

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
TEZLİ YÜKSEK LİSANS PROGRAMI**

**KÂĞIT BARDAK MAKİNESİNİN OTOMASYONU VE GERÇEK
ZAMANLI GÖRÜNTÜ İŞLEMeye DAYALI HATALI ÜRÜN TESPİT
YÖNTEMİ**

HAZIRLAYAN

ALAADDİN AYDIN

YÜKSEK LİSANS TEZİ

ANKARA - 2022

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
TEZLİ YÜKSEK LİSANS PROGRAMI**

**KÂĞIT BARDAK MAKİNESİNİN OTOMASYONU VE GERÇEK
ZAMANLI GÖRÜNTÜ İŞLEMeye DAYALI HATALI ÜRÜN TESPİT
YÖNTEMİ**

HAZIRLAYAN

ALAADDİN AYDIN

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DOÇ. DR. SELDA GÜNEY

ANKARA – 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Alaaddin Aydın tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 23 / 08 / 2022

Tez Adı: Kağıt Bardak Makinesinin Otomasyonu Ve Gerçek Zamanlı Görüntü İşlemeye Dayalı Hatalı Ürün Tespit Yöntemi

Tez Jüri Üyeleri (Unvanı, Adı- Soyadı, Kurumu)

İmza

Prof. Dr. Sedat Nazlıbilek

.....

Dr. Öğr. Üyesi Bülent İRFANOĞLU

.....

Doç. Dr. Selda GÜNEY (Başkent Üniversitesi)

.....

ONAY

Prof. Dr. Ömer Faruk ELALDI

Fen Bilimleri Enstitüsü Müdürü

Tarih: / / 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 07/09/2022

Öğrencinin Adı, Soyadı: Alaaddin AYDIN

Öğrencinin Numarası: 21820279

Anabilim Dalı: Elektrik-Elektronik Mühendisliği

Programı: Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı: Doç. Dr. Selda Güney

Tez Başlığı: Kâğıt Bardak Makinesinin Otomasyonu Ve Gerçek Zamanlı Görüntü İşlemeye Dayalı Hatalı Ürün Tespit Yöntemi

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 54 sayfalık kısmına ilişkin, 07/09/2022 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %18'dir. 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: 07 / 09 / 22

Öğrenci Danışmanı Doç Dr. Selda Güney

TEŞEKKÜR

Lisans ve yüksek lisans eğitimim boyunca desteğini hiç esirgemeyen, karşılaştığım her probleme cevap veren çok değerli danışman hocam Sayın Doç. Dr. Selda Güney'e en içten saygı ve teşekkürlerimi sunarım.

Akademik hayatım ve eğitim hayatım boyunca karşılaştığım her problemde bilgileriyle yardımcı olan, fikirleriyle başarıma katkı sağlayan Prof. Dr. Sedat Nazlıbilek'e teşekkür ederim.

Çalışmamda kullandığım verileri hazırlarken verdikleri destek için Miscup A.Ş şirketine teşekkür ederim. Literatüre katkı sağlayan tüm akademisyen ve öğrencilere teşekkür ederim.

Tüm eğitim hayatım boyunca her zaman arkamda olan, emeklerini bir an olsun esirgemeyen, her türlü fedakârlığı karşılıksız gerçekleştiren ve başarılarımla her zaman gurur duyan eşime, aileme ve yakınlarıma teşekkür ederim.

ÖZET

Alaaddin AYDIN

KÂĞIT BARDAK MAKİNESİNİN OTOMASYONU VE GERÇEK ZAMANLI GÖRÜNTÜ İŞLEMEYE DAYALI HATALI ÜRÜN TESPİT YÖNTEMİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2022

Ülkemizde kâğıt bardak üretimi yapan firma sayısı her geçen gün giderek artmaktadır. Karton bardak basımı yapan makineler Çin, Kore vb. ülkelerde üretilmektedir. Türkiye’de de yerli olarak üretilen makineler vardır. Bu makinelerde bardaklar 4, 7, 8, 12 oz diye tabir edilen ölçülerde basılmaktadır. Servo motor, asenkron motor gibi motorlar ile makineler kontrol edilmektedir. Makine üstüne takılan sensörler ve ısıtıcı rezistanslar yardımıyla kaliteli ve fire kaybı az olan bardaklar basılmaktadır. Bu çalışmada daha önce üretimi yapılmış olan bardak basma makinesini servo motor, asenkron motor ve PLC ile kontrol ederek, görüntü işleme tabanlı hata tespiti yapan ve hatalı ürünü ayıklayan bir sistem tasarlanmıştır. Hata tespiti için gerçek zamanlı bir kamera aracılığıyla derin öğrenme yöntemlerinden Yolo ve Haarcascade algoritmaları kullanılarak sınıflandırma, OpenCv kütüphanesi kullanılarak da gerçek zamanlı nesne tespiti gerçekleştirilmiştir. Tespit edilen hatalı bardak bir piston ile üretim bandından alınıp bir kutuya atılmaktadır. Sensörler, servo motor enkoderi ve kullanıcı tarafından gelen komutlarla servo motor sürücüsüne komutlar verilmektedir. Asenkron sürücü parametreleri sürücü üzerinden ayarlanmaktadır. Bütün komutlar kullanıcı tarafından bir ekran üzerinden girilebilmekte ve üretilen ürünlerin sayısı yine ekran üzerinde kurulan sistem üzerinden izlenebilmektedir. Çalışmanın yapay zeka kısmında hatalı bardakların tespiti için önceden kendi oluşturduğumuz veri setinden alınan veriler Python dilinde ve Google Colab ortamında, YOLO algoritmasının modelleri ile sınıflandırılmıştır. Modeller eğitildikten sonra Jupyter Lab (tümleşik geliştirme ortamı) üzerinde OpenCv kütüphaneleri kullanılarak gerçek zamanlı olarak kameradan gelen veriler tespit edilmiştir.

Haarcascade algoritması kullanılarak eğitilen modeller, gerçek zamanlı olarak PyCharm üzerinde OpenCv kütüphanesi kullanılarak tespit edilmiştir. Farklı derin öğrenme yöntemlerinin gerçek zamanlı sistemde performans üzerine etkisi incelenmiş ve başarılı

sonular elde edilmiřtir. En bařarılı sonu Yolov5x mimarisi kullanılarak gerekleřtirilen gerek zamanlı uygulamada % 90,8 doėruluk oranı ile elde edilmiřtir.

ANAHTAR KELİMELELER: Servo Sistem, Asenkron Motor ve İnvörtör, PLC, HMI, Derin Öğrenme, CNN, YOLO, Haarcascade



ABSTRACT

Alaaddin AYDIN

AUTOMATION OF THE PAPER CUP MACHINE AND DETECTION METHOD BASED ON REAL-TIME IMAGE PROCESSING

Başkent University Institute of Science and Engineering

Department of Electrical and Electronics Engineering

2022

The number of companies producing paper cups in our country is increasing day by day. Paper cup printing machines are produced in countries such as China, Korea, etc. There are also domestically produced machines in Turkey. These machines can print paper cups in sizes called 4, 7, 8, 12 oz. Machines are controlled by motors such as servo motors and asynchronous motors. With the help of sensors and heating resistances mounted on the machine, high quality cups with less waste loss are printed. In this study, a system that controls the previously produced cup press machine with servo motor, asynchronous motor and PLC, makes image processing based error detection and removes the faulty product is designed. For error detection, classification using the deep learning methods Yolo and Haarcascade algorithms through a real-time camera, and real-time object detection using the OpenCv library. The detected faulty cup is taken from the production line with a piston and thrown into a box. Commands are given to the servo motor driver with the commands from the sensors, the servo motor encoder and the user. Asynchronous drive parameters are set on the drive. All commands can be entered by the user on a screen and the number of products produced can be monitored over the system installed on the screen. In the artificial intelligence part of the study, the data obtained from the dataset we created beforehand for the detection of faulty cups were classified with the models of the YOLO algorithm in the Python language and Google Colab environment. After the models were trained, data from the camera were detected in real time using OpenCv libraries on Jupyter Lab (integrated development environment). The data trained using the Haarcascade algorithm were detected in real time using the OpenCv library on PyCharm. The effect of different deep learning methods on performance in the real-time system has been examined and successful results have been obtained. The most successful result was obtained with 90.8% accuracy in real-time application using YOLOv5x architecture.

KEYWORDS: Servo System, Asynchronous Motor and Inverter, PLC, HMI, Deep Learning, CNN, YOLO, Haarcascade



İÇİNDEKİLER

Sayfa

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
TABLolar LİSTESİ	viii
ŞEKİLLER LİSTESİ	ix
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ	1
1.1. Çalışmanın Konusu.....	1
1.2. Çalışmanın Amacı ve Önemi.....	1
1.3. Literatür Özeti	2
1.4. Genel Bakış	5
2. KURAMSAL TEMELLER	6
2.1. Servo Motor	6
2.1.1. DC servo motor	6
2.1.2. AC servo motor	7
2.1.3. AC servo sürücü kontrol	8
2.1.4. AC servo sürücü sürme modları	9
2.1.5. Pozisyon-hız-tork modları	9
2.2. Asenkron Motor	11
2.2.1. Asenkron motor frekans inverteri	12
2.3. PLC.....	13
2.3.1. PLC seçimi	14
2.3.2. PLC input output birimi.....	14
3. YAPAY ZEKA	15

3.1. Makine Öğrenmesi.....	17
3.2. Derin Öğrenme.....	17
3.3. Evrişimsel Sinir Ağı.....	19
3.3.1. Evrişim katmanı (convolutional layer).....	20
3.3.2. Havuzlama katmanı (pooling layer).....	20
3.3.3. Tam bağlantılı katman (fully connected layer).....	20
3.3.4. Aktivasyon katmanı (activation layer).....	21
4. MATERYAL VE METOT.....	22
4.1. Otomasyon Sistemi Çalışması.....	22
4.2. Motorların Seçimi.....	24
4.3. Asenkron Motor Tanıtma İşlemi ve Parametre Ayarı.....	24
4.4. Servo Motor Sürücüsü Sürme ve Kontrol.....	26
4.4.1. Servo sürücü PLC haberleşmesi.....	26
4.4.2. Servo sürücü parametre ayarları.....	27
4.4.3. Servo PLC yazılımı.....	31
4.4.4. Sistemin PLC yazılımı.....	32
4.4.5. HMI tasarımı.....	34
4.5. Veri Seti.....	34
4.6. YOLO Algoritması.....	36
4.7. Haarcascade Algoritması.....	38
5. DENEYSEL ÇALIŞMA VE SONUÇLAR.....	40
5.1. Yolov5 Modelleri.....	41
5.2. Yolov5 Algoritma Başarı Sonuçları.....	42
5.3. Modellerin Doğruluk ve Kayıp Sonuçları.....	43
5.3.1. Yolov5 modellerinin grafikleri.....	44
5.3.2. Haarcascade yazılım ve test Süreci.....	48
5.4. Kısıtlar.....	48
6. SONUÇ VE ÖNERİLER.....	49
7. KAYNAKLAR.....	50

TABLÖLAR LİSTESİ

	Sayfa
Tablo 4-1 Giriş terminalleri parametreleri, standart fabrika ayarları[40]	25
Tablo 4-2 Çıkış terminalleri parametreleri, standart fabrika ayarları[40].....	26
Tablo 5-1 Yolo Modelleri Değerleri	41
Tablo 5-2 Veri seti geçerleme (validation) sınıflandırma sonuçları	42
Tablo 5-3 Gerçek Zamanlı Nesne Tespiti Doğruluk Sonuçları	43



ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2-1 Dc Servo Motor İç Yapısı.....	7
Şekil 2-2 AC servo motor.....	8
Şekil 2-3 Pozisyon Mod	10
Şekil 2-4 Hız Mod	10
Şekil 2-5 Tork Mod	11
Şekil 2-6 Asenkron Motor.....	12
Şekil 2-7 PLC Gösterimi	13
Şekil 3-1 Yapay Zeka ve Alt Birimler	16
Şekil 3-2 Derin Öğrenme Modeli	18
Şekil 3-3 CNN Mimarisi	21
Şekil 4-1 Sistem Blok Diyagramı.....	22
Şekil 4-2 Otomasyon panosu.....	23
Şekil 4-3 Bardak Basma Makinesi	23
Şekil 4-4 Modbus Bağlantı Şeması	26
Şekil 4-5 Modbus Bağlantı Görseli	27
Şekil 4-6 Adım-1	28
Şekil 4-7 Adım-2	28
Şekil 4-8 Adım-3	29
Şekil 4-9 Adım-4	29
Şekil 4-10 Adım-5	30
Şekil 4-11 MR-JE-FX5U Hazır Blok Diyagram	31
Şekil 4-12 Blok Diyagram Ayarlar	32
Şekil 4-13 FBD Dili Örnek Gösterim 1	33
Şekil 4-14 FBD Dili Örnek Gösterim 2	33
Şekil 4-15 Hatasız Bardak Örneği.....	35
Şekil 4-16 Hatalı Bardak Örneği	35
Şekil 4-17 Fabrika ortamı bardak görünümü	35
Şekil 4-18 Tez çalışması kapsamında gerçekleştirilen yazılım blok diyagramı	36
Şekil 4-19 Bir girdi görüntüsünün ızgaralara bölünmesi	37
Şekil 4-20 Haarcascade çalışma prensibi	39
Şekil 5-1 Yolov5s Sınıflandırma Doğruluk Grafiği	44

Şekil 5-2 Yolov5s Sınıflandırma Kayıp Grafiği	44
Şekil 5-3 Yolov5n Sınıflandırma Doğruluk Grafiği	45
Şekil 5-4 Yolov5n Sınıflandırma Kayıp Grafiği	45
Şekil 5-5 Yolov5m Sınıflandırma Doğruluk Grafiği	46
Şekil 5-6 Yolov5m Sınıflandırma Kayıp Grafiği	46
Şekil 5-7 Yolov5x Sınıflandırma Doğruluk Grafiği	47
Şekil 5-8 Yolov5x Sınıflandırma Kayıp Grafiği	47



SİMGELER VE KISALTMALAR

FC	Fully Connected Layer (Tam Evrişimsel Ağ)
CNN	Convolutional Neural Network (Evrişimsel Sinir Ağları)
YSA	Yapay Sinir Ağı
PLC	Programmable Logic Controller (Programlanabilir Mantık Devresi)
HMI	Human Machine Interface (İnsan Makine Arayüzü)
RPM	Revolution Per Minute (Dakikadaki Devir Sayısı)
DC	Direct Current (Doğru Akım)
AC	Alternative Current (Alternatif Akım)
MLP	Multi Layer Perceptron (Çok Katmanlı Ağ)
KW	Kilowatt
IOT	Internet of Things
YOLO	You Only Look Once
RTU	Remote Terminal Unit
IOU	Intersection Over Union

1. GİRİŞ

1.1. Çalışmanın Konusu

Endüstriyel fabrikalarda ve imalat yapılan yerlerde makine panosunun tasarlanması, ürünün kalitesi ve maliyet açısından önemlidir. Sistemin pano tasarımında farklı sürücüler ve motorlar kullanılmaktadır. Servo sistemler kullanılarak daha hassas ve kaliteli üretim yapılması hedeflenmektedir [1]. Bunun yanında üretim yapılan ürünlerden fireli ürünlerin ayrıştırılması hem maliyet hem de üretim yapan firmanın marka değeri açısından çok önemlidir. Hatalı ürünlerin son kullanıcıya gitmemesi istenmektedir. Ayrıştırma işlemi için işçi çalıştırılması maliyet açısından da kötü bir durumdur. Makine öğrenimi yapılarak hatalar tespit edilip ayrıştırılabilmektedir. Fakat son yıllardaki derin öğrenme yöntemlerinin özellikle görüntü işleme alanında gelişmesi ile hata tespit oranı daha iyi seviyelere gelmektedir. Anlık görüntü alıp, görüntüyü sınıflandırma ve daha önce eğitilmiş modeller ile görüntüleri çok daha iyi şekilde işleyebilme derin öğrenme metodu ile gerçekleştirilebilmektedir. Bu yöntem, hata tespit oranı açısından büyük bir katkı sağlamaktadır. Karton bardak görüntülerinin barındırdıkları şekil bozukluğuna göre sınıflandırılması sonucu hata tespit ve tanıma sistemlerinde daha doğru sonuçlara ulaşılması hedeflenmektedir.

Bir makinenin otomasyon sisteminin verimli çalışması firmanın ismi ve makinenin ömrü açısından önemlidir. Teknoloji kullanılarak tasarlanan bir makinenin ürettiği ürününün hatalı olması durumunda ise hata tespiti ve hatalı ürünün ayrıştırılması gerekmektedir. Bu çalışma ile makine otomasyonuna katkı sağlayacak, görüntü işleme tabanlı hatalı bardakları ayıran derin öğrenme yöntemlerinden Yolo ve Haarcascade algoritmalarını kullanan gerçek zamanlı sınıflandırma uygulaması gerçekleştirilmiştir.

1.2. Çalışmanın Amacı ve Önemi

Tezin amacı sistem için gerekli doğru otomasyon sisteminin kurulması, hatalı ürün tespit oranının derin öğrenme metodu kullanarak doğru sınıflandırılması ile başarı oranını artırmaktır.

Kağıt bardak makinesinde üretim yapılırken bardak tabanının basımı esnasında bardağı basım yerine getiren mekanik sistem için seçilmesi gereken motor çok önemlidir. Sistemde hız, tork ve pozisyon hassasiyeti en önemli parametrelerdendir. Hassasiyet gerektiren işlerde (robot kolu ile ürün alma, hassas kesim ve büküm vs.) genellikle servo motor kullanılmaktadır. [2],[3]

Servo motorun hangi yöntem ile sürüleceği önemli bir konudur. Servo motorun pozisyon modda, pulse ile sürülmesiyle gidilmesi gereken pozisyon miktarının kaçırılabilirdiği görülmüştür. Aynı zamanda Modbus harici servo sürme yöntemlerinde elektriksel gürültü (parazit) olma olasılığı mevcuttur.

Servo motorun Modbus ile sürülmesi elektriksel gürültüyü azaltacağından ve istenilen pozisyonu tam olarak yakalayacağından sürücüyü Modbus yöntemi ile haberleştirmek uygun bir çözüm olarak görülmektedir.

Tek veya iki yönlü, hız ayarı olabilen sistemlerde ve yine hassasiyet gerektirmeyen makinelerde asenkron motorlar kullanılmaktadır. Asenkron motor sürücüleri ile hız kontrolü yapılmaktadır. [4]

Kağıt bardak makinesinde kağıt basılırken hatalı ürünün her seferinde bir insan tarafından ayrıştırılması için takip edilmesi gerekmektedir ki, bu çok zor ve maliyetli bir durumdur. Bu sorunun önüne geçmek amacıyla gerçek zamanlı görüntü alan ve nesne tespiti yapan derin öğrenme tabanlı algoritmalar ile nesne tespit edilip, hatalı/hatassız sınıflandırılması gerçekleştirilmiştir.

1.3. Literatür Özeti

Derin öğrenme (AI), insanların belirli bilgi türlerini kazanma şeklini taklit eden makine öğreniminin bir alt dalıdır. Derin öğrenme, istatistik ve tahmine dayalı modellemeyi içeren veri biliminin önemli bir unsurudur. Derin öğrenme yoluyla büyük miktarda veriyi toplamak, analiz etmek ve yorumlamak çok daha kolay ve işlevsel hale gelmiştir. [5,6]

Abdulsamet Aktaş, 2020 yılında yaptığı çalışmalarında obje tespit etme alanında en başarılı modellerden olan You Only Look Once- Version 3(YOLO-V3) modelini DenseNet

modeli ile birleřtirerek YOLOV3-Dense modeli oluřturmuřtur. 4580 etiketli gorsel bulunan Marmara Dokunsal Parke Yuzeyi (MDPY) veri seti uzerinde YOLO-V2, YOLO-V3 ve YOLOV3-Dense modellerini ayrı ayrı eęitmiř ve bu modellerin performanslarını test veri seti uzerinde karřılařtırılmıřtır. %81 Intersection Over Union (IoU) ,%89 F1-skor ve %92 ortalama hassasiyet deęerleri ile dokunsal parke yuzeyi tespit etme oranının YOLOV3-Dense modelinde dięer modellere gore oldukca bařarılı olduęu gozlemlenmiřtir. [7]

Oęuzhan Cömlekçi, 2020 yılında yaptıęı calıřmalarında gercek bir endüstriyel tesiste, kullanılmakta olan sıcak hava fırınında (yakıt borularının form kazanması iin oluřturulan otomasyonel makina) meydana gelen arızaların sınıflandırmasını yapay zeka yöntemleriyle yapmıřtır. Sıcak hava fırını Microsoft Visual Studio platformunda C# form uygulaması uzerinde modellenmiřtir. Bu sıcak hava fırını ortaya ıkabilecek arıza durumlarına gore bir veri seti oluřturulmuřtur. Farklı yapay zeka yöntemlerinin arıza tespiti iin sınıflandırma performansı kıyaslanmasını gercek sistemden elde edilen bu veri seti kullanılarak Microsoft Visual Studio platformunda gercekleřtirmiřtir. [8]

Karakter tanıma uygulaması olarak adlandırılan, YOLOv4 modeli kullanılarak yapılan, Bangladeř'te trafikte bulunan araçların plakalarını tespit etme calıřması Onim vd. tarafından geliřtirilmiřtir. Modelin eęitimi iin veri artırma, ęrenimin transferi (transfer learning) kullanılmıř ve MobileNetv2 mimarisi seilmiřtir. Fotoęraf veri seti, Bangladeř trafięinden alınan video grnts kullanılarak oluřturulmuř ve model 6000 epok kullanılarak eęitilmiřtir. Yaklařık %90 ortalama doęruluk oranı bařarısı grlmřtr. Sonulara gore modelin hızlı ve bařarılı olduęu tespit edilmiřtir. [9]

Hinzmann ve ark. İHA'lardan alınan kızıltesi ve optik grntleri kullanarak derin ęrenme yöntemleriyle insan tespiti uzerinde calıřmıřlardır. Evriřimli sinir aęı mimarilerinde kızıltesi ve optik grntleri birleřtirmek ve sonuları izlemek bu calıřmanın amacıdır. Oluřturulan veri seti farklı RetinaNet ve YOLO modelleri ile calıřtırılmıř ve sonular karřılařtırılmıřtır. Ayrıca karřılařtırmalarda RetinaNet modeli tarafından kullanılan odak kaybı optimizasyonu ve YOLOv3 modeli tarafından kullanılan apraz entropi kaybı dikkate alınmıřtır. Elde edilen sonularda YOLOv3 modeli, RetinaNet modeline gore daha bařarılı olduęu grlmřtr. RetinaNet mimarisinin daha bařarılı olmasının nedeninin, n plan ve arka plan arasındaki byk dengesizlikle bařa ıkmak iin kullandıęı odak kaybı iřlevi olduęu belirtilmektedir. [10]

Sarıbaşı, Çevikalp ve Kahveci, insansız hava araçlarından alınan görüntülerde arabaları tespit etme ve bulma probleminde çok yönlü konik sınıflandırıcı kullanan nesne konum bulma algoritması ile en hızlı ve en iyi sonuçları veren YOLOv2 algoritmasını karşılaştırmak için bir çalışma yapmışlardır. Çalışmada, insansız hava aracından elde edilen yaklaşık 10000 görüntü içeren kendi oluşturdukları veri setini kullanarak, 8 kök sezicili EPCC algoritmasının ortalama doğruluk oranı açısından en iyi sonucu verdiğini, hız açısından da YOLO-Tiny algoritmasının en iyi sonucu verdiğini bulmuşlardır. [11]

Yüksek performanslı tek atışlı bir dedektör olan YOLO modeli, Ophoff ve ark.'nın çalışmasında kullanılmıştır. Uydu görüntülerinden oluşan veri seti üzerinde araç ve gemi tespiti ve sınıflandırması ile ilgili deneysel bir çalışma yapılmıştır. ImageNet ve DOTA ile önceden eğitilmiş ağırlık verileri ve YOLO modelleri (YOLOv2, YOLOv3, D-YOLO ve YOLT) ile elde edilen sonuçlar hem çalışma zamanı hem de doğruluk açısından karşılaştırılmış ve en uygun modelin DYOLO olduğu belirlenmiştir. [12]

Son yıllarda kullanılmaya başlayan takip ve tespit etme yöntemleri hakkında literatür çalışmaları incelenmiştir. Obje tespitinde Single Shot Detector (SSD) [13] ve YOLO [14] gibi farklı metodlar kullanılmakla birlikte genellikle Faster R-CNN ve türevlerinin kullanıldığı da belirtilmiştir. [15]

Stanford üniversitesinin drone veri setini alan Wang ve arkadaşları yapmış oldukları çalışmada SSD ve Faster-RCNN mimarilerini RetinaNet algoritmasını kullanarak karşılaştırmışlardır. Çalışma sonucunda, tek aşamalı SSD mimarisinin %80,42 ve iki aşamalı Faster-RCNN mimarisinin %83,63 ortalama doğruluk oranı değerlerini tespit etmişlerdir. Tek aşamalı mimarilerin, iki aşamalı mimarilere yaklaştığı başarı sonuçlarından görülmüştür. [16]

Benjdira ve arkadaşları bir araç gözetimi ve trafik izleme senaryosu gerçekleştirmek için tek aşamalı YOLOv3 ve iki aşamalı Faster R-CNN modelini karşılaştırmıştır. İHA'lardan alınan görüntülerden oluşan veri setini kullanarak yaptıkları çalışmada, başarı ve işlem süresi kapsamında performans değerlendirmesini tartışmışlardır. Çalışma çıktılarına göre her iki yöntemde de kullanılan veri setindeki nesne tahmin başarı oranı en az %99 ve üzeri olmuştur. Ancak YOLOv3 algoritmasının Faster-RCNN modeline göre daha başarılı olduğu ve daha yüksek hatırlamaya sahip olduğu bulunmuştur. [17]

Tüm bu çalışmalar derin öğrenme mimarilerinin endüstriye uygulanabileceğini göstermektedir. Bu tez çalışmasında da endüstride şimdiye kadar ele alınmayan bir probleme makine öğrenmesi algoritmaları uygulanarak görüntü işleme tabanlı otomasyon sisteminin temelleri oluşturulmuştur.

1.4. Genel Bakış

Bu çalışma temel olarak 6 bölümden oluşmaktadır ve endüstriyel bir uygulamada kullanabilecek gerçek zamanlı görüntü işlemede, farklı yöntemlerin başarı oranlarına etkisi incelenerek literatüre katkı sağlamıştır. Buna ek olarak Mitsubishi marka motor ve PLC ile otomasyon sistemi kurulmuş ve endüstriyel bu uygulama için fiyat performans ilişkisinin gösterilmesi ile yine literatüre katkı sağladığı düşünülmektedir.

İlk bölümde çalışmanın konusu, amacı ve önemi sunulmaktadır. Buna ek olarak literatür taraması çerçevesinde çalışmamıza benzer nitelikte gerçek zamanlı derin öğrenme yöntemleri ile alanında yapılmış çalışmalar kronolojik sıra içerisinde sunulmuş ve özetlenmiştir.

Çalışmanın ikinci bölümünde, donanımsal özellikler temel bilgiler kapsamında servo ve asenkron motor özellikleri ve PLC donanımı başlıklarında değinilmektedir.

Üçüncü bölümde, yazılım kısmında kullanılan yöntemler genel olarak anlatılmaktadır.

Çalışmanın dördüncü bölümünde, materyal ve metot kapsamında motorların parametre ayarları, PLC ve HMI gibi donanımsal cihazların yazılım ve tasarımları ve bu çalışma kapsamında kullanılan derin öğrenme yöntemleri ve parametreleri ele alınmaktadır.

Beşinci bölümde otomasyon tasarımı kapsamında yapılan analizlerden ve derin öğrenme modellerinin başarı sonuçlarından bahsedilmektedir.

Çalışmanın altıncı bölümünde çalışma kapsamında yapılan tüm analizler ve elde edilen sonuçlar değerlendirilmiş ve önerilerde bulunulmuştur.

2. KURAMSAL TEMELLER

2.1. Servo Motor

Servo motor; açısal veya doğrusal konumun, hızın ve ivmenin hassas kontrolünü sağlayan bir döner aktüatör veya lineer aktüatördür. Lineer aktüatörler, bir şeyi bir eksen boyunca genellikle ileri geri hareket ettirir, döner aktüatörler ise dairesel olarak herhangi bir derecede döndürür. [18]

Konum geri beslemesi için bir sensöre bağlı uygun bir motordan oluşur. Servo motorlar belirli bir motor sınıfı değildir, ancak servo motor terimi genellikle kapalı devre kontrol sisteminde kullanıma uygun bir motoru belirtmek için kullanılır. Servo motorlar AC ve DC olmak üzere ikiye ayrılır.


2.1.1. DC servo motor

Geri besleme sistemini içeren DC motordur. Motorun mili, gelen kodlu sinyale göre konum alır. Motora gelen sinyal değiştikçe motor milinin konumu da değişir [10]. En çok robot teknolojisinde kullanılır ve fırçasız motor olarak da isimlendirilmektedir. Normal DC motorlar, rotor, stator, fırça ve komutatörden oluşurken, DC servo motor ise sadece stator ve rotordan oluşur. Hız, tork ve fazla güç gereken yerlerde bu motor kullanılır. 0.05 hp ile 1000 hp'ye kadar DC servo motorunun imalatı vardır.

DC servo motor 0 ile 180 derecelik açıları kontrol etmek için kullanılmaktadır. Motorun döneceği miktar PWM tarafından iletilir. Bu yazılımsal olarak belirlenir. PWM kare dalgalarından oluşur. Her puls motora güç vermektedir. Açısal hareketin olması için bir kare dalga 20ms olarak gönderilmelidir.

Darbenin uzunluğu, motorun ne kadar döneceğini belirlemektedir. Örneğin darbe 1.5 ms den az ise motor 0 dereceye yakın olacak, darbe 1.5 ms den büyükse şaft 180 dereceye yaklaşacaktır.

Servo motorların açısai adım sayıları iki şekilde belirlenir. 1-2 ms arasında gönderilen puls veya 1.25-1.75ms arasında gönderilen puls miktarı ile belirlenir. Bu değere uygun 20ms lik pulsler üreterek DC servo motor kontrolü sağlanır. Şekil 2-1’de DC servo motor görölmektedir.



Şekil 2-1 Dc Servo Motor İç Yapısı

2.1.2. AC servo motor

Hareket mekanizması olarak, alternatif akım elektrik motorları ile aynı özelliklere sahiptir, ancak AC Servo motorlar, AC motorlardan farklı olarak enkoder kısmına sahiptir. Encoder yardımı ile açısai hassasiyette dönme kabiliyeti kazandırılmış olur.

Genellikle iki veya üç fazlı olarak üretilmektedir. Bu motorların rotorları kısa devre çubuklu veya doğal mıknatıslıdır. Bu motorlar asenkron veya senkron motorlara benzemektedir. [19]

AC Servo Motorlar dairesel alanda hareket ettiklerinden dolayı 360° bir açı oluştururlar. Servo motorların hassasiyeti adım sayısı ile belirtilir. Bir adım da kat edilen açı miktarı ne kadar kısa olursa servo motor hassasiyeti de o kadar yüksek olur. Bir örnek ile açıklayacak olursak bir tam turunu 400 adımda tamamlayan bir servo motorun tek açı derecesi $360/400=0,9^\circ$ derecedir. Bu adım derecesi hassasiyetin göstergesidir. Hassas bir

servo motor elde etmek için servo motorun adım sayısı artırılmalıdır. Fakat adım sayısı ile maliyette artacaktır.



Şekil 2-2 AC servo motor

AC Servo Motor Özellikleri:

- AC motorlara göre daha hassas ve uzun ömürlüdür.
- Yüksek güç gereken yerlerde DC Servo motor yerine kullanılır.
- Yüksek frekans değerlerinde çalışabilecek motorlar vardır.
- CNC kontrollü makineler için uygundur.
- DC Servo motorlara göre daha düşük moment ile çalışırlar.

2.1.3. AC servo sürücü kontrol

Sinusoidal darbe genişlik modülasyonu ile çalışan, analog veya dijital yapıda sürücü sınıfına sahip kontrol sistemleri olarak adlandırılırlar. Geri besleme olarak hall sensör, çözümleyici artırımı enkoder veya mutlak enkoder kullanılır. [20]

Servo sürücü, kontrolörden gelen düşük güçlü emir sinyallerini yüksek voltaja ve akıma çevirmektedir. Farklı uygulamalarda değişmek üzere servo sürücü motorun gerekli konumunu, hızını ve torkunu ayarlayabilir. Servo sürücüler kendi kontrol döngüsü üzerinden kontrolöre bir sinyal göndermek için negatif geri beslemeden yararlanır.

Hareketli uygulamalarda sürücü, milin konumunun gerçek değeri ile istenen değeri arasındaki ilişkiyi anlayarak motora bir sinyal gönderebilir. Özünde, servo sürücü gerekli akım veya voltaj ayarlarını yaparak o andaki motor durumu ile istenen motor durumu

arasındaki farkı düzenlemeye yarar. Servo sürücüler, sistemin ihtiyacına göre motorun sönümlleme, geri besleme kazancı ve sertlik durumlarını ayarlayabilir. Bu da hassasiyet gerektiren uygulamalarda çok büyük avantaj sağlar.

2.1.4. AC servo sürücü sürme modları

Servo motorlar kontrol motorları olmakla birlikte elektrik motorlarıdır ve özellikle kontrol sistemlerinde sistemin çıkışındaki hareketin kontrolünü sağlamak üzere tasarlanmış ve üretilmiştir.

Servo motorların güç değerleri watt ile birkaç yüz kilowatt arasında olabilir. Bir servo motor normalde düşük veya sıfır hızda çalışır, bundan dolayı servo motorun boyutu aynı tork veya güç değerlerine sahip diğer motorlara göre daha büyüktür.


Kontrol edilen parametreye göre servo sistem tork modunda, hız modunda veya pozisyon modunda çalıştırılabilir. Tüm modlar servo sürücünün ve kontrolörün gerekli parametreleri takip etmesine ve gerekli performansı yakalamak için motora doğru komutları vermesi gereken kontrol döngülerini içerir.

Servo motorların kullanım alanı günden güne artmaktadır. Robotlarda, radar sistemlerinde, CNC'lerde, kaynak makinelerinde, preslerde, paketleme ve sarım makinelerinde, tıbbi cihazlarda, hava sürücülerinde vb. kullanımı gözükmemektedir. [21]

2.1.5. Pozisyon-hız-tork modları

Pozisyon modda kontrol sistemi, geri besleme elemanının motor milinden aldığı anlık hız değerinin konum bilgisine dönüştürülmesiyle gerçekleşir. Aslında K_p sabiti ile çarpılan konum bilgisinin geri besleme bilgisine dönüştürülmesi işlemidir.


Servoyu pozisyon modunda kontrol etmek için aslında üç kontrol döngüsünün de olması gereklidir ki bunlar tork, hız ve konum kontrolleridir. Motor milinin konumunu belirlemek için motorun hızının izlenmesi ve motorun komut verilen konuma gitmesi için ne kadar akıma ihtiyacı olduğunu belirlemek gereklidir. Pozisyon kontrol döngüsü PI veya PID (orantılı-integral-türev) kontrolörü kullanır. [22]



Şekil 2-3 Pozisyon Mod

Hız modu kontrol sisteminde motorun hızı ayarlanır ve tüm servo sürücülerde bu mod bulunmaktadır. Motorun geri beslemesinden gelen anlık hız verisi sürücüye gönderilir ve bu veri ayarlanan değer ile karşılaştırılarak eşit olması sağlanır.


Motorun değişen yükler altında belirli bir hızı koruması gerekebilir, bu gibi durumlarda hız modu kullanılır. Hız modu ile kontrol sisteminde motor hızı, motora gönderilen voltaj ile kontrol edilir. Ancak motorun hızını değiştirmek, motorun torkunda bir artma veya azalma gerektirir ve bu nedenle hız modunda bir akım kontrol döngüsü de gereklidir. [23]



Şekil 2-4 Hız Mod

Tork modu kontrol sistemi motorun momentini istenilen değerde sabit tutmak için uygulanmaktadır. Motorun akımı ile momentini orantılı olduğundan, servo kontrolör servo sürücünden o andaki motor akımını alır ve yine o andaki motor torkunu belirlemek için kullanır. Daha sonra o andaki tork değerini istenen tork ile karşılaştırır ve istenen torku sağlamak için motora verilen akımı ayarlar.

Genellikle bir PI kontrolör akım kontrol döngüsünü ayarlar ve akım döngüsü parametreleri ise çoğunlukla üretici tarafından ayarlanır.




Şekil 2-5 Tork Mod

2.2. Asenkron Motor

Asenkron motorlar indüksiyon motoru olarak da adlandırılırlar, stator sargılarına uygulanan elektrik enerjisini mekanik enerjiye çeviren elektrik makineleridir. [4]

Düşük maliyetli, basit ve sağlam yapılı, düşük bakım ihtiyacı, değişik yük durumları için iyi çalışma karakteristiği, çalışma esnasında ark yapmama özelliklerinden ötürü sık kullanılırlar. 4 kW üzerindeki motorlar 3 fazlı olarak üretilirler.

İndüksiyon motorlarında stator sargısı (alan sargıları) kaynağa bağlanır. Rotor sargıları (armatür sargıları) bir tarafı kısa devre edilip, diğer tarafı harici dirençlere bağlanır. Bu tür motorların sabit stator sarımlarından geçen AC, döner manyetik alan oluşturur. İndüksiyon motorları tek uyarımlı motorlardır. İndüksiyon motorlarında oluşan döner manyetik alan rotor sarımlarında akım indükler. Bu akımlar kabloların etrafında manyetik alan oluşturur. Bu manyetik alan dönen ana manyetik alanı takip eder. İndüksiyon motorunun çalışması rotor döngülerinden geçen döner alana bağlıdır ve hızı her zaman döner alanın hızından daha yavaştır (asenكرون hız). Rotorun akım beslemesine gerek olmamasından dolayı yapısı basit, çalışması güvenilirdir. [24] Asenkron çalışma hızlarından dolayı, indüksiyon makinelerine asenkron makineler de denir.



Şekil 2-6 Asenkron Motor

2.2.1. Asenkron motor frekans inverteri

Üç fazlı Asenkron ve PM motorlarının basit, güvenilir ve ucuz olması nedeniyle endüstriyel uygulamalarda özellikle tercih edilmektedir. Motorun devrini iki faktör belirlemektedir:

- Üç fazlı akımın frekansı.
- Motor sargısının tasarımı (kutup sayısı).

Besleme gerilimi frekansı genellikle sabit 50 Hz'dir; dolayısıyla motor devri sabittir. Motor devri sadece sargı yapısı değiştirilerek farklı uygulamalar için değiştirilebilir. Frekansın 50 Hz seçilmesinden sonra motor sürekli sabit bir devirde çalışacaktır. Örneğin 3.000 rpm veya 1.500 rpm. Birden fazla devir elde edilmesi, ancak çift sargıya (2 sargı, 4 taneye kadar farklı motor devrini etkinleştirebilir) sahip kutup değiştirmeli motorlarla mümkündür. Kutup değiştirmeli motorlarda bundan daha fazla farklı devir ve sürekli olarak değiştirilebilir devir elde edilemez. Bu sorunun çözümü bir sürücü ile halledilmektedir. Sürücü şebeke beslemesinin sabit gerilimini ve frekansını değişken frekans ve değişken gerilime çevirir. Şebeke ile motor arasına monte edilir ve tek sargılı standart bir motoru değişken hızlı tahrik sistemine çevirmek suretiyle sürekli değişken devir ayarı yapılabilmesini sağlar. [40]

Bağlanan motorun devri, invertörün çıkış gerilimi ve frekansı değiştirilerek sürekli olarak ayarlanabilir. Sürücülerin başka faydaları da vardır bunlar arasında ayarlanabilir hızlanma ve yavaşlama zamanı, tork artırma, entegre elektronik termik akım koruması sağlar.

2.3. PLC

PLC, bilgisayar ara yüzü yardımı ile makine ve robot kontrolü sağlayan, bir fabrikadaki tüm üretim aşamalarındaki cihazlarda bulunan ve o cihazların kontrolünü sağlayan, karışık kumanda yapılarının, programlama mantığıyla yazılarak, aritmetik ve mantıksal işlemlerin yapıldığı kontrol cihazıdır. Her PLC için üretici firma tarafından hazırlanan programlama ara yüzü bulunmaktadır. Günümüzde ortak bir ara yüz (codesys) hazırlama çalışmaları devam etmektedir.

Otomasyon sistemlerinin bulunduğu her fabrikada ve her makinada PLC kullanılmaktadır. En büyük avantajları ise, toza, sıcaklığa, elektriksel gürültülere, mekanik darbelere karşı dayanıklı olmalarıdır. Bundan dolayı endüstride programlama yapılırken çoğu zaman saha şartları göz önünde bulundurularak PLC kullanılmaktadır.



Şekil 2-7 PLC Gösterimi

2.3.1. PLC seçimi

PLC yazılımı yapılmadan önce hangi tür ve kapasitesi ne olacak gibi soruların cevabı çok önemlidir. Sistemdeki giriş ve çıkış sayısına, işlem hızına, analog giriş ve çıkış olup olmamasına göre seçim yapılır. PLC'lere harici olarak dijital ve analog olmak üzere giriş ve çıkış modülleri eklenebilir. PLC'lerde hızlı sayıcı girişi olması da önemli bir avantajdır. PLC'ler source veya sink bağlantılı, röle veya transistör çıkışlı olarak çeşitli şekillerde üretilirler. Yine 24V veya 220V besleme ile çalıştırılabilirler. Otomasyon yapılacak sisteme göre seçim yapılmalıdır. Bunların piyasada çeşitleri vardır. [25]

2.3.2. PLC input output birimi

PLC'lerde giriş ve çıkış sayıları değişmektedir. Dijital 16 giriş/16 çıkış, 8 giriş/16 çıkış vb tarzları vardır ve bunlar ihtiyaca göre seçilir. Analog olarak PLC'lerde 0-10 v ve 4-20 ma girişleri ve çıkışları mevcuttur. Bunlar sensörlerden gelen veriler olabilirler.

- PLC'ye harici olarak analog modül de eklenebilir.
- PLC, PC ile rs232 ve rs485 çeviriciler ile bağlanabilir.
- PLC'ler, HMI olarak adlandırılan ekranlar ve motor sürücüleri vb. ile de haberleşirler.
- Profibus, Profinet, Modbus, Modbus RTU, Cc Link gibi haberleşme yöntemleri vardır. Genellikle PLC'ler ethernet kablosu üzerinden haberleştirilirler. [26]

3. YAPAY ZEKA

Yapay Zeka (artificial intelligence) kelimeleri ilk defa 1956 yılında kullanıldı ve veri miktarlarının artması, bilgi işlem adı altındaki ilerlemeler ve bilgilerin depolanması ile ilgili ortaya çıkan sorunlara insanların çözüm bulmada zorlanması sebebiyle gelişmiş algoritmalara sahip yapay zeka bu sorunları çözmeye başlaması nedeniyle popüler hale geldi. [27]


Yapay zeka; sağlık, bankacılık, eğitim vb. sektörlerde kullanılmaya başlandı. Yapay zekanın amacı makinelerle insan zekası kazandırmaktır.

Makinelerin daha akıllı hale gelmesi, insanlar gibi davranabilmesi ve bunun yanında düşünebilmesine yönelik çalışmalar yapılmaktadır. Makineler problem çözme ve insanlardan daha iyi düşünmek için eğitilmektedir. Örnek olarak otonom araçlar, robotlar vs.

Makine Öğrenimi denetimli, denetimsiz ve yarı denetimli öğrenme olmak üzere üç sınıfa ayrılmaktadır: Verilerin analiz edilmesi, toplanması, filtrelenmesi, algoritmaların eğitilmesi, test verilerinin oluşturulması makine öğrenimi adı altında gerçekleştirilir. [28]

Derin Öğrenme, insan beynindeki nöronlardan ilham alınarak oluşturulmuştur ve makine öğrenimi tekniklerinden biridir. Bir veri seti ile sonuçların tahmin edilmesi ve birden fazla katmandan oluşan sistem derin öğrenme ile gerçekleştirilir. Yapay zekanın eğitilmesi için hem denetimli hem de denetimsiz öğrenme yöntemi tercih edilebilir.

Sonuç olarak derin öğrenmenin makine öğrenmesinin bir alt dalı olduğu, makine öğrenmesinin de yapay zekanın bir alt dalı olduğu söylenebilir. Yapay zeka tüm öğrenme algoritmalarını kapsar. Şekil 3-1’de yapay zeka ve alt dalları gösterilmiştir.



Şekil 3-1 Yapay Zeka ve Alt Birimler

Yapay zeka çok geniş bir kullanım alanına sahiptir. Ses tanıma sistemleri, görüntü işleme, doğal dil işleme, muhakeme gibi konu başlıklarında oldukça yaygın kullanılmaktadır.

Günlük hayatımızda siber güvenlik ve savunma sanayi, sesli asistanlar, dil çevirileri, öneri sistemleri, navigasyon, sosyal güvenlik, sağlık hizmetleri, e-ticaret ve yardımcı robot uygulamaları yapay zekanın bizlere katkı sağladığı örnek alanlardır.

Yapay zeka tekniklerine aşağıdaki sistemler örnek olarak verilebilir.

- Tavlama Benzetimi (Simulated Annealing),
- Uzman Sistemler (Expert Systems),
- Bilgisayarlı Görme (Computer Vision),
- Konuşma Tanıma (Speech Recognition),
- Yapay Sinir Ağları (ANN: Artificial Neural Networks),
- Bulanık Mantık (Fuzzy Logic)

3.1. Makine Öğrenmesi

Bir sorunu çözmek için mevcut verilerden ve deneyimlenmiş bilgilerden öğrenen yönteme makine öğrenmesi (Machine Learning) denir ve bir makine öğrenmesinin çalışma sistemi aşağıdaki gibi listelenebilir:

- Sorunun tanınması,
- Eğitim ve test verilerinin toplanması,
- Verileri tanımlayan özelliklerin oluşturulması veya çıkarılması,
- Kayıp fonksiyonunun optimize edilmesi için modelin eğitilmesi
- Eğitilmiş modelin görünmeyen test verileri üzerindeki performansını değerlendirmek için modeli test etme.

Denetimli veya denetimsiz olarak öğrenme, makine öğrenmesinde probleme göre değişebilir. Denetimsiz öğrenmeye kümeleme örneği ve denetimli öğrenmeye de sınıflandırma ve regresyon verilebilir. [29]

3.2. Derin Öğrenme

Derin öğrenme, insan beyninin çalışmasından esinlenerek geliştirilmiştir. Sistemlerin verileri kümelemesine ve büyük doğrulukta tahminler yapmasına imkan tanır.

Derin öğrenme, makine öğreniminin bir alt dalıdır ve temelde üç veya daha fazla katmana sahip bir sinir ağı vardır. Bu sinir ağları, insan beyninin davranışını taklit etmeye çalışır ve oldukça yüksek miktardaki veriden öğrenim sağlar. Tek katmanlı bir sinir ağı yaklaşık tahminler yapabilirken, ek gizli katmanlar ise doğruluğu optimize etmeye ve iyileştirmeye yardımcı olabilir. Derin öğrenme ile otomasyon sistemlerinin insan müdahalesi olmadan gerçekleştirilmesi yapılabilmektedir.

Derin öğrenme sinir ağları veya yapay sinir ağların da giriş verileri, ağırlıklandırmalar ve yanlılık (bias) kombinasyonu yoluyla insan beyni gibi öğrenmeye ve çıktı vermeye çalışır. Bunlar verilerdeki nesnelerin tanınması, sınıflandırılması ve tanımlanması için birlikte çalışır.


Derin sinir ağı, birbirine bağlı birden çok düğüm katmanlarından oluşur ve her biri bir önceki katmanın üzerine kurulur. Bunlar tahmin veya sınıflandırmayı iyileştirmek ve optimize etmek için yapılır. Sinir ağı üzerinden yapılan hesaplamaların ilerlemesine, ileriye doğru yayılma (forward propagation) denir. [30]

Derin bir sinir ağının giriş ve çıkış katmanlarına görünür katmanlar denir. Giriş katmanı, derin öğrenme modelinin verileri işlemek üzere geldiği yer, çıktı katmanı ise tahmin veya sınıflandırmanın yapıldığı yerdir.

Geri yayılım (back propagation) ise, tahminlerdeki hataları hesaplamak için gradyan azaltma (gradient descent) gibi algoritmalar kullanır ve arkasından modeli eğitmek için katmanlar arasında geriye doğru hareket ederek fonksiyonun ağırlıklarını ve yanlılık değerlerini ayarlar.

Derin öğrenme algoritmalarında farklı türlerde sinir ağıları vardır. Örneğin, bilgisayarla görme ve görüntü sınıflandırma uygulamalarında Evrişimli Sinir Ağları (Convolutional Neural Network) kullanılır. [31]

Tekrarlayan sinir ağı (Recurrent Neural Network, RNN) ise dil ve konuşma tanıma uygulamalarında kullanılır. [31]



Şekil 3-2 Derin Öğrenme Modeli

3.3. Evrişimsel Sinir Ağı

CNN, görsel loblarda (öncelikle biyolojik beyinlerde) meydana gelen biyolojik süreçlerden ilham alabilen, sinir ağının özel bir ileri besleme türüdür. Görüntü ve video işlemede yaygın olarak kullanılmaktadır.

CNN, birden çok gizli seviye içeren benzersiz bir topolojiye sahip çok katmanlı bir ağıdır (MLP). Özellik çıkarımı için kullanılan yerel olarak bağlı birkaç katmanı ve ardından sınıflandırma için kullanılan bir dizi tam bağlı (FC) katmanı birleştirerek geleneksel MLP'lerden farklıdır. [32]

CNN, herhangi bir uygun normalleştirme olmaksızın ilk giriş bilgisinden kendi seviyelerinin ayırt edici özelliklerini otomatik olarak çıkaracaklarından, görüntü işleme, el yazısı tanıma ve ses tanımda temel olarak nesne tanıma için kullanılır.

Bu modül türü, dahili yapılarla (görüntüler gibi) veri girişi için ve sabit işlevselliğin bulunması gereken durumlarda kullanışlıdır. CNN kullanmanın temel sorunlarından biri, genel problemlere bakılarak elde edilemeyebilecek manuel olarak tasarlanmış giriş işlevlerinden kaçınmaktır.

CNN mimarisi özellik çıkaran sinir ağı ve sınıflandırma ağı olmak üzere iki bölüme ayrılabilir. Görüntüler ve zaman serisi verileri gibi çeşitli eğitim verilerinden son derece temsili, hiyerarşik özellikleri verimli bir şekilde işleme ve öğrenme konusundaki güçlü yetenekleri, görüntü analizi, video sinyali işleme, doğal dil sinyal işleme dahil olmak üzere birçok alanda uygulamalarını görmektedir. [31]

Şekil 3-3' de görüldüğü üzere CNN mimarisi, genel olarak üç temel katman türünden oluşur. Bunlar evrişim katmanları, havuz katmanları ve tam bağlı katmanlardır. Bir evrişim ve havuz katmanı çiftleri yığını, bir CNN'nin özellik çıkarma bloğunu oluşturur. Sınıflandırma bloğu, özellik çıkarma bloğundan çıkarılan özelliklere dayalı olarak girdinin sınıf tahminini gerçekleştiren tam bağlantılı katmandan oluşur. Daha gelişmiş CNN mimarileri, aktivasyon katmanı, toplu normalleştirme (batch size), bırakma katmanları (drop out layers) vb. gibi belirli işlevleri olan çeşitli katmanları içerir.

3.3.1. Evriřim katmanı (convolutional layer)

Evriřim katmanı, CNN mimarisinin bel kemiğidir. Adından da anlaşılacağı gibi, evriřim işlemine dayanmaktadır. Bu katman, yeni özellik haritaları oluşturmak için girdinin uzamsal boyutluluğu boyunca kıvrılan bir dizi evriřim filtresinden (çekirdekler) oluşmaktadır. Evriřim katmanı tarafından oluşturulan özellik haritalarının sayısı, filtrelerin sayısına eşittir. Evriřim katmanındaki her nöron, giriş hacminin yalnızca küçük bir bölgesine bağlıdır. [33]

3.3.2. Havuzlama katmanı (pooling layer)

Aşağı örnekleme katmanı olarak da bilinen havuzlama katmanı, tipik bir CNN mimarisinde genellikle evriřim katmanını takip eder. Katman, girdi özellik haritalarının uzamsal boyutunu ve dolayısıyla ağı eğitilebilir parametrelerinin sayısını azaltmayı amaçlar. [34] Havuzlama süreci boyunca, temsil, öteleme ve küçük bozulmalara karşı neredeyse değişmez hale gelir. [34] Ayrıca, havuzlama işlemi CNN mimarisinin hesaplama karmaşıklığını azaltmaya yardımcı olur. Havuza alınan özellik haritalarının sayısı, havuzlama katmanı işleminden sonra aynı kalır. Çoğu CNN'de havuzlama işleminin filtre boyutu 2×2 pikseldir. Girdinin uzamsal boyutları boyunca 2'lik bir adımla uygulanır. Yaygın olarak kullanılan iki havuzlama işlemi, maksimum havuzlama ve ortalama havuzlama içerir. Ortalama havuzlama, özellik haritasındaki her yama için ortalama değeri hesaplar. Maksimum havuzlama, giriş özelliği haritasının her bir yaması için maksimum değerleri çıkarır.


3.3.3. Tam bağlantılı katman (fully connected layer)

Tam bağlantılı katman (Fully Connected Layer, FCL), önceki sıralı evriřim ve havuzlama işlemlerinden elde edilen görüntülerin özellik haritalarının bir birleşimi olan tek boyutlu bir özellik vektörünü girdi olarak alır. FCL katmanı genellikle, önceki katmandaki her nöronu bir sonraki katmandaki her nörona doğrudan bağladığı CNN mimarisinin sonunda bulunur. Nihai tam bağlı katman, tipik olarak sınıf sayısı ile aynı sayıda çıktı düğümüne sahiptir. [42]

3.3.4. Aktivasyon katmanı (activation layer)

Literatürde genellikle bir aktivasyon fonksiyonu veya transfer fonksiyonu olarak adlandırılan aktivasyon katmanı, performansını doğrudan etkilediği için CNN mimarisinin önemli bir bileşenidir. Aktivasyon fonksiyonu, bir sinir ağındaki bir katmanın girdilerinin ağırlıklı toplamının nasıl bir çıktıya dönüştürüleceğini tanımlar. [35] Aktivasyon fonksiyonları, temsil ettikleri fonksiyona göre lineer veya lineer olmayan olabilir. Ayrıca bir CNN mimarisinin farklı aşamalarında farklı aktivasyon fonksiyonları kullanılmaktadır.

Türevlenebilir doğrusal olmayan etkinleştirme işlevleri genellikle bir sinir ağındaki gizli katmanlara yerleştirilir ve burada doğrusal çıktıları doğrusal olmayan çıktılara dönüştürerek ağı verilerdeki karmaşık kalıpları öğrenmesini sağlar. Sorun alanına bağlı olarak, bir ağı çıkış katmanında genellikle farklı aktivasyon fonksiyonu kullanılır. Günümüzde çoğu CNN tabanlı mimaride kullanılan en yaygın etkinleştirme işlevleri arasında Sigmoid, hiperbolik tanjant (Tanh) ve Rektifiye Edilmiş Doğrusal Birim (ReLU) işlevleri bulunur. Sigmoid aktivasyon işlevi, gerçek bir sayıyı bir olasılık puanına dönüştürmek için sinir ağlarının çıkış katmanında yaygın olarak kullanılır. ReLU aktivasyon fonksiyonu, sıfırdan küçük girişlerin değerlerini belli bir oranda onları sıfıra zorlayarak düzeltir. [36] ReLU'nun kaybolan gradyanlar sorununu çözdüğü için Sigmoid ve Tanh etkinleştirme işlevlerine kıyasla daha iyi performans sunduğu görülmüştür.




Şekil 3-3 CNN Mimarisi


4. MATERYAL VE METOT

4.1. Otomasyon Sistemi Çalışması

Bu tez çalışması kapsamında servo ve asenkron motor ile çalıştırılan kağıt bardak basma makinesinde PLC, sensörler, motor sürücüleri ve HMI gibi elektronik ürünler aktif görev almaktadırlar. PLC ile sürücüler haberleştirilmiş, HMI ve butonlardan gelen komutlar ile motorlara hareket sağlama veya durdurma işlemleri gerçekleştirilmiştir. Bardak taban kağıdı ve diğer baskılama işlemleri için ısı sensörlerinden gelen veriler PLC input outputları ile motor sürücülerine bağlanır. Herhangi bir iş kazasını önlemek için endüktif sensör (insan eli veya başka bir cisim araya girdiğinde sistemi durdurma) kullanılmıştır. Şekil 4-1’de kontrol sisteminin blok diyagramı verilmektedir. Şekil 4-2 ‘de otomasyon panosu ve Şekil 4-3’de bardak basma makinesi verilmektedir.



Şekil 4-1 Sistem Blok Diyagramı



Şekil 4-2 Otomasyon panosu



Şekil 4-3 Bardak Basma Makinesi

4.2. Motorların Seçimi

Bu çalışmada makinenin sistemli bir şekilde çalıştırılabilmesi ve maliyet performans analizine uygun bir sistem kurulması amacıyla farklı türde motorlar kullanılmıştır. Bunlar; Asenkron ve Servo motorlardır.

Bardak basma makinemizde bardakların düzenli bir halde sıralanması ve yuvarlak gövdeli sistemin bir zamana göre döndürülmesi gerekmektedir. Çok hassasiyet gerektirmeyen ve orta güç özelliklerine (2.2 KW) sahip Mitsubishi marka bir endüstriyel asenkron motor seçilmiştir. Bu motor sabit hızda ve belirli bir torkta sistemin hareketini sağlar. Fiyat olarak uygun olması avantaj sağlamaktadır.

Bir diğer nokta, makinede hassas hareket gerektiren bir kısım bulunmaktadır. Burada anında durma ve mm lik hesap gerektiren ölçümler söz konusudur. Burada step veya servo motor seçilmesi doğru olmaktadır. Servo motor step motora göre daha hassas bir ölçüm yapabilmekte ve sahip olduğu enkoder ile pozisyonu bilebilmektedir. Bu sebepten ötürü kaliteli bir marka olan Mitsubishi servo motor seçilmiştir. Sistemin çok yüksek güç gerektirmediği görüldüğünden 1.2 kw lık bir servo motor seçilmiştir.

Asenkron motor parametrelerinin ayarı yapılırken öncelikle motor tanıtma işlemi yapılmıştır ve sonrasında sürücü üzerindeki dijital ayar potu ve dışarıdan butonlar ile sürücü kontrol edilmiştir. Yani kullanıcı makine üzerindeki butonlar ile asenkron motoru durdurup, çalıştırabilmektedir. Aşağıdaki bölümlerde motor tanıtma işlemi ve dışarıdan butonlar ile sürücüyü kontrol etme işlemi anlatılmıştır.

4.3. Asenkron Motor Tanıtma İşlemi ve Parametre Ayarı

Bu fonksiyon ile motor sabitleri ölçülür ve uygun motor kontrol performansı elde edilmeye çalışılır. Genellikle sabit ve döner olmak üzere iki çeşit motor tanıtma şekli vardır. Motor boşta ve yüksüz durumdayken en doğru motor tanıtma işlemi için döner şekli kullanılmalıdır. Sabit motor tanıtma şekli ise motorun daha önceden kurulmuş bir sistemde dönmesi mümkün olmayan durumlarda kullanılabilir, ancak ölçülemeyen bazı değerler sonradan girilmelidir.

Motor tanıma ile motor sabitleri (motor birincil ve ikincil direnç değerleri) ve motor endüktans değerleri tespit edilir. Motor tanıma yaparken girilmesi gereken motor parametreleri motor etiketindeki yazan değerler ile yapılır. Bu değerlerin doğru girilmesi önemlidir. Çünkü motor karakteristikleri değişebilir. Motor tanıma fonksiyonu ile motor/sürücü performansı artırılır ve düşük hızlarda tork üretilmesi sağlanır. Çalışmamızda Mitsubishi marka D700 serisi invertör kullanılmıştır.

D700 serisi için motor tanıma işlemi yapılırken PU moduna geçilir ve en iyi performans için parametreler şu şekilde girilmelidir:

Pr.160 parametresi 0 olmalıdır.

Pr.9 parametresine motor etiket akım değeri girilmelidir.

Pr.71 parametresi 3 olarak set edilmelidir.

Pr.80 parametresine motor etiket KW değeri girilmelidir.

Pr.83 parametresine motor etiket voltaj değeri girilmelidir.

Pr.84 parametresine motor etiket frekans değeri girilmelidir.

Bu parametreler girildikten sonra Pr.96 parametresi 11 olarak girilmelidir. [40]

Tablo 4-1 Giriş terminalleri parametreleri, standart fabrika ayarları[40]

İnverter Serisi	Terminal İsmi	Pr. No	Fabrika Set Değeri ve Açıklamaları	
D700 / E700	STF	178	60	İleri yön start
D700 / E700	STR	179	61	Geri yön start
D700 / E700	RL	180	0	Düşük hız start
D700 / E700	RM	181	1	Orta hız start
D700 / E700	RH	182	2	Yüksek hız start
E700	RES	184	62	İnverter reset

Tablo 4-2 Çıkış terminalleri parametreleri, standart fabrika ayarları[40]


İnverter Serisi	Terminal İsmi	Pr. No	Fabrika Set Değeri ve Açıklamaları	
D700 / E700	RUN	190	0	İnverter çalışıyor
D700 / E700	ABC	192	99	Alarm çıkış
D700	SO	197	80	Acil dur çıkış
E700	FU	191	1	Çıkış frekansı kontrolü

4.4. Servo Motor Sürücüsü Sürme ve Kontrol

Servo motorlar bulundukları sistem içerisinde istenilen hassasiyete ve işe göre farklı metodlar ile sürülebilmektedir. Bunlar; pozisyon mod, hız mode, tork modu ve Modbus ile sürmedir. Servo motor, makinemizde taban kağıt sürülmesi esnasında kullanılmaktadır ve artırımlı (incremental) olarak istenilen pozisyona gitmektedir. Mitsubishi marka, 0.70 KW'lık bir servo motor makinenin çalışmasında gayet yeterli olacağı için bu güçte bir motor kullanılmıştır.


4.4.1. Servo sürücü PLC haberleşmesi

Servo motor PLC ile Modbus RTU protokolü ile haberleşmektedir ve Modbus olarak servo sürücü kontrol edilmektedir. Modbus bağlantı şeması Şekil 4-4'de gösterilmiştir.



Şekil 4-4 Modbus Bağlantı Şeması

Şekil 4-5 'deki RDA, RDB ,SDA, SDB ve SG olarak adlandırılan bağlantılar Modbus haberleşmede kullanılan bağlantı kablolarıdır. PLC ile servo sürücü arasında Modbus haberleşmesinin yapılması için PLC bacak bağlantıları gösterilmiştir. Sg toprak bağlantısı, sdb ve sda bağlantıları verici pozitif ve negatif bağlantısı, rdb ve rda ise alıcı pozitif ve negatif bağlantılarıdır.



Şekil 4-5 Modbus Bağlantı Görseli


4.4.2. Servo sürücü parametre ayarları

Servo sürücü, kontrolörden gelen düşük güçlü emir sinyallerini yüksek voltaja ve akıma çevirmektedir. Farklı uygulamalarda değişmek üzere servo sürücü motorun gerekli konumunu, hızını ve torkunu ayarlayabilir. Servo sürücüler kendi kontrol döngüsü üzerinden kontrolöre bir sinyal göndermek için negatif geri beslemeden yararlanır.

Hareketli uygulamalarda sürücü, milin konumunun gerçek değeri ile istenen değeri arasındaki ilişkiyi anlayarak motora bir sinyal gönderebilir.


Sürücü, Mitsubishi marka olduğundan parametre ayarları Mr Configurator olarak adlandırılan ara yüz programında ayarlanmıştır. Parametre ayarları aşağıdaki görsellerde sırasıyla anlatılacaktır. [41]

1. Yeni proje açılır,
2. Sürücü modeli seçilir,
3. Seçim tamamlanır.




Şekil 4-6 Adım-1

1. Parametre kısmına girilir,
2. Temel seviye seçilir,
3. PA19 parametresi seçilir ve adresi 00AB olarak değiştirilir,
4. Seçtiğimiz parametre onaylanır,
5. Servo sürücü tekrar çalıştırılır.




Şekil 4-7 Adım-2

1. Sürücü tarafından parametre değerleri okunur.
2. Listede gösterilen yapılandırılabilir parametre sayısı artmıştır.



Şekil 4-8 Adım-3

1. Temel parametre ayarı seçilir.
2. PA01 parametresi 1006 adresi (pozisyon modu (point table modu)) olarak değiştirilir.



Şekil 4-9 Adım-4

Detaylı ayarları şu şekildedir:

Modbus RTU ile haberleşme sağlanmıştır. Baud hızı 115200 bps'dir.

Motorun ilk (home) durumuna gelmesi için PT04 parametresinin 0012 olarak değiştirilmesi gerekir. Servo pozisyona artırımlı (incremental) olarak gideceği için PT01 parametresinin 0001 olarak değiştirilmesi gerekir.

Hatve denilen vidalı milin diş arasının ölçüsü 10 mm olması durumunda ve redüksiyon dişlisi olmadığında, PA06 parametresi 131072 sayısal değerinin ve PA07 parametresi ise 10000 değerinin sadeleştirilmiş hali olarak girilir.


Bu sistemde ekrana manuel olarak 10 cm yazıldığında servo motor 1 tur dönerek 10 cm kadar hareket eder. $131072/10000= 8192/625$ 'dir.

PA06=8192

PA07=625

parametre değerleri olarak girilir.

1. Tek bir sürücü için yazdırma butonu seçilir ve PC70 parametresi sistemde tek sürücü olduğundan 1 olarak girilmiştir.
2. Servo sürücü tekrar açılır.




Şekil 4-10 Adım-5

4.4.3. Servo PLC yazılımı


Servo parametre ayarları yapıldıktan sonra PLC yazılımı yapılmaktadır. Servo sürücü ile PLC Modbus-RTU yöntemi ile haberleşmektedir. Modbus ile servo motor sürüldüğünde sürücü 2 şekilde sürülebilir. Bunlar jog mod ve point table moddur. Bunun yanında home mod motorun çalışmaya başladığı ilk aşamada kullanılmaktadır. Home mod ile servo sıfır noktasına çekilir ve motor tekrar çalışmaya başladığında istenilen pozisyona gitmeye başlar. Enerji kesilmediği müddetçe home işlemi bir kez yapılır. Pano üzerinden kapatılıp motor tekrar çalıştırılırsa home işlemi yapılabilir.

Point table mode seçildiğinde HMI üzerinden girilen pozisyon kadar motor çalışır ve otomatik olarak işlem devam eder. Jog modda ise manuel olarak motor çalıştırılır ve bu işlem otomatik olarak devam etmez.

Aşağıdaki şekilde yazılımın bir bölümü örnek olarak gösterilmiştir.



Şekil 4-11 MR-JE-FX5U Hazır Blok Diyagram



Şekil 4-12 Blok Diyagram Ayarlar

4.4.4. Sistemin PLC yazılımı

Otomasyon sisteminde Mitsubishi marka motorlar ve sürücüler kullanılarak tasarlanan mimaride yine Mitsubishi marka PLC kullanılmıştır. Tüm sistemin yazılımı FBD (function block diagram) dili ile yazılmıştır. PLC yazılımı 8 bölümden oluşmuştur. Bunlar;

1-Değer Kaydet

2-Devreye Hazır

3-Hız-Referans

4-Sayılar

5-Sensörler


6-Servo Programı

7-Sıcaklık Ayarları

8-Start


bölümlerinden oluşmaktadır. Örnek yazılım aşağıda gösterilmektedir.

Şekil 4-13’de makinedeki ısı sensörlerinden gelen verilerin PLC’ de okunabilmesi için hafızaya yazılması işleminin bir kısmı gösterilmiştir.



Şekil 4-13 FBD Dili Örnek Gösterim 1

Şekil 4-14’de makinedeki tüm sensörler, sürücüler vb. ayarlandıktan sonra sistemin çalışması için tüm ön koşullar sağlanarak bir yazılım yapılmış örneği gösterilmektedir.



Şekil 4-14 FBD Dili Örnek Gösterim 2

4.4.5. HMI tasarımı

İnsan makine ara yüzü olarak adlandırılan ekran programına HMI denir. PLC ile operatör arasındaki bağlantı HMI üzerinden kurulabilir. [37]

HMI üzerinde kullanıcının yaptığı ayarlar ve kontroller, haberleşme yoluyla PLC'ye aktararak, kullanıcının makineyi kontrol etme imkanını sunar. HMI'lar farklı ölçülerde ve birbirinden farklı özelliklere sahip olabilirler. HMI'lar PLC ile farklı şekillerde haberleştirilebilirler (modbus RS232, RS485, RS422, modbus tcp-ip, ethernet, profibus, profinet). Ekran boyutları inç olarak ifade edilir. HMI'lar genellikle dokunmatik ekran olarak çalışmaktadır. Ancak dokunmatik ekranın yanında üzerinde bulunan yardımcı butonlarında olduğu modeller mevcuttur.

Bu sistemde Mitsubishi marka HMI kullanılmıştır ve ekran tasarımı Gt Designer programında tasarlanmıştır. Makinenin bütün kontrolleri HMI üzerinden yapılmaktadır.

4.5. Veri Seti

Veri setimiz bardak basma makinesinin bastığı bardakları hatalı ve hatasız olmak üzere ki sınıfa ayrılmış görüntülerden oluşmaktadır. Şekil 4-16 ve Şekil 4-15'de sırasıyla hatalı ve hatasız bardak örnek görüntüleri verilmektedir. 534 adet hatalı bardak görüntüsü ve yine 534 adet hatasız diye adlandırılan görüntü veri setini oluşturmaktadır. Görüntülerin boyutu 418x418 pikseldir. Bu görüntülerin %90'ı eğitim için, %10'u ise geçerleme için kullanılmıştır. Bu veri seti ile belirlenen en başarılı modele gerçek zamanlı test verileri uygulanarak gerçek zamanlı doğruluk oranları tespit edilmiştir. Tüm analiz edilen derin öğrenme mimarilerine kameradan 100 adet hatalı bardak ve 100 adet hatasız bardak gösterilerek gerçek zamanlı doğruluğu belirlenmiştir. Bu tez çalışmasında yapılan yazılım çalışmalarının blok diyagramı Şekil 4-18'de verilmektedir.




Şekil 4-16 Hatalı Bardak Örneği



Şekil 4-15 Hatasız Bardak Örneği



Şekil 4-17 Fabrika ortamı bardak görünümü



Şekil 4-18 Tez çalışması kapsamında gerçekleştirilen yazılım blok diyagramı

4.6. YOLO Algoritması

YOLO, 'You Only Look Once' teriminin kısaltmasıdır. Bu, bir görüntüdeki çeşitli nesneleri (gerçek zamanlı olarak) algılayan ve tanıyan bir algoritmadır. YOLO' da nesne tespiti, bir regresyon problemi olarak yapılır ve tespit edilen görüntülerin sınıf olasılıklarını sağlar. [38]

YOLO algoritması, nesneleri gerçek zamanlı olarak algılamak için evrişimli sinir ağlarını (CNN) kullanır. Adından da anlaşılacağı gibi, algoritma nesneleri algılamak için bir sinir ağı üzerinden yalnızca tek bir ileri yayılım gerektirir.

YOLO algoritması çeşitli varyantlardan oluşur. Yaygın olanlardan bazıları küçük YOLO ve YOLOv3'ü içerir.

YOLO algoritması aşağıdaki üç tekniği kullanarak çalışır:

- Artık bloklar
- Sınırlayıcı kutu regresyonu
- Birlik Üzerinden Kavşak (IOU)

İlk olarak, görüntü çeşitli ızgaralara bölünür. Her ızgaranın bir $S \times S$ boyutu vardır. Aşağıdaki görüntü, bir girdi görüntüsünün ızgaralara nasıl bölündüğünü gösterir.



Şekil 4-19 Bir girdi görüntüsünün ızgaralara bölünmesi

Yukarıdaki resimde, eşit boyutta birçok ızgara hücresi vardır. Her ızgara hücresi, içinde görünen nesneleri algılayacaktır. Örneğin, belirli bir ızgara hücresi içinde bir nesne merkezi belirirse, bu hücre onu algılamaktan sorumlu olacaktır.

Sınırlayıcı kutu regresyonu;

Sınırlayıcı kutu, görüntüdeki bir nesneyi vurgulayan bir ana hattır.

Görüntüdeki her sınırlayıcı kutu aşağıdaki özelliklerden oluşur:

- Genişlik (bw)
- Yükseklik (bh)
- Sınıf (örneğin, kişi, araba, trafik ışığı vb.)- Bu, c harfi ile gösterilir.
- Sınırlayıcı kutu merkezi (bx,by)

YOLO, nesnelerin yüksekliğini, genişliğini, merkezini ve sınıfını tahmin etmek için tek bir sınırlayıcı kutu regresyonu kullanır. Sınırlayıcı kutuda görünen bir nesnenin olasılığını temsil eder.

Birleşim üzerinden kesişme (IOU), kutuların nasıl üst üste bindiğini açıklayan nesne algılamada bir olgudur. YOLO, nesneleri mükemmel bir şekilde çevreleyen bir çıktı kutusu sağlamak için IOU'yu kullanır.

Her ızgara hücresi, sınırlayıcı kutuları ve bunların güven puanlarını tahmin etmekten sorumludur. Öngörülen sınırlayıcı kutu gerçek kutuyla aynıysa, IOU 1'e eşittir. Bu mekanizma, gerçek kutuya eşit olmayan sınırlayıcı kutuları ortadan kaldırır.

4.7. Haarcascade Algoritması


"Basit Özelliklerin Yükseltilmiş Katmanını Kullanarak Hızlı Nesne Algılama" adı verilen etkili bir nesne algılama yöntemidir. Makine öğrenimine dayanarak, bu algoritma birçok pozitif ve olumsuz görüntü ile eğitilmiştir. Daha sonra diğer görüntülerdeki nesneleri tespit etmek için kullanılır. [39]

Haarcascade algoritması şöyle çalışır:


Belirli bir algoritmaya göre bulunması istenen nesneler önce bilgisayara eklenir ve daha sonra benzer şekillere sahip resimler veya video çerçeveleri taranır ve nesne bulunur.

Sınıflandırıcının eğitimi için, aranan nesne ile pozitif resimler ve bu nesne olmadan negatif resimler gereklidir. Sınıflandırıcı eğitiminde, kara bölgedeki piksel değerlerinin toplamından ve beyaz bölgedeki piksel değerlerinin toplamından karanlık ve ışık değerlerini kontrol ederek belirli hedef değerler oluşturulur. Çerçeveleri belirli boyutlarda ayarlanmış pozitif görüntüler Şekil 4-20' de görülmektedir.


1. Edge features



2. Line features



3. Center-surround features



Şekil 4-20 Haarcascade çalışma prensibi

Feature denilen bu çerçevelere zayıf sınıflandırıcılar denilmektedir. Çünkü tek başına doğru bir sınıflandırıcı olamazlar. Bir nesnede bu zayıf sınıflandırıcılardan birçoğu olacaktır ve bu zayıf sınıflandırıcıların toplandığı noktada büyük doğruluk oranıyla aranılan nesne var demektir. Sınıflandırıcı, bu şekilde çalışmaktadır.

5. DENEYSEL ÇALIŞMA VE SONUÇLAR

Çalışmamızda YOLOv5 algoritmasının farklı modellerini kendi oluşturduğumuz veri setimizdeki 534 adet hatalı bardak fotoğrafı ve yine 534 adet hatasız bardak verilerine göre başarı karşılaştırmasını yaparken Google Colab platformu kullanılmıştır. Daha önceden eğitilen modeller üzerinden kendi veri setimizin eğitimi, tarafımızdan gerçekleştirilmiştir. Görüntülerin %90'ı eğitim, %10'u ise geçerleme verisi olarak seçilerek eğitim yapılmıştır.

Deneysel çalışmalar Tablo 5-1'de görüldüğü üzere derin öğrenme tabanlı sınıflandırıcılardan faydalanılarak gerçekleştirilmiştir. Sınıflandırma için YOLOv5 algoritmasının farklı modelleri kullanılmıştır. Bu modellerin analizleri yapılmıştır. Hatalı ve hatasız bardak tespit etme oranları karşılaştırılmıştır. Aynı zamanda HAARCASCADE ve YOLOv5 algoritmalarının karşılaştırılması da yapılmıştır. Yapılan çalışmalarda YOLOv5 algoritmasının v5x modelinin diğer modellere göre daha iyi tespit ortaya koyduğu saptanmış ve Haarcascade algoritmasının Yolov5 algoritmasına göre tespit başarısı daha düşük olarak tespit edilmiştir. Bu tez kapsamında yapılan tüm çalışmalar Google Colab ortamında gerçekleştirilmiştir. Analizlerimiz için bu platform bize GPU desteği sağlamıştır.

Google Colab ile eğittiğimiz modellerimiz Anaconda navigatör platformundaki Jupyter Lab üzerinde gerçek zamanlı olarak çalıştırılmıştır. Gerçek zamanlı olarak hatalı ve hatasız bardakları tespit ederken fabrika ortamına çok benzer bir ortamda testler gerçekleştirilmiştir. Farklı ışık altında testler de yapılmıştır. Test sonuçları her model için Tablo 5-2 'de gösterilmiştir. Yolov5x modelinin gerçek zamanlı nesne tespitinin başarı oranı en yüksek olarak saptanmıştır.

5.1. Yolov5 Modelleri

Yolov5 Algoritmasının 5 farklı modeli bulunmaktadır.

Bu modeller Yolov5s, Yolov5n, Yolov5m, Yolov5l, Yolov5x olarak adlandırılırlar ve herbiri için hiperparametre değerleri (öğrenme hızı, momentum, kayıplar, büyütme vb.) dahil olmak üzere eğitim için tanımlanır.

- YOLOv5n : Edge, IoT cihazları ve OpenCv DNN desteği ile yeni sunulan bir nano modeldir. INT8 formatında 2,5 MB'den küçük ve FP32 formatında 4 MB civarındadır. Mobil çözümler için idealdir.
- YOLOv5s : Yaklaşık 7,2 milyon parametreye sahiptir ve CPU üzerinde çıkarım yapmak için ideal bir modeldir.
- YOLOv5m : 21,2 milyon parametrelili orta ölçekli modeldir. Hız ve doğruluk arasında iyi bir denge sağladığı için birçok veri seti ve eğitim için belki de en uygun modeldir.
- YOLOv5l : 46,5 milyon parametrelili geniş bir modeldir. Daha küçük nesneleri algılamamız gereken veri kümeleri için idealdir.
- YOLOv5x : Beş model arasında en büyüğüdür. Diğerlerine göre daha yavaş olmasına ve 86,7 milyon parametreye sahip olması doğruluk oranını oldukça artırmaktadır.

Tablo 5-1 Yolo Modelleri Değerleri

Model	size (pixels)	mAP ^{val} 0.5:0.95	mAP ^{test} 0.5:0.95	mAP ^{val} 0.5	Speed V100 (ms)	params (M)	FLOPS 640 (B)
YOLOv5s6	1280	43.3	43.3	61.9	4.3	12.7	17.4
YOLOv5m6	1280	50.5	50.5	68.7	8.4	35.9	52.4
YOLOv5l6	1280	53.4	53.4	71.1	12.3	77.2	117.7
YOLOv5x6	1280	54.4	54.4	72.0	22.4	141.8	222.9
YOLOv5x6 TTA	1280	55.0	55.0	72.0	70.8		

5.2. Yolov5 Algoritma Başarı Sonuçları

Veri seti (bardak) üzerinde sınıflandırma yapılması amacıyla uygulanan derin öğrenme tabanlı Yolov5 algoritmasının modellerinin çıktıların sonucunda en yüksek geçerleme (validation) sınıflandırma başarısı Tablo 5-1’de görüldüğü gibi Yolov5x derin öğrenme modeli kullanılarak elde edilmiştir. Bu başarının başlıca sebeplerinden bir tanesi Yolov5x modelinin 86.2 milyon parametreye sahip olmasından kaynaklıdır. Veri setinde analiz amaçlı denediğimiz Yolov5 algoritması modellerinden nispeten en başarısız olanı %90.02 başarı oranı ile Yolov5n modelidir. Gerçek zamanlı uygulamalarda algılama hızı da oldukça önemli bir parametredir. Tüm Yolov5 algoritmalarının gerçek zamanlı doğruluk oranları birbirine çok yakın olduğu için kullanıcılar tarafından en az parametreye sahip en hızlı olan Yolov5s6 algoritması da seçilebilir.

Tablo 5-2 Veri seti geçerleme (validation) sınıflandırma sonuçları

Veri Seti	Metot	Optimizasyon Algoritması	Doğruluk(%)
Veri seti (bardaklar)	Yolov5s	SGD	90.53
	Yolov5n	SGD	90.02
	Yolov5m	SGD	90.45
	Yolov5l	SGD	90.65
	Yolov5x	SGD	90.80

5.3. Modellerin Doğruluk ve Kayıp Sonuçları

Gerçek zamanlı (real time) nesne tespiti için daha önceden eğittiğimiz modeli kullanarak ve OpenCv kütüphanesinden yararlanarak Jupyter Lab ortamında testler gerçekleştirilmiştir.


Modellerin başarıları, gerçek zamanlı olarak Logitech marka harici bir kamera ile test edilmiştir. Test fabrika ortamına benzer bir ortamda gerçekleştirilmiş, farklı açı ve farklı ışık durumları göz önüne alınarak yapılan test sonuçları Tablo 5-3’ te görülmektedir.

Tablo 5-3 Gerçek Zamanlı Nesne Tespiti Doğruluk Sonuçları


Model	Test	Test	Hatalı		Hatasız	
	Sayısı (Hatalı bardak için)	Sayısı (Hatasız bardak için)	Ürünü	Doğru	Ürünü	Doğru
			Tespit Sayısı		Tespit Sayısı	
Yolov5s	100	100	80		70	
Yolov5n	100	100	75		70	
Yolov5m	100	100	85		75	
Yolov5l	100	100	90		80	
Yolov5x	100	100	95		90	
Haarcascade	100	100	85		85	

5.3.1. Yolov5 modellerinin grafikleri


Model accuracy (doğruluk) ve object loss (kayıp) grafikleri aşağıdaki şekillerde gösterilmektedir.




Şekil 5-1 Yolov5s Sınıflandırma Doğruluk Grafiği




Şekil 5-2 Yolov5s Sınıflandırma Kayıp Grafiği




Şekil 5-3 Yolov5n Sınıflandırma Doğruluk Grafiği




Şekil 5-4 Yolov5n Sınıflandırma Kayıp Grafiği



Şekil 5-5 Yolov5m Sınıflandırma Doğruluk Grafiği



Şekil 5-6 Yolov5m Sınıflandırma Kayıp Grafiği



Şekil 5-7 Yolov5x Sınıflandırma Doğruluk Grafiği



Şekil 5-8 Yolov5x Sınıflandırma Kayıp Grafiği

5.3.2. Haarcascade yazılım ve test Süreci

Haarcascade algoritmasını kullanmak için öncelikle görüntüler pozitif ve negatif veriler olmak üzere ikiye ayrıldı. Hatalı bardaklar pozitif dosyasına, hatasız veriler ise negatif dosyasına aktarıldı. Cascade Trainger Gui diye isimlendirilen bir hazır platform üzerinden eğitim gerçekleştirildi ve çıkan xml uzantılı dosya ile PyTorch programı üzerinde, OpenCv kütüphanesi kullanılarak gerçek zamanlı nesne tespiti yapıldı.

5.4. Kısıtlar

Gerçek zamanlı bardak tespiti sırasında kameranın açısı, ortamın ışık ayarı, bardağın farklı açılardan kameraya gösterilmesi, farklı renk ve şekildeki bardakların testleri gibi durumlara göre nesne tespitinin doğruluk sonuçları değişmektedir.

Fabrika ortamında kamera bardağın üst kısmındaki hatalı ve hatasız ürünleri tespit ederken, bardağın alt kısmında (taban kısmı) oluşan hatalar kamera tarafından görülemediği için hatalı/hatasız ürün tespiti gerçekleştirilememiştir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada kağıt bardak makinesinin otomasyon sistemi kurulmuş, bardak üretilmeye başlanmış ve üretim hattına eklenen canlı bir kamera ile ürün tespiti yapılmıştır.

Otomasyon sistemi için Mitsubishi marka servo ve asenkron motorlar, sürücüler, PLC, HMI kullanılmıştır. Servo sürücünün gerekli parametre ayarları yapılarak motor sürüldüğünde kağıt bardakları döndüren mekanizmanın titreşim oranının düşük olması ve tam hizalama şartını sağlaması başarılı bir sonuç çıkarmıştır. Asenkron motor için HMI üzerinden kontrol sağlandığında da rampalama sürelerinde motorun çalıştığı gözlemlendi. Asenkron sürücü bu sürme işlemini başarı ile gerçekleştirdi.

PLC yazılımında birçok eklentiler yapıldı, adresleme ve pozisyon belirleme yapılırken makine üzerinde testler gerçekleştirildi. Sensörlerden gelen verilere göre, yine HMI üzerinden girilen isteklere göre PLC'nin cevap verme hızının diğer PLC markalarına göre daha başarılı olduğu gözlemlendi. PLC ile Servo Modbus RTU yöntemi ile haberleştirildi. Bu sayede elektriksel gürültü azaldı ve hassasiyet daha iyi seviyelerde görüldü.

Gerçek zamanlı kamera ile görüntü alınırken öncesinde veri seti tarafımızdan oluşturuldu. Hatalı ve hatasız bardakların fotoğrafları çekildi. Görüntüler aynı boyutta ölçeklendirildi. Kendi oluşturduğumuz veri seti ile YOLOV5 modelleri ve Haarcascade algoritması gibi derin öğrenme hazır modelleri ile eğitim yapıldı. Bu modellerin sınıflandırma başarı sonuçları karşılaştırıldı.

Kendi oluşturduğumuz veri seti ile OpenCv kütüphanesi kullanılarak gerçek zamanlı nesne tespiti yapıldı ve başarı sonuçları karşılaştırıldı. Bu sonuçlar incelendiğinde YOLOV5x mimarisini kullanarak başarılı bir gerçek zamanlı uygulama gerçekleştirilmiştir. Tüm sürece ait donanımsal ve yazılımsal kısımlar ayrı ayrı test edilerek endüstriye uygulanabilecek gerçek bir problem ele alınarak sonuçları ortaya konmuştur. Gelecek çalışmalarda bu yapılan ön çalışma sonuçlarından yararlanarak fabrika ortamında tüm sistem tasarımının yapılması planlanmaktadır. Farklı derin öğrenme mimarileri ve görüntü ön işleme ve iyileştirme yöntemleri de incelenerek hatalı/hatasız tespit başarısının artırılması hedeflenmektedir.

7. KAYNAKLAR

- [1] R. Firoozian, "Servo motors and industrial control theory," 2014.
- [2] *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, vol. 4, 719-726, 2016.
- [3] *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, vol. 1, 97-104, 2012.
- [4] Fırat Üniversitesi Mühendislik Bilimleri Dergisi vol. 29, no. 2, 163-172, 2017
- [5] A. Şeker, B. Diri, ve H. H. Balık, "Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme," *Gazi Mühendislik Bilimleri Dergisi* vol. 3, no. 3, 47-64, 2017.
- [6] Ö. İnik, ve E. Ülker, "Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri," *Gaziosmanpaşa Bilimsel Araştırma Dergisi* vol. 6 no. 3 85-104, 2017.
- [7] A. Aktaş, Ö. Demir, and B. Doğan. "Derin öğrenme yöntemleri ile dokunsal parke yüzeyi tespiti," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* vol. 35, no. 3, p. 1685-1700, 2020.
- [8] O. Çömlekçi, "Endüstriyel otomasyon sistemlerinde yapay zeka yöntemleri ile arıza tespiti," Ph.D. dissertation, Bursa Uludag University, 2020.
- [9] S. H. Onim, M. I. Akash, M. Haque ve R. I. Hafız, "Traffic surveillance using vehicle license plate detection and recognition in bangladesh," in %1. *11th International Conference on Electrical and Computer Engineering (ICECE)*. IEEE, p. 121-124, 2020.
- [10] T. Hinzmann, T. Stegemann, C. Cadena ve R. Siegwart, "Deep learning-based human detection for uavs with optical and infrared cameras: system and experiments," Zurich, 2020.
- [11] H. Sarıbaş, H. Çevikalp ve S. Kahvecioğlu, "insansız hava araçlarından alınan

görüntülerdeki araçların konumlarının bulunması," %1 içinde. 26. *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, İzmir, 2018.

- [12] T. Ophoff, S. Puttemans, V. Kalogirou, J. P. Robin ve T. Goedemé, "Vehicle and vessel detection on satellite imagery: a comparative study on single-shot detectors," *Remote Sensing*, vol. 12, no. 1217, 2020.
- [13] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, A. C. Berg, "Ssd: single shot multibox detector," in *European Conference On Computer Vision*, Springer, 2016, p. 21–37.
- [14] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition*, 2016, p. 779–788.
- [15] G. Ciaparrone, F. L. Sánchez, S. Tabik, L. Troiano, R. Tagliaferri, F. Herrera, "Deep learning in video multi-object tracking: A survey," *Neurocomputing*, vol. 381, p. 61–88, 2020.
- [16] X. Wang, P. Cheng, X. Liu ve B. Uzochukwu, "Fast and Accurate, Convolutional Neural Network Based Approach for Object Detection from UAV," *arXiv.org*, 2018.
- [17] B. Benjdira, T. Khursheed, A. Koubaa, A. Ammar ve K. Ouni, «Car Detection using Unmanned Aerial Vehicles: Comparison between Faster R-CNN and YOLOv3,» *arXiv*, 2018.
- [18] Makinası, Universal Tahrik. "Lineer Eyleyici (Aktüatör)."
- [19] Syufrijal, S., et al. "Design and implementation of pipe cutting machine with AC servo motor and PLC based on HMI." *IOP Conference Series: Materials Science and Engineering*. vol. 1098. no. 4. *IOP Publishing*, 2021.
- [20] G. Aydın, Y. F. Sur, ve E. Kaplanoğlu, "ac servo motor eğitim seti tasarımı ve konum kontrolü." *Uluslararası Teknolojik Bilimler Dergisi* vol. 1, no. 2, 74-81, 2009.

- [21] K. Kaan, "Ac servo motorlar ve sürücü devreleri." 2006.
- [22] H. F. Kalkan, "Seri haberleşen iki akıllı röle modülü ile servo motorlu geçiş turnikesi kontrolü," M.S. thesis, Başkent Üniversitesi Fen Bilimleri Enstitüsü., Etimesgut, Ankara, 2020.
- [23] M. Şirincan, ve T. Erfidan, "Akıllı servo sürücü ile makina otomasyonu," *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, vol. 4, no. 2, p. 719-726, 2016.
- [24] Z. B. Duranay, ve H. Güldemir, "Bir fazlı asenkron motor v/f hız kontrolü." *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 29, no. 2, p. 163-172, 2017.
- [25] H. C. Bayrakcı, ve H. Büyükpatpat, "PLC ve SCADA kontrol yöntemleri ile sıvı dolum otomasyonu." *Avrupa Bilim ve Teknoloji Dergisi* no. 27, p. 283-291.
- [26] M. G. Hudedmani, M. R. Umayal, S. K. Kabberalli, "Programmable logic controller (PLC) in automation," *Advanced Journal of Graduate Research* vol. 2, no. 1, p. 37-45 2017.
- [27] A. Yılmaz, "Yapay zeka," Kodlab Yayın Dağıtım Yazılım Ltd. Şti., 2021.
- [28] M. Peker, ve A. Zengin, "Gerçek zamanlı harekete duyarlı bir görüntü tanıma sistemi." *6th International Advanced Technologies Symposium (IATS'11)*. vol. 16. no. p. 18, 2011.
- [29] Ö. M. Gökalp, "Makine öğrenmesi," Gazi Üniversitesi, Gazi Bilişim Enstitüsü, Adli Bilişim Bölümü.
- [30] Alfarra, Ahmad AA. "Training multi-layer deep neural networks using hybrid algorithms to detect network intrusions," *Electronic Turkish Studies* vol. 16, no. 5, 2021.
- [31] E. Çakmak, ve İ.H. Selvi, "Derin öğrenme (CNN, RNN, LSTM, GRU) kullanarak protein ikincil yapı tahmini," *Acta Infologica*, 2022.

- [32] G. B. Ergün, S. Güney, ve T. G. Ergün, "Köpeklerdeki uzun kemiklerin evrimsel sinir ağları kullanılarak sınıflandırılması," *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 33, no. 1, p. 125-132, 2021.
- [33] T. Karahan, ve V. Nabiye, "Plant identification with convolutional neural networks and transfer learning," *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 27, no. 5, p. 638-645, 2021.
- [34] S. Kızılluluk, "Comparison of standard and pretrained cnn models for potato, cotton, bean and banana disease detection." *Naturengs*, vol. 2, no. 2, p. 86-99. 2021.
- [35] K. Adem, ve S.Kılıçarslan. "Covid-19 diagnosis prediction in emergency care patients using convolutional neural network," *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, vol. 21, no. 2, p. 300-309, 2021.
- [36] R. Zebari, A. Abdulazeez, D. Zeebaree, D. Zebari, and J. Saeed, "A comprehensive review of dimensionality reduction techniques for feature selection and feature extraction," *J. Appl. Sci. Technol. Trends*, vol. 1, no. 2, pp. 56–70, 2020, doi: 10.38094/jastt1224.
- [37] E. Normanyo, F. Hüsinu, ve O. R. Agyare, "Developing a human machine interface (HMI) for industrial automated systems using siemens simatic WinCC flexible advanced software," *Journal of Emerging Trends in Computing and Information Sciences*, vol. 5, no. 2, p. 134-144, 2014.
- [38] P. Jiang, D. Ergu, F. Liu, Y. Cai, and B. Ma, "A review of yolo algorithm developments." *Procedia Computer Science*, vol. 199, p. 1066-1073, 2022.
- [39] T. Q. Vinh, and N. T. N. Anh, "Real-time face mask detector using YOLOv3 algorithm and Haar cascade classifier." *2020 International Conference on Advanced Computing and Applications (ACOMP)*. IEEE, 2020.
- [40] Motkonsis, 'Temel Devreye Alma Kılavuzu'. Available: motkonsis.com.tr/Yonetim/Urunler/Dosyalar/Motkonsis-Dosya_15967-1.pdf,

erişim: 28.07.2022, 12.35

- [41] Mitsubishi, 'Servo Motor Instruction Manuel'. Available: dl.mitsubishielectric.com/dl/fa/document/manual/servo/sh3181/sh3181l.pdf ,
erişim:28.07.2022 , 13.20
- [42] W. Ma, ve J. Lu, "An equivalence of fully connected layer and convolutional layer," *arXiv preprint arXiv:1712.01252* (2017).

