son kullanıcılara destek olabilir, ürün seçimi ve doğruluğu konusunda kişilere yol gösterebilir veya hatalı seçim yapmaması konusunda uyarılarda bulunabilir. Bu yazılımsal destekler ile endüstrilerde günlük işlemlerdeki hata oranları düşecek, verimlilik artacak ve sonucunda işletmelerin karlılığı artacaktır.

4.6. Geleceğe Yönelik Çalışmalar ve Sonuç

Bu tez çalışmasında, çeşitli teknikler kullanılmıştır ve standart mekanik parçalara ait görüntülerin sınıflandırılması yapılmıştır. Bu bölümde çalışmada elde edilen sonuçlar sunulmuştur. Çalışmada kullanılan ESA modellerinin başarılarının kesinlik, doğruluk ve duyarlılık değerleri hesaplanarak karşılaştırılmıştır ve hangi modelin sunulan problemin çözümüne daha uygun olacağı tartışılmıştır.

Problemin çözümü için kurulan deneyde literatürde görüntü sınıflandırmasında sıklıkla kullanılan ESA modelleri kullanılmıştır. Bu modeller batch ve epoch parametreleri değiştirilerek kurulmuş ve belirlenen veri setleri ile eğitilip test edilmiştir. Elde edilen sonuçlara göre daha detaylı öğrenim algoritmasına sahip olan göreceli olarak daha yeni modellerin daha başarılı olduğu görülmüştür.

Ayrıca kullanılan veri setinin içeriğinin de sonuçlarda oldukça etkili olduğu gözlemlenmiştir. Aynı parametrelerle kurulan modellerin eğitimlerinde dijital tasarım görsellerine ek olarak gerçek fotoğrafların da kullanılmasının sınıflandırma başarısını arttırdığı anlaşılmıştır. Son deneylerle de bu hipotez desteklenmiştir. Veri kümelerindeki gerçek fotoğraf oranları düşürüldüğünde ESA modelinin başarısında düşüş meydana gelmiştir.

Elde edilen sonuçlara göre Xception ESA modelinin her iki veri setinde de en başarılı olduğu anlaşılmıştır. Ancak bu modelin diğerlerine göre daha çok kaynak ve zaman kullanmasından dolayı planlanan yazılım desteğinin sistemi bu bilgiler göz önünde bulundurularak kurulmalıdır.

Bu çalışmanın devamı olarak bu problemin çözümü araştırılabilir. Çalışma zamanını hızlandıracak ve aynı zamanda başarısını devam ettirecek bir model kurulması için uygun parametreler tespit edilebilir.

Ayrıca sadece dijital tasarım görselleri kullanıldığında pim ve rondela parçalarını ayırt etmekte yaşanan zorluğun giderilmesi için de çalışmalar yapılabilir. Veri setindeki görseller daha ayırt edici olabilmesi için çeşitli görüntü işleme yöntemleri kullanılarak ön işlemlerden geçirilebilir.

5. KAYNAKLAR

- [1] “Cıvata Nedir?” MakinaEgitimi.com. <https://www.makinaegitimi.com/civata-nedir-civata-cesitleri-ve-ozellikleri/> (Accessed: 07/2024)
- [2] “Somun Nedir?” MakinaEgitimi.com. <https://muhendistan.com/somun-nedir-cesitleri-nelerdir/> (Accessed: 07/2024)
- [3] “Pim Nedir?” MakinaEgitimi.com. <https://www.makinaegitimi.com/pimler-pim-cesitleri-ve-standartlari-konu-anlatimi/> (Accessed: 07/2024)
- [4] “Rondela Nedir?” MakinaEgitimi.com. <https://muhendistan.com/rondela-nedir/> (Accessed: 07/2024)
- [5] “CAD (computer aided design) Nedir?”. cadprogramlari.com. <https://www.cadprogramlari.com/cad-computer-aided-design-ne-demek/> (Accessed: 07/2024)
- [6] Philip O. Adejumobi; Oluwadare A. Adebisi; Iyabo I. Adeaga; Abiodun A. Baruwa; Kolawole M. Ajala. (Volume. 8 Issue. 4, April- 2023) "Automatic Classification of Mechanical Components of Engines using Deep Learning Techniques.", International Journal of Innovative Science and Research Technology (IJISRT), www.ijisrt.com. ISSN- 2456-2165, PP:- 2028-2037. <https://doi.org/10.5281/zenodo.8265646>
- [7] Taheri, Benjamin & Haladjian, Juan & Bruegge, Bernd. (2019). “Fine-Grained Visual Categorization of Fasteners in Overhaul Processes.” 241-248. 10.1109/ICCAR.2019.8813486.
- [8] A.K. Amit, S. B. Dhiraj, and M. J. Prashil, “An application for the separation of nuts and bolts using image processing and artificial intelligence,” International Journal of Latest Technology in Engineering, Management and Applied Science (IJLTEMAS), vol. 7, No.1, pp. 1-3, 2018.
- [9] D. Amol, A.S. Khobragade, S. Ambarish, “Mechanical nut-bolt sorting using principle component analysis and artificial neural network,” International Journal of Applied Information Systems (IJ AIS), pp. 1-3, 2018.

- [10] M. Rucco, F. Giannini, K. Lupinetti, and M. Monti, “A methodology for part classification with supervised machine learning,” *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, vol. 33, pp. 100-113, 2019.
- [11] Rucco, Matteo & Giannini, Franca & Lupinetti, Katia & Monti, Marina. (2018). “A methodology for part classification with supervised machine learning. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*.” 33. 1-14. 10.1017/S0890060418000197.
- [12] Johan, Teuku & Prabuwno, Anton Satria. (2011). “Recognition of bolt and nut using artificial neural network.” *Proceedings of the 2011 International Conference on Pattern Analysis and Intelligent Robotics, ICPAIR 2011*. 1. 10.1109/ICPAIR.2011.5976889. M.J.
- [13] Sangpil Kim et al, 2020, “A Large-scale Annotated Mechanical Components Benchmark for Classification and Retrieval Tasks with Deep Neural Networks”, Purdue University,
- [14] Kızrak, M.A., Bolat, B., 2018, “Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma”, *Bilişim Teknolojileri Dergisi*, (11) 3: 263-286
- [15] J. Gu et al., “Recent advances in convolutional neural networks, *Pattern Recognit.*”, vol. 77, pp. 354–377, 2018.
- [16] T. Wang, D. J. D. J. Wu, A. Coates, and A. Y. Ng, “End-to-end text recognition with convolutional neural networks, *ICPR, Int. Conf. Pattern Recognit.*”, no. May, pp. 3304–3308, 2012.
- [17] B. Xu, N. Wang, T. Chen, and M. Li, “Empirical Evaluation of Rectified Activations in Convolutional Network”, *J. Foot Ankle Res.*, vol. 1, no. S1, p. O22, May 2015.
- [18] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, “Activation Functions: Comparison of trends in Practice and Research for Deep Learning”, *arXiv Prepr. ArXiv1811.03378*, Nov. 2018.

- [19] S. Hochreiter, “The vanishing gradient problem during learning recurrent neural nets and problem solutions”, *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 6, no. 02, pp. 107–116, 1998.
- [20] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, “Improving neural networks by preventing co-adaptation of feature detectors”, pp. 1– 18, 2012.
- [21] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: A Simple Way to Prevent Neural Networks from Overfittin”, *J. Mach. Learn. Res.*, vol. 1, no. 60, p. 11, 2014.
- [22] Alom Z. et. al. “The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches”, *Computer Vision and Pattern Recognition*, 2018.
- [23] E. Rezende, G. Ruppert, T. Carvalho, A. Theophilo, F. Ramos et al., “Malicious software clas- sification using VGG16 deep neural network’s bottleneck features,” in *Information Technology-New Generations. Advances in Intelligent Systems and Computing*, S. Latifi (Eds.), vol. 738. Cham: Springer, pp. 51–59, 2018.
- [24] Kaiming He Xiangyu Zhang Shaoqing Ren Jian Sun, “Deep Residual Learning for Image Recognition”, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)
- [25] Gao Huang; Zhuang Liu; Laurens Van Der Maaten; Kilian Q. Weinberger, "Densely Connected Convolutional Networks", 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)
- [26] F. Chollet, “Xception: Deep learning with depthwise separable convolutions,” in *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, July 21– 26, Honolulu, HI, USA: IEEE, pp. 1251–1258, 2017.
- [27] Wes McKinney and the Pandas Development Team, “pandas: powerful Python data analysis toolkit” Release 1.2.4 Apr 12, 202 Apr 12, 2021
- [28] Seaborn, “NumPy Reference”, Release 1.20 Date January 31, 2021

- [29] Matplot Overview — Matplotlib 3.4.1 documentation
- [30] Keras, Developer guides (keras.io)
- [31] Tensorflow Guide | TensorFlow Core
- [32] Refaeilzadeh, Payam & Tang, Lei & Liu, Huan. (2009). “Cross-Validation. Encyclopedia of Database Systems”. 532–538. 532-538. 10.1007/978-0-387-39940-9_565.
- [33] D. Mishkin, N. Sergievskiy and J. Matas, “Systematic evaluation of convolution neural network advances on the imagenet,” Computer Vision and Image Understanding, vol. 161, no. 2, pp. 11–19, 2017.
- [34] D. Datta, R. Agarwal, I. Tuteja, V. B. Vedula and P. K. Maurya, “Optimization of an automated examination generation system using hybrid recurrent neural network,” International Journal of Interdisciplinary Global Studies, vol. 14, no. 4, pp. 246–255, 2020.
- [35] A. GERON, “Hands-on machine learning with scikit-learn, Keras, and tensorflow: Concepts, tools and techniques to build Intelligent Systems.” Beijing; Boston; Farnham etc.: O'Reilly, 2019.
- [36] C. M. BISHOP, “Pattern recognition and machine learning.” SPRINGER-VERLAG NEW YORK, 2016.
- [37] C. Chakraborty, B. Gupta and S. K. Ghosh, “Identification of chronic wound status under tele-wound network through smartphone,” International Journal of Rough Sets and Data Analysis, vol. 2, no. 2, pp. 58–77, 2015.
- [38] L. Garg, E. Chukwu, N. Nasser, C. Chakraborty and G. Garg, “Anonymity preserving IoT-based COVID-19 and other infectious disease contact tracing model,” IEEE Access, vol. 8, pp. 159402– 159414, 2020.
- [39] Amraee et al., “Visual Computing for Industry”, Biomedicine, and Art <https://doi.org/10.1186/s42492-022-00111-6> (2022) 5:13

- [40] Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). "Deep learning for visual understanding: A review." *Neurocomputing*, 187, 27-48.
- [41] Castelluccio, M., Poggi, G., Sansone, C., & Verdoliva, L. (2015). "Land use classification in remote sensing images by convolutional neural networks." *arXiv preprint arXiv:1508.00092*.
- [42] Adler, A., Elad, M., & Zibulevsky, M. (2016). "Compressed Learning: A Deep Neural Network Approach." *arXiv preprint arXiv:1610.09615*.
- [43] Yang, J., Nguyen, M. N., San, P. P., Li, X., & Krishnaswamy, S. (2015, July). "Deep Convolutional Neural Networks on Multichannel Time Series for Human Activity Recognition." In *IJCAI* (pp. 3995-4001).
- [44] Xiao, T., Li, H., Ouyang, W., & Wang, X. (2016, June). "Learning deep feature representations with domain guided dropout for person re-identification." In *Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on* (pp. 1249-1258). IEEE.
- [45] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). "Improving neural networks by preventing co-adaptation of feature detectors." *arXiv preprint arXiv:1207.0580*.
- [46] Ioffe, S., & Szegedy, C. (2015, June). "Batch normalization: Accelerating deep network training by reducing internal covariate shift." In *International conference on machine learning* (pp. 448-456).