

Table of Contents

Ferhat Yılmaz, Gözde Celebi Efe, Tuba Yener

Production of Aluminide Based Coating on Ti6Al4V Alloy by Pack Cementation Method.....49-60

Tuba Yener, Furkan Hasan Sakacı, Ş. Çağrı Yener

Dimension Measurement and Classification of Metallic Materials Using Image Processing and Machine Learning.....61-69

Mert Süleyman Demirsoy, Mustafa Çağrı Kutlu, Mohammed Mansour

Android Based Exercise Tracking with PID Controlled IoT Communication.....70-80

Serdar Özkaya, Gökhan Atalı

Weather Forecasting with Artificial Neural Networks and LabVIEW Interface Design for Multi-Layer Network Model81-96

Süleyman Aktürk, Kasım Serbest

A Review of Deep Learning Libraries for Object Detection.....97-119

Kenan Erin, Bünyamin Bingöl, Barış Boru

YOLO – Based Waste Detection.....120-127

Ozgun Ahmet Efeturk, Gizem Turgut, Hamid Asadi Dereshgi, Aziz Yılmaz

A Review of Visual Attention Research Using Eye-Tracking Technologies.....128-135

Editor in Chief

Prof. Dr. Zafer Tatlı

Publishing Manager

Assist. Prof. Dr. Kasım Serbest

Editorial Board

Prof. Dr. Yusuf Çay

Prof. Dr. Fatih Çalışkan

Assoc. Prof. Dr. Gözde Çelebi Efe

Assoc. Prof. Dr. Halil Arslan

Assoc. Prof. Dr. Mehmet Akif Koç

Assist. Prof. Dr. Tahir Akgül

Assist. Prof. Dr. Fatih Uysal

Publishing Board

Muhammad Shahreeza Safiruz Bin Kassim, Department of Artificial Intelligence, University of Malaya (Malaysia)

İsmail Esen, Makine Mühendisliği Bölümü, Karabük Üniversitesi (Turkey)

Mehmet Aydın, Computer Science and Creative Technologies, University of the West of England (UK)

Shyqyri Haxha, Department of Electronic Engineering, Royal Holloway University of London (UK)

Enes KILINÇ, Makine Mühendisliği Bölümü, Karabük Üniversitesi (Turkey)

Rasim TEMÜR, İnşaat Mühendisliği Bölümü, İstanbul Üniversitesi (Turkey)

Hasan Arman, Department of Geology, United Arab Emirates University (UAE)

Ahmet Türk, Metalurji Ve Malzeme Mühendisliği Bölümü, Manisa Celal Bayar Üniversitesi (Turkey)

İbrahim Karaman, Materials Science and Engineering, Texas A&M University (USA)

Rahul Ribeiro, Department of Mechanical Engineering, Alliance University (India)

Murat Alçın, Mekatronik Mühendisliği Bölümü, Afyon Kocatepe Üniversitesi (Turkey)

Kutu Sementasyon Yöntemi ile Ti6Al4V Alaşımı Üzerine Aluminid Esaslı Kaplama Üretimi

Ferhat YILMAZ¹ , Gözde Celebi EFE² , Tuba YENER^{3*} 

¹ Sakarya Üniversitesi, Mühendislik Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Sakarya, Türkiye.
ferhat.yilmaz4@ogr.sakarya.edu.tr

² Sakarya Uygulamalı Bilimler Üniversitesi, Mühendislik Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Sakarya, Türkiye. gcelebi@subu.edu.tr

³ Sakarya Üniversitesi, Mühendislik Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Sakarya, Türkiye.
tcerezci@sakarya.edu.tr

ÖZ

Ti6Al4V alaşımları havacılık ve uzay alanında en çok kullanılan $\alpha+\beta$ alaşımlarından biridir. Bu çalışmada yüzeyde Ti alüminid esaslı tabakası oluşturularak yüzey özelliklerinin iyileştirilmesi hedeflenmiştir. Üretilen kaplamanın karakteristik özellikleri taramalı elektron mikroskobu (SEM), enerji dağılımlı spektrometre (EDS) ve X-ışını kırınımı (XRD) vasıtasıyla incelenmiştir. Alüminyum kaynağı olarak Al, dolgu malzemesi olarak Al_2O_3 tozu ve aktivatör olarak da NH_4Cl tozları açık atmosferli bir fırında $700^\circ C$ sıcaklıkta 4,6 ve 8 saat alüminyum kaplama işlemi gerçekleştirilmiştir. Yapılan X-ışını (XRD) analizlerinde kaplama tabakası üzerinde TiAl, $TiAl_2$ ve $TiAl_3$ ve eser miktarda Al_2O_3 fazları tespit edilmiştir. Kaplama tabakası kalınlığı tutma sürelerine bağlı olarak 12-20 μm arasında değiştiği görülmüştür. Oluşan titanyum alüminid tabakasında 578-650 HV arasında sertlik değerleri elde edilmiştir.

Anahtar Kelimeler: Ti6Al4V alaşımı, kutu sementasyonu, alüminid esaslı kaplama

Production of Aluminide Based Coating on Ti6Al4V Alloy by Pack Cementation Method

ABSTRACT

Ti6Al4V alloy is one of the $\alpha+\beta$ titanium alloys frequently used in aerospace and biomedical fields. In this study it is aimed to increase surface properties thanks to the aluminum-based protective and relatively harder intermetallic formed on the surface. The characteristic properties of this coating were investigated by scanning electron microscopy (SEM), energy dispersive spectrometry (EDS) and X-ray diffraction analyses (XRD). Al powder is used for aluminum source, Al_2O_3 powder as the filler material and NH_4Cl powder used as the activator. Aluminization process was carried out in an open atmosphere furnace at $700^\circ C$ for 4,6 and 8 hours. In the X-ray diffraction (XRD) analyzes, TiAl, $TiAl_2$ and $TiAl_3$ and Al_2O_3 phases were detected on the coating layer. It has been observed that the coating layer thickness varies between 12-20 μm depending on the holding times. The hardness of titanium aluminide layer was measured with the Vickers hardness method and the hardness values were between 578-650 HV.

Keywords: Ti6Al4V alloy, pack cementation, diffusion coating, aluminide-based coating

* Corresponding Author's email: tcerezci@sakarya.edu.tr

1 Giriş

Titanyum bazlı alaşımlar, sertlik, yüksek mukavemet ve üstün korozyon dirençleri nedeniyle havacılık, otomobil ve savunma sanayi endüstrisinde yaygın olarak kullanılmaktadır. Titanyum alaşımlarından yaygın olarak kullanılan $\alpha+\beta$ alaşımlarından olan Ti6Al4V, iyi bir mekanik mukavemete ve şekillendirilebilirliğe sahiptir. Ti6Al4V titanyum alaşımı, 400°C üzerindeki yüksek çalışma sıcaklıklarına çıktığı zaman ise yüzeyinde oluşan TiO₂ tabakası büyür ve parçalanır. Mekanik özelliklerinin bozulmasına yol açan bu durumu engellemek önem taşır. Oksidasyon direncini arttırmak ve yüksek servis sıcaklıklarında çalışmasında stabile etmek amacıyla Ti6Al4V alaşımı yüzey modifikasyonuna ihtiyaç duyulmaktadır [1]. Uygulanan modifikasyon işlemlerinden biri olan kutu sementasyonu, yapılan araştırmalar sonucu galvanizleme gibi diğer yüzey işlemlerine göre daha az maliyetli olduğu için üzerine yoğunlaşılacak alanların başındadır. Kutu sementasyon yöntemi, alaşımlı çeliklere aşınma ve korozyon direnci, sürtünme, oksidasyon gibi yüzey özelliklerini iyileştirme yanı sıra sert ve koruyucu alüminid kaplamalar oluşturmak için alternatif bir tekniktir [2].

Alaşımlı çelikler, titanyum alaşımları ve nikel alaşımları gibi üzerine sert ve koruyucu Al ve Cr içerikli kaplamalar korozyon direncinin iyileştirilmesinde önemli bir rol oynar. Yüksek sıcaklıklarda çelik malzemelerin yüzeyinde oluşan Fe₂O₃ tabakasına göre Alümina (Al₂O₃) gibi koruyucu bir oksit oluşumu alüminyum kaplama prosesi ile sağlanabilmektedir. Bu yolla daha stabil bir oksit tabakası oluşumu sayesinde korozyon direnci sağlanır. Altlık malzemesinin yüzeyine oksijenin difüzyonunu engellemek için Al₂O₃, Cr₂O₃, SiO₂, gibi ince oksit filmleri oluşturularak atmosferden yüzeyi korur [3]. Ancak, krom oksit (Cr₂O₃) tabakası 900°C üzerine çıktığı zaman, farklı ortamlara göre 800 °C – 850 °C sıcaklıklara göre değişiklik gösterebilir, bu tabaka CrO₃ tabakasına dönüşür ve daha fazla oksitlenme nedeniyle krom ölçüğü yetersiz hale gelir, altlık malzemesinin oksidasyon direncinde azalma meydana gelir. Alüminyum dioksit (Al₂O₃) ve silisyum dioksit (SiO₂) tabakası, krom oksit (CrO₃) tabakasına göre daha yüksek sıcaklıklara dayanır ve bu da oksidasyona karşı yüksek sıcaklıklarda direnci gösterir [4]. Dolayısıyla yüzeyde alüminid tabakası oluşturmak suretiyle yüksek sıcaklıklarda alumina oluşumuna izin verilir ve bu yolla altlık malzeme oksidasyona karşı direnç sağlar [5]–[7].

Alüminid kaplamaların temel özellikleri şunlardır: İstenilen servis koşullarında (korozyon, erozyon ve strese bağlı korozyon sorunları vb.) kaplama- altlık ara yüzünün bütünlüğünü (ideal bir ara yüzey, sürekli ve gerilmelerinden arınmış yapı) sağlamak. Kaplamanın mekanik ve termal çevrimler altında alt tabakaya yapışması [8].

Bu çalışma literatürden farklı olarak, Ti6Al4V alaşımının açık atmosferli bir ortamda, nispeten düşük bir sıcaklık ve kısa işlem sürelerinde alüminid birikimi sağlanmış olup oluşan Ti esaslı alüminid fazlar mikroyapısal ve sertlik yönüyle karakterize edilmiştir.

2 Metodoloji

Çalışmada kullanılan Ti6Al4V alaşımı ve kimyasal kompozisyon değerleri Türk Havacılık ve Uzay Sanayii AŞ'den temin edilmiştir. Tablo 2.1'de kimyasal kompozisyonu verilmiştir. Ti6Al4V titanyum alaşımı abrasiv diskli kesme cihazında 30 x 2 x 19,5 .mm uzunluğunda kesilmiş ve deney numunelerinin bütün yüzeyleri 60, 120, 240, 400, 600, 800 ve 1000 grit zımpara ile zımparalanmıştır. Sonrasında alkol ile temizlenip, kurutulmuştur. Böylece alüminyumlama işlemi öncesi Ti6Al4V alaşımının yüzeylerinin oksit, kir ve yağlardan arındırılması sağlanmış ve kaplama işlemi sırasında alüminyumun yüzeye daha

iyi yapışmasını sağlamak amaçlanmıştır.

Tablo 2.1. Ti6Al4V kimyasal kompozisyonu [9]


| N | Fe | V | Al | Ti |
|-------|-------|------|------|-------|
| 0.005 | 0.165 | 3.93 | 5.89 | Denge |

Kutu sementasyonu yöntemi ile Ti6Al4V alaşımının yüzeyinde alüminid kaplama tabakası oluşturmak için, aktivatör olarak %10 NH₄Cl, kaplama tozu olarak %35 saf Al (Alfa aeaser) tozu ve %55 ticari saf Al₂O₃ tozu hassas terazi yardımıyla istenilen ağırlıkça oranda tartılmıştır. Tartım sonrası tozlar homojen bir şekilde karıştırılmıştır. Karışım tozları alaşımın içinde bulunduğu, çelik bir pota içerisinde 700° 4, 6 ve 8 saat açık atmosferik bir fırında işleme tabi tutulmuştur. Kaplama sonrası oda sıcaklığına kadar soğutulmuş ve fırından alınmıştır. Alüminyum kaplama işleminden sonra yüzeyi kaplanmış numunelerin kesitleri mikroyapı çalışmaları için metalografik olarak hazırlanmıştır.

Kutu sementasyonu yöntemi ile alüminyumla işlemi uygulanmış numunelerin mikroyapı incelemesi JOEL JSM-5600 model taramalı elektron mikroskobu (SEM) ile yapılmıştır. Kaplama yüzeyinde oluşan fazların tespiti için 20° ile 90° arasında , 1.54056 Å dalga boyuna ve 2θ açısında CuKα radyasyonu kullanılarak Rigaku X-ışını difraktometresi ile belirlenmiştir. Titanyum alüminid tabakalarının sertlikleri mikro sertlik ölçümleri Leica WMHT-Mod sertlik cihazında Vickers elmas piramit uç kullanılarak 15 saniye süre ile oluşturulan iz yardımı ile belirlenmiştir.

3 Bulgular ve Tartışma


Şekil 3.1.'de 700°C sıcaklıkta 4, 6 ve 8 saat alüminyumlama işlemine tabi tutulmuş Ti6Al4V alaşımının SEM kesit görüntüsü verilmiştir. Kesit görüntülerinde üç adet belirgin intermetalik tabaka bulunmaktadır. Bu tabakalar Şekil 3.4'de alınan SEM-EDS analize göre TiAl₃, TiAl₂ ve TiAl olarak belirlenmiştir. XRD analizleri de bu sonucu destekler niteliktedir (Şekil3.3.). SEM mikro yapılarına bakıldığında; 4 saat işlem görmüş numunede birikme az miktarda gerçekleşmiş olup tabaka kalınlığı yaklaşık 14 µm olarak tespit edilmiştir. Kaplama süresi 6 saat'e ulaşıldığında ise numune yüzeyinde daha fazla alüminid tabakası birikimi (~18 µm) ve homojen bir kaplama tabakası elde edilmiştir. Kaplama süresinin artışına bağlı olarak 8 saat sonunda ise numunenin yüzeyinde oksit oluşumu başlamıştır. Bununla beraber ortamdaki alüminyumun oksit oluşumuna harcanması sebebiyle kaplama tabakasında beklenen artış sağlanamamış olup yaklaşık kalınlık 4 saat ile aynı değere ulaşmıştır (~13 µm). Optimum homojenlikte ve sürekli bir alüminyumca zengin kaplama tabakası ise 6 saat kaplanmış numune yüzeyinde görülmüştür.



Şekil 3.1. 700°C sıcaklıkta a) 4 b) 6 c) 8 saat alüminyumlanmış Ti6Al4V alaşımı SEM görüntüsü

Kutu sementasyon yöntemiyle alüminyum kaplama işleminde başlangıçta Al atomları aktivatörden gelen Cl gazı yardımıyla buhar fazına geçer ve $AlCl_3$ gazı, altlık malzemesi yüzeyine yayılır ve atomik olarak oluşan Al, Ti alaşımı ile reaksiyona girer. Şekil 3.2.'de kutu sementasyonun şematik gösterimi verilmiştir.

Aktivatör olarak kullanılan NH_4Cl , ilk olarak reaksiyon (1)'de gösterildiği gibi 400°C [5] üzeri sıcaklıklara çıktıkça NH_3 ve HCl 'ye ayrışır:



HCl, Al tozu ile reaksiyona girer ve AlCl_3 buhar fazına geçer:



Gaz halindeki AlCl_3 numune yüzeyine taşınır yüksek sıcaklıklara çıktığında Ti alaşımı altlık malzemesinden gelen titanyum, alüminyum ile reaksiyona girer ve AlTi tabakası oluşur.




Aluminyum kaplama süresi arttıkça Al aktivitesi artar ve oluşan AlTi tabakasından gelen titanyum dışarı doğru difüze olarak aşağıdaki reaksiyonun gerçekleşmesini sağlar:




Yukarıdaki reaksiyon sonucu ortada TiAl_2 tabakası gelişir. Aluminyumun aktivitesi daha da artması ve altlık malzemeden gelen titanyumun difüzyonu yavaşladığında aşağıdaki reaksiyon meydana gelir:



En dış tabakada TiAl_3 tabakası oluşur. Bu kısımdan sonra altlık malzemesi üzerinde üç katmanlı bir kaplama tabakası oluşmaktadır [10].



Şekil 3.2. Kutu Sementasyonunda Gerçekleşen Reaksiyonların Şematik Gösterimi




Şekil 3.3. 700°C sıcaklıkta 4, 6 ve 8 saat alüminyum kaplanmış Ti6Al4V alaşımının XRD analizi

Yang ve arkadaşlarının [1], Ti6Al4V titanyum alaşımını 400°C–800°C sıcaklıkta kutu sementasyonu yöntemiyle yaptığı alüminyum kaplama işleminde, benzer olarak 700°C sıcaklıkta 6 saat alüminyumla işlemi sonrasında XRD analizinde TiAl₃ fazının varlığına rastlanmıştır. Kaplama tabakasının üst kısmında TiAl₃ birikimi sağlanmıştır.


Şekil 3.4.'de Ti6Al4V alaşımının 700° C sıcaklıkta 4, 6 ve 8 saat alüminyumlanmış numunelerin SEM-EDS analizleri yer almaktadır. Sonuçlara baktığımızda sürenin artmasıyla beraber başlangıçta kaplama tabakasının kalınlığı ve daha sonra tabakanın kalınlığı düştüğü görülmektedir. Tabaka kalınlığı en fazla 18 µm ile 6 saat alüminyumlanmış numunede görülmektedir. Kaplama tabakalarının mikro yapı açısından incelendiğinde titanyum alüminid tabakası üç katman şeklinde olduğu görülmektedir. Üst kısımlarda alüminyumca zengin TiAl₃ tabakası oluşurken, yüzeyden aşağıya doğru TiAl₂ ve kaplamanın altlık malzemesi ile temas ettiği bölgede ise TiAl fazı oluşmuştur. Şekil 3.4.'de 1 numara ile gösterilen noktalarda 4 saat alüminyumlanmış numunede ağırlıkça %68,388 Al, 6 saat işlem görmüş numunede ağırlıkça %68,616 Al ve 8 saat de ise ağırlıkça %61,288 Al oranı görülmektedir. Burada görülen alüminyum oranının azalmasının, alüminyumun oksijenle reaksiyona girmesi ve TiAl₃ fazının TiAl₂ fazına dönüşmesi olarak yorumlanabilir. Şekil 3.5.'de yer alan Ti-Al denge diyagramına bakıldığında stokiometrik olarak, ağırlıkça yüzdelere örtüştüğü görülmektedir. Du ve arkadaşlarının [10], Ti6Al4V titanyum alaşımını 1000°C sıcaklıkta kutu sementasyonu yöntemiyle yaptığı alüminyum kaplama işleminde, benzer bir şekilde kaplamanın tabakalı yapıda olduğu ve yukarıdan aşağıya doğru sırasıyla TiAl₃, TiAl₂ ve TiAl fazlarından oluştuğu görülmüştür. Alüminyum kaplama sonrası oluşan fazlardan TiAl₃ tabakası altlık malzemesinin oksidasyon direncini arttırmaktadır. TiAl₃, hafifliği ve içerdiği yüksek alüminyum miktarından dolayı yüksek sıcaklıklarda oksidasyona karşı direnci nedeniyle öneme sahiptir [11].

(a)




| No | ağ. % | | |
|----|--------|--------|--------|
| | Al | Ti | V |
| 1 | 68,388 | 31,612 | - |
| 2 | 69,036 | 30,964 | - |
| 3 | 59,490 | 40,510 | - |
| 4 | 45,428 | 54,572 | - |
| 5 | 8,149 | 89,569 | 2,283 |
| 6 | 5,748 | 81,108 | 13,144 |

b)




| No | ağ. % | | | |
|----|--------|--------|-------|--------|
| | Ti | Al | O | V |
| 1 | 31,160 | 68,616 | 0,224 | - |
| 2 | 31,415 | 68,570 | 0,015 | - |
| 3 | 32,063 | 67,935 | - | - |
| 4 | 33,363 | 66,637 | - | - |
| 5 | 42,050 | 57,950 | - | - |
| 6 | 59,735 | 40,265 | - | - |
| 7 | 82,112 | 15,712 | - | 2,176 |
| 8 | 80,715 | 4,484 | - | 14,801 |
| 9 | 88,721 | 8,469 | - | 2,810 |



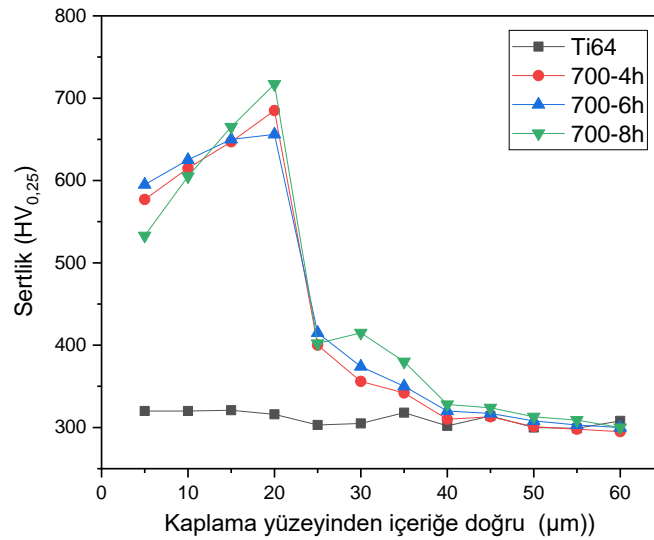
| No | ağ. % | | | |
|----|--------|--------|--------|-------|
| | Ti | Al | V | O |
| 1 | 38,030 | 61,288 | - | 0,651 |
| 2 | 30,393 | 68,784 | - | 1.323 |
| 3 | 30,312 | 69,688 | - | - |
| 4 | 40,401 | 59,598 | - | - |
| 5 | 60,903 | 39,097 | - | - |
| 6 | 78,026 | 18,666 | 3,308 | - |
| 7 | 77,734 | 5,465 | 16,801 | - |
| 8 | 88,797 | 8,313 | 2,890 | - |

Şekil 3.4. Ti6Al4V alaşımının 700° C sıcaklıkta a) 4, b) 6 ve c) 8 saat alüminyumlanmış numunelerin SEM-EDS analizi



Şekil 3.5. Ti-Al faz diyagramı [12]

Numunelerin mikro sertlikleri Vickers elmas piramit uç kullanılarak 15 gr yük altında 10 saniye süre ile oluşturulan iz yardımı ile belirlenmiştir. Sertlik değerleri 5 ayrı ölçümün ortalamasıdır. Elde edilen sertlik değerlerinin ortalaması alınarak, sonuçlar Şekil 3.6.'da verilmiştir. 700°C sıcaklıkta 4,6 ve 8 saat alüminyumlanmış, TiAl₃ kaplamalardan alınan sertlik değerleri, Ti6Al4V titanyum alaşımının sertlik değeri olan 320±15 HV'den yüksek olup 4 saatte 595±20 HV, 6 saatte 650±15 HV ve 8 saatte 570±15 HV olarak belirlenmiştir. Sertlik değerleri karşılaştırıldığında en yüksek sertlik değerinin 6 saat alüminyumlanmış numunede görüldüğü açıktır. Bu artış yoğun bir alüminid tabakasının oluşumuna işaret etmektedir. Rastkar ve arkadaşları [13] Ti-45Al-2Nb-2Mn-1B titanyum alaşımını kutu sementasyon yöntemiyle 750°C sıcaklıkta alüminyum kaplaması sonucunda TiAl₃ esaslı kaplama üretmişler ve benzer olarak altlık malzemeden (330 HV) kaplamada daha yüksek bir sertlik (600 HV) elde etmişlerdir. Aynı şekilde Gök [14] farklı yöntemlerle titanyum alüminyum intermetalik kaplama oluşturulması çalışmasında TiAl₃ alaşımının enine kesitinden aldığı sertlik değeri benzer şekilde 576 HV sertlik değerini bulmuştur. Bu çalışmada elde edilen sertlik değerlerinin literatür ile uyumlu olduğu görülmüştür.



Şekil 3.6. Ti6Al4V alaşımının 700° C sıcaklıkta 4, 6 ve 8 saatte yüzeyinde oluşan titanyum alüminid tabakasının yüzeyden içeriye doğru mikrosertlik dağılımı

4 Sonuçlar

Bu çalışmada aşağıdaki sonuçlar çıkarılabilir:

- 1) Ti6Al4V alaşımının kutu sementasyonu yöntemiyle alüminyum kaplama sonucunda yüzeyde homojen ve sürekli bir alüminyumca zengin kaplama tabakasına, 700°C sıcaklık 6 saat tutma süresinde ulaşılmıştır.
- 2) Kaplama tabakası kalınlığı sürenin armasıyla birlikte, 4 saatte 10 μm iken 6 saatte 18 μm şeklinde artmış fakat 8 saatte 13 μm şeklinde bir düşüş olmuştur.

- 3) XRD ve SEM analizlerinde kaplama tabakasında Ti-Al denge diyagramında yer alan $TiAl_3$, $TiAl_2$ ve $TiAl$ fazlarından oluşan çok katmanlı bir intermetalik kaplama tabakası oluşmuştur.
- 4) Kaplama süresine bağlı olarak sertliğin 595 HV, 650 HV ve 570 HV değerleri arasında değiştiği görülmüş ve en yüksek sertlik değerinin 6 saat alüminyumlanmış numunede olduğu tespit edilmiştir.

5 Beyanname

5.1 Teşekkür

İntermetalikler konusunda ve birçok alanda ülkemize, üniversitemize büyük katkılar sunan, biz öğrencilerimizi aydınlatan, yol gösteren, çalışmalarımıza ışık tutan, yeri hiçbir zaman dolmayacak kıymetli hocam, Merhum, Prof.Dr. Sakin Zeytini'ni saygı ve özlemle anıyorum.

5.2 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

5.3 Yazarların Katkıları

1. Ferhat YILMAZ: Makaleye katkısı. (Deneyisel çalışma yapmak, verileri düzenlemek ve raporlamak, araştırma sırasında literatür taraması için sorumluluk almak, sonuçların açıklanması ve sunulması için sorumluluk almak, araştırma sırasında literatür taraması için sorumluluk almak.)

2. Gözde ÇELEBİ EFE: Makaleye katkısı. (Makalenin tamamının veya ana kısmının oluşturulması için sorumluluk almak, verilerin sadece yazım ve dilbilgisi açısından değil, aynı zamanda entelektüel içerik veya diğer katkılar açısından da yeniden işlenmesini düzenlemek ve raporlamak.)

3. Sorumlu Yazar Tuba YENER: Makaleye katkısı. (Araştırma için fikir geliştirmek, sonuçlara ulaşmak için materyal ve yöntemleri planlamak, deneyler için sorumluluk almak, sonuçların açıklanması ve sunulması için sorumluluk almak, makalenin tamamının veya ana bölümünün oluşturulması için sorumluluk almak.)

Kaynakça

- [1] W. Yang *et al.*, "Evaluation of growth kinetics of aluminide coating layers on Ti6Al4V alloys by pack cementation and the oxidation behaviours of the coated Ti6Al4V alloys," *Int. J. Refract. Met. Hard Mater.*, vol. 101, p. 105642, Dec. 2021, doi: 10.1016/J.IJRMHM.2021.105642.
- [2] T. Yener, "Chromium-Aluminide Coatings via Pack Cementation Method on Inconel 718 Alloy and Fe-Cr-Ni SuperAlloy," *Sak. Univ. J. Sci.*, vol. 23, no. 5, pp. 817–823, Oct. 2019, doi: 10.16984/sofenbilder.495407.
- [3] T. Yener, "Low temperature aluminising of Fe-Cr-Ni super alloy by pack cementation," *Vacuum*, vol. 162, no. September 2018, pp. 114–120, 2019, doi: 10.1016/j.vacuum.2019.01.040.
- [4] F. J. Pérez, M. P. Hierro, F. Pedraza, M. C. Carpintero, C. Gómez, and R. Tarín, "Effect of fluidized bed CVD aluminide coatings on the cyclic oxidation of austenitic AISI 304 stainless steel," *Surf. Coatings Technol.*, vol. 145,

- no. 1–3, pp. 1–7, Aug. 2001, doi: 10.1016/S0257-8972(01)01019-2.
- [5] K. M. Döleker *et al.*, “Enhancing the wear and oxidation behaviors of the Inconel 718 by low temperature aluminizing,” *Surf. Coatings Technol.*, vol. 412, p. 127069, Apr. 2021, doi: 10.1016/J.SURFCOAT.2021.127069.
- [6] T. Yener, A. Erdogan, M. S. Gök, and S. Zeytin, “Formation, characterization, and wear behavior of aluminide coating on mirrax® ESR steel by low-temperature aluminizing process,” *J. Tribol.*, vol. 143, no. 1, 2021, doi: 10.1115/1.4047667.
- [7] A. Erdogan, T. Yener, K. M. Doleker, M. E. Korkmaz, and M. S. Gök, “Low-temperature aluminizing influence on degradation of nimonic 80A surface: Microstructure, wear and high temperature oxidation behaviors,” *Surfaces and Interfaces*, vol. 25, p. 101240, Aug. 2021, doi: 10.1016/J.SURFIN.2021.101240.
- [8] T. Yener, K. M. Doleker, and A. Erdogan, “High temperature oxidation behavior of low temperature aluminized Mirrax® ESR steel,” *Mater. Res. Express*, vol. 6, no. 11, 2019, doi: 10.1088/2053-1591/ab4541.
- [9] S. S. Rahman, M. Z. I. Ashraf, M. S. Bashar, M. Kamruzzaman, A. K. M. Nurul Amin, and M. M. Hossain, “Crystallinity, surface morphology, and chemical composition of the recast layer and rutile-TiO₂ formation on Ti6Al4V ELI by wire-EDM to enhance biocompatibility,” *Int. J. Adv. Manuf. Technol.*, vol. 93, no. 9–12, pp. 3285–3296, 2017, doi: 10.1007/s00170-017-0772-5.
- [10] H. Du, N. Tan, L. Fan, J. Zhuang, Z. Qiu, and Y. Lei, “Formation mechanism of aluminide diffusion coatings on Ti and Ti6Al4V alloy at the early stages of deposition by pack cementation,” *Materials (Basel)*, vol. 12, no. 19, 2019, doi: 10.3390/ma12193097.
- [11] R. Khoshhal, “Effect of TiAl₃ Coating Thickness and Morphology, Formed Using the Immersion of Titanium Sheets in Molten Aluminum, on Titanium Oxidation Behavior,” *Met. Mater. Int.*, vol. 25, no. 2, pp. 449–455, Mar. 2019, doi: 10.1007/S12540-018-0183-7/FIGURES/9.
- [12] The Materials Information Society, “ASM Handbook Volume 3 - Alloy Phase Diagrams,” *ASM Handbook*. 1992. doi: 10.1007/BF02869318.
- [13] A. R. Rastkar, P. Parseh, N. Darvishnia, and S. M. M. Hadavi, “Microstructural evolution and hardness of TiAl₃ and TiAl₂ phases on Ti-45Al-2Nb-2Mn-1B by plasma pack aluminizing,” *Appl. Surf. Sci.*, vol. 276, pp. 112–119, Jul. 2013, doi: 10.1016/j.apsusc.2013.03.043.
- [14] O. Gök, “Farklı Yöntemlerle Titanyum Alüminyum İntermetalik Kaplama Oluşturulması Çalışması,” İstanbul Teknik Üniversitesi, 2016.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).



Görüntü İşleme ve Makine Öğrenmesi Kullanılarak Metalik Malzemelerin Boyut Tespiti ve Sınıflandırılması

Tuba YENER^{1*} , Furkan Hasan SAKACI² , Ş. Çağrı YENER³ 

¹ Metalurji ve Malzeme Mühendisliği Bölümü, Mühendislik Fakültesi, Sakarya Üniversitesi, Türkiye.
tcerezci@sakarya.edu.tr

² Simülasyon ve Otonom Sistemler, HAVELSAN, Ankara, Türkiye. fhsakaci@havelstan.com.tr

³ Elektrik ve Elektronik Mühendisliği Bölümü, Sakarya Üniversitesi, Sakarya Üniversitesi, Türkiye.
syener@sakarya.edu.tr

ÖZ

Metalik malzemelerin makroskobik seviyede boyut ölçümü ve sınıflandırılması endüstriyel proseslerde çeşitli amaç ve yöntemlerde gerçekleştirilen bir işlemdir. Bu çalışmada bakır, alüminyum ve çelik olmak üzere üç farklı metal türüne ait metalik malzemelerin görüntü işleme ile boyut ölçümü ve makine öğrenmesi ile malzeme sınıflarının belirlenmesi gerçekleştirilmiştir. Boyut ölçümünde kullanılan kamera modülü ve alınan görüntü kalitesine bağlı olarak hedeflenen %99.5'in üzerinde doğruluk sağlanmıştır. Farklı makine öğrenmesi yöntemlerinin başarımı ayrı ayrı test edilmiş, Fine KNN ile malzeme sınıflandırması tam doğrulukla gerçekleştirilmiştir.

Anahtar Kelimeler: Metaller, görüntü işleme, makine öğrenmesi, (KNN) K-en yakın komşu algoritması

Dimension Measurement and Classification of Metallic Materials Using Image Processing and Machine Learning

ABSTRACT

In industrial processes, dimension measurement and classification of metallic materials at the macroscopic level are performed for various purposes with various methods. In this study, dimensions of metal materials belonging to three different types such as copper, aluminum and steel have been obtained by using image processing, and their classification has been performed by using machine learning. For the size measurement, over 99.5% accuracy has been achieved based on the quality of the camera module used and the image quality received. The performance of various machine learning methods has been tested for the material classification and the error-free result has been obtained with fine KNN.

Keywords: Metals; image processing; machine learning; KNN (K-nearest neighborhood)

* Sorumlu yazarın e-posta adresi: tcerezci@sakarya.edu.tr

1 Giriş

Görüntü işleme teknikleri üzerindeki gelişmeler çeşitli özellik, model ve kategorize etme yöntemlerini ortaya koyarak malzemelerin sınıflandırılması ve tanımlanmasına olanak sağlamaktadır [1–5]. Görüntülerin işlenmesinde ve sınıflandırılmasında renk, doku, spektral yoğunluk gibi özelliklerden faydalanılır [5–11]. Makine öğrenmesi yöntemlerinin malzeme biliminin farklı alanlarına uygulanması da önemli olanaklar katmaktadır [12].

Malzemelerin makroskobik seviyede boyut ölçümü çok farklı amaç ve yöntemlerle gerçekleştirilen bir işlemdir. Malzeme boyutları ultrasonik, lazer temelli sensörlerle belirlenebilse de, otonom sistemlerde malzeme yerleşiminin uygun olmaması gibi nedenlerle hatalı ölçüm yapılması söz konusu olur. Daha kompleks sistemler ölçüm işlemini gerekli doğrulukta yapabilirler. Fakat bu sistemlerin dezavantajı ilave kapsamlı donanımlar gerektirmeleri ve maliyetli oluşlarıdır. Malzeme boyutlarının görüntü işleme tekniklerinden yararlanarak belirlenmesi hızlı ve ekonomik çözüm sağlayan bir yöntem olmaktadır [13–19].

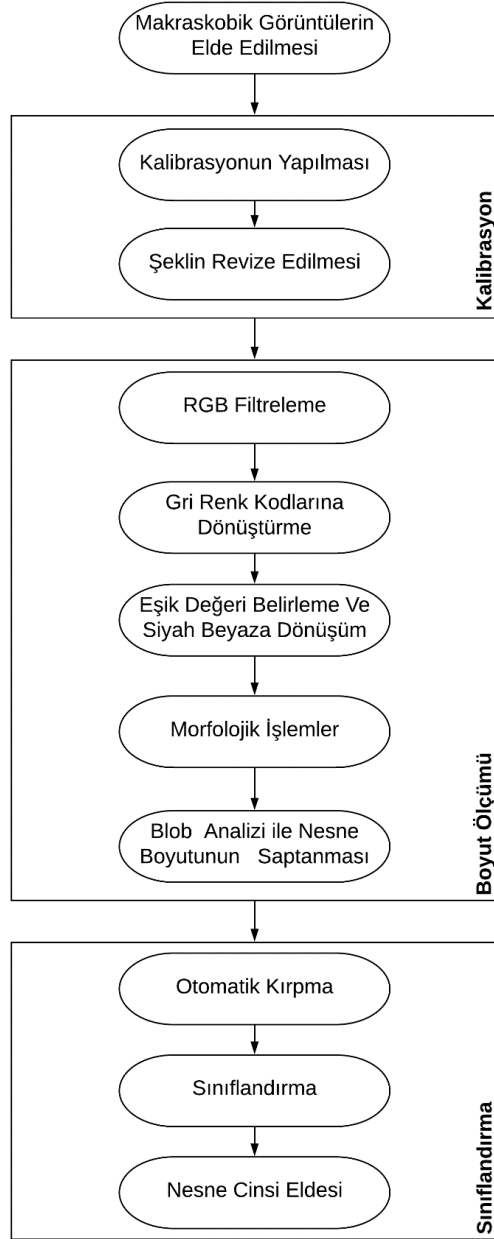
Görüntülerin tanımlanmasında iki temel basamak, özellik çıkarımı ve sınıflandırmadır. Görsellerde özellik çıkarımı için manuel ve otomatik yöntemler uygulanmaktadır. Sınıflandırma için makine öğrenmesi yöntemlerinden destek vektör makinesi (Support Vector Machine, SVM), K-en yakın komşu (K Nearest Neighborhood, KNN) ve ağaç (tree) gibi algoritmalar gerekli doğruluk sağlayan algoritmalar [20–23]. Malzemelerin görüntü işleme teknikleri ile sınıflandırılmasında, mikroskobik görüntülerle daha yüksek başarımlar elde edilebilir. Ancak mikroskobik görüntünün alınmasında; malzemenin uygun boyuta getirilmesi (kesilmesi, kalıplanması), ön hazırlıklar (zımparalama, parlatma, dağlama), görüntüleme ekipmanı üzerinde yapılması gereken ayarlamalar gibi sürecin uzamasına yol açan etmenler söz konusudur. Ayrıca bu yöntemde kullanılan görüntüleme ekipmanlarının yüksek maliyetlidir [24–27]. Bu bağlamda, kolayca erişilebilir ve uygun maliyetli bir kamera modülü ile malzemenin ölçümü ve sınıflandırılmasını gerekli doğrulukta sağlayacak görüntüler hızlı ve ucuz biçimde elde edilebilmesi önemli avantaj sağlamaktadır [13–18,28].

Bu çalışmada farklı metalik malzemelerin görüntü işleme temelli boyut ölçümüne ve sınıflandırılmalarına yönelik yaklaşım ve gerçekleştirme aşamaları sunulmuştur. Hızlı çalışan otonom bir ayrıştırma sistemi için uygun olan bu yöntemle, malzemenin standart bir fotoğraf çekme modülü ile görüntüsünün alınması, ardından bu tek veri ile boyut ve malzeme sınıflandırması olmak üzere iki çıkarım yapılmaktadır.

Bu çalışma aşağıdaki biçimde planlanmıştır: Giriş bölümünün ardından çalışmanın ikinci bölümünde malzeme ölçümü ve sınıflandırılmasına yönelik ele alınan problem tanımlanmış ve gerçekleştirilecek süreç basamakları sunulmuştur. Çalışmanın üçüncü bölümünde malzemenin boyut tespitine yönelik aşamalar, dördüncü bölümünde sınıflandırmaya ilişkin işlem adımları ve elde edilen sonuçlar sunulmuştur. Çalışma sonuçlarına ilişkin son bölümle tamamlanmıştır.

2 Metodoloji

Malzemenin boyutunun tespiti için en temel iki nokta doğru referans uzunluğun belirlenmesi ve görüntünün kalibrasyon işlemi yapılarak ele alınması gerekliliğidir. Referans uzunluğun görüntü işleme algoritması tarafından doğru biçimde belirlenmesi için dama tahtası görünümünde bir referans düzlem kullanılmıştır. İkinci temel işlem basamağı olan sınıflandırma için, algoritmanın hızlı ve yüksek doğruluklu çalışmasına yönelik malzeme referans boyut düzlemi ve boş arka plandan otomatik ayrıştırılarak özellik seçimine yönelik görüntüler oluşturulmuştur. Gerçekleştirilen işlem basamaklarına yönelik süreç adımları Şekil 1’de verilmiştir.

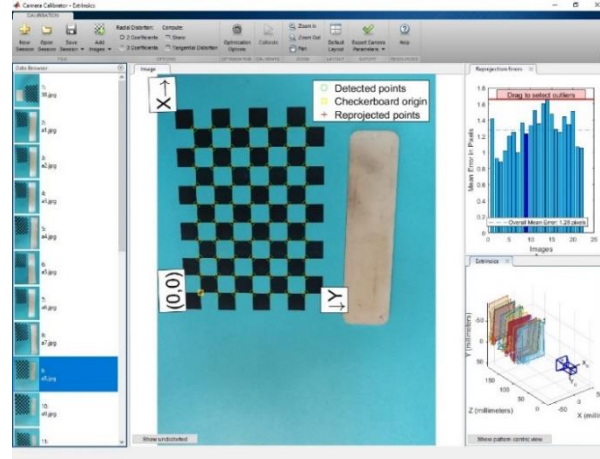


Şekil 1. İşlem basamaklarına yönelik süreç adımları


3 Malzemelerin Boyut Ölçümü

Malzemelerin boyut ölçümünün doğru yapılabilmesi için ilk aşamada ölçüm alınacak ortamın kalibrasyonunun yapılması gerekmektedir. Bu amaçla dama tahtası görünümlü referans düzlemin kalibrasyonu için farklı açılardan fotoğraf alınmıştır. Alınan bu görüntülerle MATLABTM programında


bulunan Kamera Calibration aracı kullanılarak kalibrasyon parametreleri elde edilmiştir (Şekil 2 a). Alınan ham görüntü ve kalibrasyon sonrası ölçüm referansı için kullanılacak görüntüler sırasıyla Şekil 2 b) ve c)'de verilmiştir. Kalibrasyon işlemi sonrası elde edilen parametreler, oluşturan algoritmaya ilişkin koda aktarılmıştır.



a)



b)



c)


Şekil 2. Ölçüm kalibrasyonuna ilişkin a) MATLAB ortamında Kamera Calibration aracının kullanımı, b) ham görüntü, c) kalibrasyon işlemi sonrası referans uzunluk için kullanılacak görüntü



a)



b)



c)

Şekil 3. Görüntünün işlenmesi ve boyut belirlenmesine yönelik adımlar: a) filtreleme, b) temizleme ve doldurma, c) belirlenen boyutlar.

Kalibrasyon işlemi yapılan fotoğrafta ölçüm alınacak nesnenin saptanabilmesi için öncelikle RGB filtreleme yapılmıştır. Burada arka plan rengi, boyut belirlemesi ve sınıflandırma için kullanılacak metal malzemelerden olabildiğince ayrışacak biçimde seçilmiştir.

Malzemenin saptanabilmesi öncelikle için arka plan ve ölçü referans düzleminin filtrelenmesi gerekmektedir. Bu filtreleme işlemi sonrası elde edilen görüntü Şekil 3 a ile verilmiştir. Bu işlemin ardından görüntü ilk olarak gri tonlara, ardından otomatik eşik (threshold) belirlemesi ile siyah beyaz renklere dönüştürülmüştür. Ardından temizleme ve doldurma işlemleri yapılarak Şekil 3 b)'de verilen görüntü elde edilmiştir. Malzemenin boyutunun belirlenmesi için öncelikle pixel cinsinden en ve boy değerleri belirlenmiştir. Ardından daha önce elde edilmiş kalibrasyon değerleri kullanılarak gerçek ölçüler 32.45 mm ve 198.02 mm olarak belirlenmiştir.

4 Malzemelerin Sınıflandırılması

Cisimlerin hangi malzeme grubuna dahil olduğunu saptamak için ise alüminyum, çelik ve bakır fotoğrafları ayrı ayrı düzenlenmiştir. Düzenlenen bu fotoğraflarda öncelikle otomatik kırpma işlemi yapılmıştır. Daha sonra bu fotoğraflar kullanılarak otomatik özellik çıkarımı yapılmış ve bu özellikler kullanılarak eğitim yapıp eğitim algoritmalarından hangisinin en iyi olduğunu saptamak için Classification Learner aracı kullanılmıştır.

Kullanılan yöntemlerden, KNN, k değerine göre gözlemlerin yapılacağı sınıfı ve en yakın komşuyu belirleyen parametrik olmayan bir sınıflandırma modelidir. KNN, sınıflandırmayı yeni bir noktaya yakın noktalara bakarak, birbirine yakın olan öğelerin aynı kategoriye ait olduğu temeline göre yapar.

SVM yöntemi sınıflandırma ve regresyon analizi için verileri işleyen denetimli öğrenme modelidir. SVM, iki kategori arasındaki boşluğun genişliğini en üst düzeye çıkarmak için eğitim örneklerini uzaydaki noktalara eşler. Yeni örnekler ardından aynı alana eşlenir ve boşluğun hangi tarafına düştüklerine bağlı olarak bir kategoriye ait oldukları tahmin edilir.

Basit Karar Ağacı Analizi, bir veri setini farklı koşullara göre ayırmanın yollarını tanımlayan algoritmik bir yaklaşımla oluşturulan genel tahmine dayalı bir modelleme aracıdır. Denetimli öğrenme için en

yaygın kullanılan yöntemlerden biri olup veri özelliklerinden çıkarılan basit karar kurallarını öğrenerek bir hedef değişkenin değerinin tahmini sağlar.

Bu araç kullanılarak algoritmalara göre başarı oranları Tablo 1 ile verilmiştir.

Tablo 1: Algoritmalara Göre Başarı Oranları

| Model Tipi | Başarı (%) |
|---------------------|------------|
| Fine KNN | 100 |
| Kubik KNN | 82.2 |
| Kubik SVM | 97.8 |
| Lineer SVM | 93.3 |
| Medium Gaussian SVM | 96.7 |
| Basit Ağaç | 86.7 |

| | | | |
|---|-----------------|----|----|
| 0 | 30 | | |
| 1 | | 30 | |
| 2 | | | 30 |
| | 0 | 1 | 2 |
| | Predicted class | | |

Şekil 4: Fine KNN modelinin karıştırma matrisi, 0:Alüminyum, 1: Bakır, 2: Çelik

5 Sonuçlar

Bu çalışmada bakır, alüminyum ve çelik olmak üzere üç farklı metal türüne ait malzemelerin görüntü işleme ile boyut ölçümü ve makine öğrenmesi ile malzeme sınıflarının belirlenmesi gerçekleştirilmiştir. Malzeme taşınımı ve ayrıştırması yapan otonom sistemler yanında, görüntünün taşınabilir bir kamera modülü ile operatör tarafından manuel olarak da alınabilmesi, bunun sonucunda yüksek doğruluklu bir sonuç elde edilmesi amaçlanmıştır. Literatürde yapılan benzer çalışmalarda özellikle altın ve gümüş boyutunun ve cinsinin tespitleri yapılmıştır. Yapılan çalışmalarda %90 ile %98 arasında başarı

sağlanmıştır. Boyut ölçümünde kullanılan kamera modülü ve alınan görüntü kalitesine bağlı olarak %99.5'in üzerinde doğruluk sağlanmıştır. Çelik, bakır ve alüminyum gibi ergime sıcaklıklarından mekanik özelliklerine kadar farklı özellik gösteren metalik bağ yapısına sahip malzemelerin ayrıştırılması makine öğrenmesi temelli gerçekleştirilmiş ve başarıyı farklı makine öğrenmesi yöntemleri ile ayrı ayrı test edilmiştir. Fine KNN ile malzeme sınıflandırması tam doğrulukla gerçekleştirilmiştir.

6 Beyanname

6.1 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

6.2 Yazarların Katkıları

1. Sorumlu Yazar Tuba YENER: Makaleye katkısı. (Verileri düzenlemek ve raporlamak, araştırma sırasında literatür taraması için sorumluluk almak, sonuçların açıklanması ve sunulması için sorumluluk almak, araştırma sırasında literatür taraması için sorumluluk almak.)

2. Furkan Sakacı: Makaleye katkısı. (Deneylerin yapılması, makalenin tamamının veya ana kısmın oluşturulması için sorumluluk almak, verilerin sadece yazım ve dilbilgisi açısından değil, aynı zamanda entelektüel içerik veya diğer katkılar açısından da yeniden işlenmesini düzenlemek ve raporlamak.)

3. Şuayb Çağrı Yener: Makaleye katkısı. (Araştırma için fikir geliştirmek, sonuçlara ulaşmak için materyal ve yöntemleri planlamak, sonuçların açıklanması ve sunulması için sorumluluk almak, makalenin ana bölümünün oluşturulması için sorumluluk almak.)

Kaynakça

- [1] J. C. Grande, "Principles of Image Analysis," *Metallography, Microstructure, and Analysis*, vol. 1, no. 5, pp. 227–243, Oct. 2012.
- [2] A. Picon, O. Ghita, P. F. Whelan, and P. M. Iriando, "Fuzzy Spectral and Spatial Feature Integration for Classification of Nonferrous Materials in Hyperspectral Data," *IEEE Transactions on Industrial Informatics*, vol. 5, no. 4, pp. 483–494, Nov. 2009.
- [3] N. Salamati and C. Fredembach, "Material Classification Using Color and NIR Images." <https://infoscience.epfl.ch/record/142367/files/SalamatiFS2009.pdf> (accessed February 3, 2019).
- [4] S. Su *et al.*, "Material Classification Using Raw Time-of-Flight Measurements." <https://vccimaging.org/Publications/Su2016MCU/Su2016MCU.pdf> (accessed February 3, 2019).
- [5] M. Strese, C. Schuwerk, A. Iepure, and E. Steinbach, "Multimodal Feature-Based Surface Material Classification," *IEEE Transactions on Haptics*, vol. 10, no. 2, pp. 226–239, Apr. 2017.
- [6] B. Jin, W. Hu, and H. Wang, "Image Classification Based on pLSA Fusing Spatial Relationships Between Topics," *IEEE Signal Processing Letters*, vol. 19, no. 3, pp. 151–154, Mar. 2012.
- [7] G. Wu *et al.*, "Light Field Image Processing: An Overview," *IEEE Journal of Selected Topics in Signal Processing*, vol. 11, no. 7, pp. 926–954, Oct. 2017.

- [8] Bang Zhang, Yang Wang, and Fang Chen, "Multilabel Image Classification Via High-Order Label Correlation Driven Active Learning," *IEEE Transactions on Image Processing*, vol. 23, no. 3, pp. 1430–1441, Mar. 2014.
- [9] G. Schwartz and K. Nishino, "Recognizing Material Properties from Images." <https://arxiv.org/pdf/1801.03127.pdf> (accessed February 3, 2019).
- [10] E. S. Nadimi, J. Herp, M. M. Buijs, and V. Blanes-Vidal, "Texture classification from single uncalibrated images: Random matrix theory approach," in *2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP)*, 2017, pp. 1–6.
- [11] M. Varma and A. Zisserman, "A Statistical Approach to Material Classification Using Image Patch Exemplars," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, no. 11, pp. 2032–2047, Nov. 2009.
- [12] Y. Liu, T. Zhao, W. Ju, and S. Shi, "Materials discovery and design using machine learning," *Journal of Materiomics*, vol. 3, no. 3, pp. 159–177, Sep. 2017.
- [13] J. Rejc *et al.*, "The mechanical assembly dimensional measurements with the automated visual inspection system," *Expert Systems with Applications*, vol. 38, no. 8, pp. 10665–10675, Aug. 2011.
- [14] E. G. Loewen, "High Speed Optical Scanning Techniques for Dimensional Measurement," *CIRP Annals*, vol. 29, no. 2, pp. 513–518, Feb. 1980.
- [15] G. Rosati, G. Boschetti, A. Biondi, and A. Rossi, "On-line dimensional measurement of small components on the eyeglasses assembly line," *Optics and Lasers in Engineering*, vol. 47, no. 3–4, pp. 320–328, Mar. 2009.
- [16] P. Klapetek and T. Dziomba, "Dimensional Measurements," *Quantitative Data Processing in Scanning Probe Microscopy*, pp. 97–149, Jan. 2018.
- [17] B. Chao, Q. Xinghua, L. Yong, L. Yaping, and L. Jingliang, "Dimensional Measurement of Small Hot Pieces Based on a Monochrome CCD," *Procedia Engineering*, vol. 99, pp. 1158–1163, Jan. 2015.
- [18] N. H. Maerz, "Aggregate sizing and shape determination using digital image processing," 1998, pp. 195–203.
- [19] A. Lashgari, S. Ghamami, S. Shahbazkhany, G. Salgado-Morán, and D. Glossman-Mitnik, "Fractal Dimension Calculation of a Manganese-Chromium Bimetallic Nanocomposite Using Image Processing," *Journal of Nanomaterials*, vol. 2015, pp. 1–9, Apr. 2015.
- [20] A. Shayei, M. Abbasi, A. Habiban, M. Shabany, and Z. Kavehvash, "A Machine Learning Approach for Material Classification in MMW Imaging Systems based on Frequency Spectra," in *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*, 2018, pp. 1–5.
- [21] Quan-De Wang, Zhi-Feng Zhong, and Xian-Pei Wang, "Design and implementation of insulators material hydrophobicity measure system by support vector machine decision tree learning," in *2005 International Conference on Machine Learning and Cybernetics*, 2005, pp. 4328–4334 Vol. 7.
- [22] M. J. Mendenhall and E. Merenyi, "Relevance-Based Feature Extraction for Hyperspectral Images," *IEEE Transactions on Neural Networks*, vol. 19, no. 4, pp. 658–672, Apr. 2008.
- [23] T. Aujeszky, G. Korres, and M. Eid, "Thermography-based material classification using machine learning," in *2017 IEEE International Symposium on Haptic, Audio and Visual Environments and Games (HAVE)*, 2017, pp. 1–6.
- [24] B. L. DeCost and E. A. Holm, "A computer vision approach for automated analysis and classification of microstructural image data," *Computational Materials Science*, vol. 110, pp. 126–133, Dec. 2015.
- [25] L. Kunčická, R. Kocich, and T. C. Lowe, "Advances in metals and alloys for joint replacement," *Progress in Materials Science*, vol. 88, pp. 232–280, Jul. 2017.
- [26] A. Pineau, A. A. Benzerga, and T. Pardoen, "Failure of metals I: Brittle and ductile fracture," *Acta Materialia*, vol. 107, pp. 424–483, Apr. 2016.

- [27] Z. Gácsi, “The Application of Digital Image Processing for Materials Science.” <http://www.scientific.net> (accessed February 9, 2019).
- [28] L. Barazzetti and M. Scaioni, “Development and implementation of image-based algorithms for measurement of deformations in material testing.,” *Sensors (Basel, Switzerland)*, vol. 10, no. 8, pp. 7469–95, 2010.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).



PID Kontrollü IoT Haberleşme İle Android Tabanlı Egzersiz Takibi

Mert Süleyman DEMİRSOY*^{ID}, Mustafa Çağrı KUTLU^{ID}, Mohammed MANSOUR^{ID}

Mekatronik Mühendisliği, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye

ÖZ

Rehabilitasyon zahmetli ve maliyetli bir tedavi sürecidir. İnmeden hemen sonra yapıldığında çok etkili olduğu bilinmektedir, ancak bu süre zarfında tüm hastalar tedavi görme imkanı bulamamaktadır. Ayrıca yoğunlaştırılmış tedavi seansları ve hedefe yönelik rehabilitasyon, evde rehabilitasyonun verimliliğini önemli ölçüde arttırmaktadır. Evde rehabilitasyonun bir diğer önemi hasta sayısı arttıkça rehabilitasyon gereksinimlerinin karşılanması zorlaşmaktadır. Rehabilitasyon robotları, terapistin aynı anda birkaç hastayı tedavi etmesine imkan sağlar ve iş yükünü azaltır. Ancak rehabilitasyon robotları pahalı ve ev ortamında tedaviye uygun değildirler. Eklemeli imalatın geliştirilmesi, dış iskelet gibi bazı rehabilitasyon robotlarının potansiyelini ve maliyetlerini arttırmaktadır. Bu robotik sistemlerin rehabilitasyon sürecinde kullanılması da önemli bir teknik sorundur. Bu nedenle robotik rehabilitasyon için dış iskeletler kullanılarak, hastaların anatomik yapılarına göre uzuvlarını saracak şekilde tasarlanmalıdır. Ek olarak bu dış iskeletler ev ortamında kullanılmak üzere tasarlanmalı ve kullanımı kolay ve hasta tarafından takılıp çıkarılabilen olmalıdır. Çalışmada kullanılan cihaz için tasarlanan kontrolcünün konum hata değerlerinin normu 1,755° olmakta birlikte, fizyoterapistler tarafından rehabilitasyon sürecindeki ilerlemenin izlenmesine hala ihtiyaç vardır.

Anahtar Kelimeler: Nesnelerin interneti, ev bazlı rehabilitasyon, dış iskelet, üst ekstremité

Android Based Exercise Tracking with PID Controlled IoT Communication

ABSTRACT

Rehabilitation is a laborious and costly treatment process. It is known to be very effective when done early after a stroke, but not all patients can have therapy during this time. In addition, intensified sessions and goal-oriented rehabilitation significantly increase rehabilitation efficiency at home. As the number of patients increases, rehabilitation requirements become more difficult to meet. Rehabilitation robots help the therapist treat several patients at the same time and reduce the workload. However, rehabilitation robots are expensive and they are not mobile. The development of additive manufacturing increases the potential and costs of some rehabilitation robots such as exoskeletons. The use of these robotic systems in the process of rehabilitation is also an important technical problem. Therefore, exoskeletons for robotic rehabilitation should be designed to wrap the patient's limbs according to their anatomical structure. Furthermore, exoskeletons are intended to be

* Sorumlu yazarın e-posta adresi: mertdemirsoy@subu.edu.tr

used in a home-based environment and should be easy to use and don/doff by the patient. Although the norm of the position error values of the controller designed for the device used in the study is 1.755°, there is still a need to monitor the progress of the rehabilitation process by physiotherapists.

Keywords: Internet of things, home based rehabilitation, exoskeleton, upper extremity

1 Giriş

İnme, Türkiye'de yetişkin sakatlığının en büyük ikinci nedenidir. Yaklaşık olarak her 6 kişiden 1'i hayatında bir kez felç geçirir. İnmeye bağlı ölümlerin sayısı yılda 35.000 ile 40.000 arasındadır [1].

İnme sonrası hasta üzerinde belirli fonksiyon kayıpları meydana gelirken üst ekstremitede oluşan etkiler kişinin günlük yaşam aktivitelerini ve bireysel ihtiyaçlarını karşılayabilmesini zorlaştırmaktadır. Bu nedenle, üst ekstremitede hastanın yeme içme, banyo yapma gibi temel ihtiyaçları bakımından önem arz etmektedir [2]. Temel ihtiyaçların karşılanabilmesi için üst ekstremitede rehabilitasyonu oldukça önemli bir yere sahiptir. İnme rehabilitasyonu zahmetli ve maliyetli bir tedavi sürecidir. İnme hastalarının sayısı arttıkça rehabilitasyon ihtiyaçlarının karşılanması da zorlaşmaktadır. Rehabilitasyon inmeden sonra erken yapıldığında çok etkili olduğu bilinmektedir, ancak bu süre zarfında tüm hastalar tedavi görememektedir. Rehabilitasyon robotları, fizyoterapistin aynı anda birkaç hastayı tedavi etmesine ve iş yükünü azaltmasına yardımcı olur. Bu, daha düşük tedavi maliyetleri demektir. Rehabilitasyon robotları, geleneksel tedavi yöntemlerine kıyasla, artan rehabilitasyon gereksinimlerine alternatif olacaktır.

Fizyoterapistler tarafından yapılan geleneksel terapi ile karşılaştırıldığında, robotik rehabilitasyon, daha yoğun ve daha uzun terapi seansları ve hareketlerin daha iyi tekrarlanabilirliği gibi önemli avantajlara sahiptir. Ayrıca yoğunlaştırılmış tedavi seansları ve görev odaklı rehabilitasyon tedavi sürecini kısaltarak iyileşme hızını arttıracaktır. Ek olarak robotik rehabilitasyonda sanal gerçeklik, bilgisayar oyunları vb. bu tür uygulamalarla hastanın rehabilitasyon sürecine aktif katılımı artırılabilir. Robotik rehabilitasyon, hasta performans bilgilerinin kaydedilmesi ve analiz edilmesi gibi ek işlevleri de içermektedir. Eklemli imalattaki son gelişmeler, giyilebilir rehabilitasyon robotlarının maliyetini düşürür. Bu, ev tabanlı bir rehabilitasyon robotunun üretilmesine olanak sağlar. Ancak yine de hasta gelişimini takip etmek için rehabilitasyon sürecinin profesyoneller tarafından takip edilmesine ihtiyaç vardır. Fiziksel nesnelerin birbirleri aracılığıyla belirlenen protokollere dayalı olarak bağlantılı olan ve internete bağlamak için ağ olarak tanımlanan nesnelerin interneti (IoT - Internet of Things) kavramı uygulanabilir. Bu bildiride geliştirilen sistem, IoT donanımı, algılama ekipmanı, kontrol algoritmaları ve mobil uygulamalardaki önemli yenilikler aracılığıyla kol eğitimini desteklemektedir. Özellikle, sistem iki önemli bileşeni bütünleştirir. Birincisi, kontrol algoritmasını çalıştıran bir IoT (Internet of Things) cihazıdır (mikro denetleyici). İkincisi ise fizyoterapist ve hastalar için kullanıcı ara yüzleridir (mobil uygulamalar).

Rehabilitasyon amaçlı tasarlanmış robotik sistemler; terapötik egzersiz robotları, harekete yardımcı dış iskelet robotları, protez ve yürüyen rehabilitasyon robotları gibi birkaç gruba ayrılabilir. Robotik rehabilitasyon için dış iskeletler, anatomik yapılarına göre hastanın uzuvlarını saracak şekilde tasarlanmalıdır.

2 İlişkili Çalışmalar

Bu araştırmanın amacı, ideal düşük maliyetli bir ev tipi egzersiz cihazı geliştirilmesidir. Bu amaç doğrultusunda gerçekleştirilen bu çalışmada nicel araştırma yöntemlerinden araştırma-geliştirme ve deneysel model geliştirilmiştir. Bu yöntemde iki ya da daha fazla grubun belirli değişkenler açısından etkileri incelenmektedir. Rehabilitasyon amaçlı tasarlanmış robotik sistemleri; terapötik egzersiz

robotları, harekete yardımcı dış iskelet robotları, protez ve yürüyen rehabilitasyon robotları olmak üzere 3 gruba ayırabiliriz. Çalışmanın bu bölümünde, nöromusküler hastalıkları olan hastaların dirsek eklemi rehabilitasyon tedavisi için üst ekstremitte dış iskelet robotlarındaki son gelişmeler hakkında bilgi verilecektir.

Birçok rehabilitasyon robotunun, üst ekstremitte etkinlikleri için fonksiyonel hareket kabiliyetleri kısmen sınırlıdır. Buna rağmen mevcut robotların omuz dış iskeleti, üst uzuv stabilizesi için çok önemli bir rol oynamaktadır. Bu sorunu gidermek için Ball ve diğerleri, MEDARM adı verilen ayarlanabilir robot dış iskeletini terapistleri desteklemek için tasarlamıştır [3].

Mekanizma aynı zamanda düzlemsel omuz-dirsek hareketini kolaylaştırmaktadır. Bu mekanizmada aktüatör olarak elektrik motoru kullanılmıştır ve hareket iletimi, halat ve kayış kombinasyonu tarafından yapılmaktadır. Bu, robotun güç-ağırlık oranını optimum seviyeye çıkarmaktadır. Böylece, robot herhangi bir hareket için yer çekimi faktörüne karşı avantaj sağlamaktadır. MEDARM, ayrıca farklı insanların uzuv boyutları için ayarlanabilme özelliğinin yanı sıra en büyük avantajı 5 serbestlik derecesinin tümünü bağımsız olarak kontrol etmenin mümkün olmasıdır [3].

Ripel ve diğerleri çalışmasında robotik dış iskelet ilkelerinden esinlenerek elektrikli aktüatörlü bir aktif dirsek ortezi tasarımı yapmıştır. Cihaz yalnızca dirsek eklemi için yapılmış olsa bile kolay bir şekilde diğer eklemler içinde kolayca değiştirilebilir. Cihazda bir kuvvet ölçer kullanılarak hastanın hareket aktivitesini belirler ve bu ölçüm değerini ortezi çalıştıran aktüatörü kontrol etmek için kullanılmaktadır [4].

Zhang ve diğerlerinin çalışması olan NEEM cihazı, hasta kullanıcıya maksimum konfor ve güvenlik sağlamak için tasarlanmış ve güçlendirilmiş bir dirsek dış iskelet sistemidir. Cihaz gelişmiş ergonomi sağlamak için birçok önemli tasarım çözümünü bünyesinde barındırmaktadır. İlk olarak, çift bağlantı ile cihaz gelişmiş robot-insan etkileşim alanına sahiptir. Diğer mekaniksel özellikleri ise cihaz kompakt ve hafif bir yapıdadır. Bu kompaktlık etkileşim konforunu optimize etmekte önemli bir paya sahiptir [5].

Tablo 1'de literatürdeki araştırılmış ev tipi rehabilitasyona uygun cihazların bilgileri verilmektedir.


Tablo 1: Literatürdeki Bazı Ev Tipi Rehabilitasyona Uygun Çalışmalar

| Yazar | Aktüatör | Kontrol Yöntemi | Kullanım | Yıl |
|------------------|-------------|------------------|---------------------------|------|
| Stephen [3] | Elektriksel | Akıllı kontrol | Fonksiyonel eğitim | 2007 |
| Vanderniepen [6] | Elektriksel | Konum kontrol | Ev bazlı terapi ve eğitim | 2009 |
| Lee [7] | Elektriksel | Kuvvet kontrol | Ev bazlı terapi | 2012 |
| Zhibin [8] | Elektriksel | Empedans kontrol | Ev bazlı terapi | 2013 |
| Ripel [4] | Elektriksel | Kuvvet kontrol | Ev bazlı terapi | 2014 |
| Zhang [5] | Elektriksel | Konum kontrol | Ev-klinik bazlı terapi | 2017 |

3 Sistem Görünümü

Sistem 5 bileşenden oluşmaktadır. Hasta, ev ortamında rehabilitasyon için dış iskeleti bantlar yardımı ile koluna yerleştirdikten sonra EMG elektrotları triseps kasları üzerine yerleştirilir. Kuvvet sensörü dış iskelete konumlandırılmıştır. Geliştirilen tasarımda farklı anatomik uzuv yapısındaki hastaların rehabilitasyon sürecinde kullanılmak üzere esnek ve ergonomik bir tasarım uygulanmıştır.

Veri aktarımı için bulut tabanlı bir iletişim yöntemi olan IoT kullanılmaktadır. EMG, eklem açısı ve kuvvet sinyalleri sensörler tarafından alınarak mikro denetleyiciye iletilmektedir. Bu veriler, bluetooth aracılığıyla mobil uygulamaya aktarılır. Hasta fizyoterapist tarafından önerilen görevleri yerine getirir. Hasta ayrıca ana mobil uygulama ekranından bulunabilecek farklı hedefe yönelik görevleri de seçebilir. Uygulama tarafında, veriler bir iletişim ağı üzerinden IoT ile buluta aktarılır ve veri tabanında toplanır. Fizyoterapist, uygun görevleri belirlemek ve rehabilitasyondaki ilerlemeyi izlemek için bir mobil uygulama kullanır. Sisteme genel bakış ve 5 farklı alt görünüm Şekil 1'de gösterilmiştir. Bunlar EMG bağlantıları, mobil uygulama arayüzü, kontrolör, dış iskelet ve kuvvet sensörüdür.



Şekil 1. Sistem Görünümü

3.1 Görev Tanımı

Son dönemde yaşanan pandemi, rehabilitasyon sürecini önemli ölçüde etkilemektedir. Bunun nedeni, hastaların hareket kabiliyetinin olmaması ve hükümetler tarafından uygulanan kısıtlamalardır. Bu nedenle ev bazlı hedefe yönelik rehabilitasyon daha önemli hale gelmektedir. Bir fizyoterapist, bir hastayı ev ortamında günlük yaşam aktivitelerini gerçekleştirmesi için yönlendirebilir olmalıdır. Ancak, bu maliyetli bir süreç ve yeterli kaynak bulmak zordur. Geliştirilen sistemde, 4 farklı hareket türünden oluşan hedefe yönelik görevler ile terapi sürecini desteklemek amaçlanmıştır. Bunlar 1) aynı tarafa erişim, 2) zıt tarafa erişim, 3) uzak tarafa erişim ve 4) yakın tarafa erişimdir.

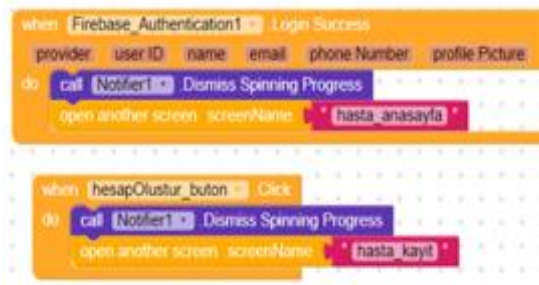
Dış iskelet, bilek ve triseps bölgesini kapsayacak şekilde giyilir. Yüzey EMG sensörleri, triseps kasına yerleştirilir. Mobil uygulama ile mikro denetleyici bağlantısı kurulur. Uygulamadan başla butonuna tıklanarak görev başlatılır. Ardından sistem EMG sinyallerinin seçilen görevi tetiklemesini bekler veya 3 saniye sonra başlar. Bu fizyoterapistin seçimine bağlıdır. Katılımcının kasından yeterli EMG sinyali alınırsa bu düğme etkinleştirilebilir. Veriler, IoT aracılığıyla buluta gönderilir. Fizyoterapist, hastaların

terapi esnasında ulaşmak istediği her veriyi getir butonuna basarak buluttan çekerek uygulamada görüntülemektedir.

3.2 Yazılım Tasarımı

Nesnelerin İnterneti (IoT) artık güvenilir bir teknolojik standart ve yoğun bir şekilde araştırılan bir alandır. Sensörler, günlük ürünlerden endüstriyel izleme sistemlerine kadar neredeyse her yerde kullanılmaktadır. IoT ve sensör tabanlı yoğun sağlık bakım sistemlerinin kullanımı hızla artmaktadır [9]. IoT hayatımızı daha akıllı, daha verimli ve daha kolay hale getirir. IoT, gelişen mobil cihazlar ve sensör ağları ile çeşitli fiziksel ve sanal nesnelere birbirine bağlayarak dinamik bir küresel ağ altyapısı oluşturmayı amaçlamaktadır. IoT, başlangıçta, RFID teknolojisi aracılığıyla, benzersiz bir şekilde tanımlanabilir nesnelere ve nesnelerin sanal temsillerini internet benzeri bir yapı içinde birleştirir.

Bu bildiride IoT, hastadan bir mobil uygulama yardımıyla bilgi alıp merkezdeki bir sunucuya aktaran ve böylece fizyoterapistin hastanın tedavi durumunu öğrenmesini sağlayan bir sistem olarak kullanılmayı amaçlamaktadır. PID kontrol, raspberry pi python programlama dili ile programlanmıştır. Hastalar ve fizyoterapistler için mobil uygulama ara yüzleri MIT App Inventor'da geliştirilmiş ve hayata geçirilmiştir. Ek olarak EMG sinyallerinde modül kart ile işlenir. Dış iskeletten gelen veriler bluetooth üzerinden hastanın mobil uygulamasına aktarılır. Mobil uygulamaya aktarılan tüm veriler, IoT yardımıyla firebase bulut ortamında toplanır. Ardından fizyoterapistin mobil uygulamasında görüntülenebilir. Şekil 2'de firebase kod bloğunun bir kısmı gösterilmektedir.



Şekil 2. Firebase Kod Bloğu

3.3 Donanım Tasarımı

Bu makale, raspberry pi kontrollü bir uzaktan izleme sistemini açıklamaktadır. Raspberry Pi, ARM11 mikroişlemcili, kredi kartı boyutunda tek kart bilgisayardır. Vücudumuzdaki sinirlerin ve kasların elektriksel aktiviteleri ölçülerek ve incelenerek çeşitli sinir ve kas hastalıkları ile ilgili bilgiler edinebilir ve teşhisler koyabiliriz

Bu çalışmada, EMG (Elektromiyografi) sinyalleri kullanılmakta ve diğer hayati parametreleri sürekli olarak izlemek için bir sistem tasarlanmıştır. Bu veriler bir bulutta saklanır ve sadece fizyoterapist tarafından erişilebilen bir bulutta görüntülenebilir [10]. Raspberry pi, linux tabanlı bir işletim sistemi olan raspbian ile kurulu olup, C, python vb. tüm programlama dillerini desteklemektedir. Kolay erişim için iletişim için Python programlama dili kullanılmaktadır. EMG modülü, kaslardan gelen sinyalleri işler ve seçilen görevi tetikler. EMG sinyallerinin işlenmesi ve en uygun yöntemin seçimi önemlidir.

EMG modülü, + 5V ve -5V voltajlarını gerektirir. Bu gerilim servo motoru beslemek için de gereklidir. Elektrotlardan gelen sinyaller, IC'de fark edilir ve güçlendirilir. Bu sinyaller daha sonra bir bant geçiren filtre yardımıyla karşılık gelen sinyallere aktarılır. Negatif kısımlar yarım dalga doğrultucu ile elimine edilir. İskelet kaslarının fonksiyonel temel birimi motor birimleridir. Tek bir motor ünitesinden uyarım


sonucunda, iğne elektrotlar vasıtasıyla hücre dışı potansiyel değişimleri 3 ile 5 ms arasında sürer ve genlikleri motor ünitenin büyüklüğüne bağlı olarak 20-2000 mv'dir. Ortaya çıkan sinyaller kontrolör eşiğini geçer geçmez servo motoru tetikler ve kolun istenen hareketi yapmasına olanak sağlar.

4 Biyomekanik Model ve Kontrolcü Tasarımı

Bu bölümde ilk olarak kontrolcü tasarımı için sistemin ve kolun matematiksel modeli türetilecektir. Daha sonra geliştirilen modele uygun kontrolcü tasarımı yapılacaktır.


4.1 Kolun Biyomekanik Model

x_1 , y_1 ve z_1 tanımları, omuz bölgesinde meydana gelen hareketleri anlatmak için kullanılmaktadır. Şekil 3'te gösterilen dirsekten bileğe (f) ve omuzdan dirseğe (u) kadar olan alanlarda bantlar bulunmaktadır. Dirsek açısı bir eksende θ_f olarak alınıp denklemde kullanılır.



Şekil 3: İnsan Kol Sistem Geometrisi

Şekil 3, iki parçadan oluşan insan kolu sisteminin geometrisini göstermektedir. Şekil 4, Şekil 3'te görünen kısıtlı insan kolu modelinin geometrisinin daha ayrıntılı bir tanımını sağlar. İlk bağlantı, omuz ekleminin dirseğe kadar olan üst kolu ($I_{u1} + I_{u2}$) uzunluk ile temsil eder. İkinci bağlantı, dirsekten bilek ağına kadar olan ön kolu ($I_{f1} + I_{f2}$) uzunluk ile temsil eder. Kısıtlama, ön kolün yatay düzlemde uzanması gerektiği ve üst kol boyunca eksen etrafında dönüşün mümkün olduğu anlamına gelir. Triseps kası tetikleme için seçilmiştir, çünkü inme hastaları tipik olarak ulaşma görevleri sırasında omuz ve dirsek ekstansiyonu ile ilgili sorun yaşamaktadır.




Şekil 4: Kısıtlanmış İnsan Kol Geometrisi

İnsan kolunun modellenmesi için dış iskeletin açısal eksenleri Şekil 5'de gösterilmiştir. Denklem 1'de J ve C sırasıyla atalet ve coriolis etkisidir. F_h ve G_h ise sırasıyla sürtünme ve yer çekimsel etkilerdir. Burada h_h dışarıdan uygulanan kuvveti temsil etmektedir [11].

$$J(\ddot{\phi}) + C(\dot{\phi}) + F_h(\dot{\phi}) + G_h(\phi) = g(\dot{\phi}) - h_h \quad (1)$$

Dış iskelet modeli ve kısıtlanmış insan kol modelindeki dirsek eklemi açısından fark nispeten kabul edilebilir ölçüde belirlenmiştir.



Şekil 4: Kısıtlanmış İnsan Kol Geometrisi

Şekil 5'de görüldüğü gibi omuz bölgesinde 3 eksenle hareket oluşacaktır ve bunlar ϕ_1, ϕ_2, ϕ_3 ile gösterilir. Dirsek bölgesinde hareket tek eksenle olacağı için ϕ_4 olarak gösterilmiştir.

4.1.1 PID Kontrolcü Tasarımı

PID kontrolörünün hata sinyali, kol gerçek zamanlı açısı ile hedef kol eklem açısı arasındaki farktır. Daha sonra üst ekstremiteler hareketi için kas aktivasyon dinamiklerine dayalı olarak kas aktivasyon seviyelerine aktarılan kontrol sinyali $u(t)$ 'yi hesaplamak için kullanılmıştır. Her bir zaman adımında, sinyal hatasını $e(t)$ en aza indirmek, yani simülasyon sonuçları ve deneysel veriler arasındaki kol eklemi açısı farkını en aza indirmek için kas aktivasyon seviyesi PID kontrolörü tarafından tekrarlanabilir olarak ayarlanmıştır. PID denetleyicisi için formül aşağıda denklem (2) ve denklem (3) deki gibidir:

$$e(t) = D(t) - y(t) \quad (2)$$


$$u(t) = k_p * y_d(t) + k_i * \int_0^t y_d(\tau) d\tau + k_d \frac{dy_d(t)}{dt} \quad (3)$$

Denklem (2) de $e(t)$ hata sinyali olduğunda kol eklem açısı, $y_d(t)$ sinirsel gecikmeden sonraki gerçek zamanlı kol eklem açısıdır, k_p, k_i and k_d , PID kontrolörünün oransal, integral ve türev kazançlarıdır [12].

Üst ekstremiteler için kullanılan dış iskelet, bazen rehabilitasyona yardımcı olmak için çoklu serbestlik derecesi admintans kontrollü cihazlarda uygulanmaktadır [13]. Düşük atalet ve göreve bağlı sertlik oluşturma, kullanıcının dış iskelet ile hareket etmesine yardımcı olmaktadır [14]. Cihazın hareket kontrollü yapısı sayesinde, admintans kontrolü ile saf hareket kontrolü arasında sorunsuz bir şekilde


geçiş yapabilmektedir [15]. Bu, uygulamalı pozisyon bozulmaları, insan sinir-kas-iskelet sistemi dinamiklerinin tanımlanması ve otomatik, reaktif ve işbirlikçi görevler arasında geçiş yapmak için admintans kontrolü ön plana çıkarmaktadır [16].

Şekil 5’de C olarak gösterilen blok PID kontrolörü temsil etmektedir. Seçilen kazanç değerleri sırasıyla oransal, integral ve türev $k_p = 0,6$, $k_i = 3$, $k_d = 0.02$ olarak belirlenmiştir. P olarak gösterilen blok kontrol edilen sistemi temsil etmektedir. PID kontrolördeki hata sinyali (e), kolun gerçek zamanlı açısı ile hedef kol eklem açısı arasındaki farktır. Şekil 5’de PID kontrol blok diyagramı gösterilmektedir.



Şekil 5. PID Blok Diyagramı

Şekil 6’da servo motora herhangi bir kontrolcü uygulamadan, kendi içinde bulunan kontrolcü sayesinde verilen sinüs dalga referans sinyali takip ettiği grafik görülmektedir. Burada oluşan hata (e) gözle görülür düzeydedir. Hata özellikle dip ve tepe noktalarda (30° ve 120°) daha fazla olduğu gözlemlenmektedir. Bu oluşan hataların normunu almak gerekirse 4 periyotta ortalama 3.812 olarak hesaplanmıştır. Bu hatanın iyileştirilmesi için PID kontrolcü uygulanacak ve hatanın minimize edilmiş hali seçilip çalışmada kullanılacaktır.




Şekil 6. Kontrolsüz Giriş-Çıkış Sinyal Grafiği (Grafiğin dikey eksenini açı derecesi, yatay eksenini örnekleme miktarını göstermektedir. Kırmızı çizgi sinüs referans dalgasını, mavi çizgi sistemin konumunu göstermektedir.)

Şekil 7’de servo motora PID kontrolcü uygulanarak verilen sinüs dalga referans sinyalini takip ettiği grafik görülmektedir. Oransal, integral, türev kazançları sırasıyla $k_p = 0,6$, $k_i = 3$, $k_d = 0.02$ olarak belirlenmiştir. Her sinüs dalgasının bir periyodu 100 örneklemeden oluşmaktadır. Grafikte görüldüğü

üzere kırmızı referans sinyali takip eden ve motor konumunu temsil eden mavi çizgi yaklaşık 14. örneklemede referans çizgisine oturmaktadır. Kullanılan servo motorun hassasiyeti ve torku az olması nedeniyle, sistem bozucu etkilere maruz kaldığında parazit şeklinde bozulmalar meydana gelmektedir.

Bu oluşan hataların normunu aldığımızda yaklaşık 1,755 olarak hesaplanmıştır.



Şekil 7 : PID Kontrollü Giriş-Çıkış Sinyal Grafiği (Grafiğin dikey eksenini açı derecesi, yatay eksenini örnekleme miktarını göstermektedir). Kırmızı çizgi sinüs referans dalgasını, mavi çizgi sistemin konumunu göstermektedir.)

Servo motora herhangi bir kontrolcü uygulamadan ve PID kontrolör uygulanması sonucunda elde edilen hataların normuna bakarak; PID kontrolör ile daha az hata olduğu görüldüğünden seçimimiz bu kontrolcüdür.

5 Sonuç

Doktorların veya diğer sağlık görevlilerinin hastayı kronik olarak devam eden hastalıklar açısından en iyi şekilde izleyebileceği ortamlar hastanın doğal yaşamıdır. Bu nedenle hastaları doğal yaşamlarında takip edebilmek için çeşitli taşınabilir izleme cihazlarına ihtiyaç duyulmaktadır. Bu cihazlar ilgili sağlık hizmetindeki hastalardan verileri sunucularına göndererek alır, o kişi adına çeşitli kararları sağlıkta gelecek için daha verimli vermelerini sağlayabilir.

Bu çalışmada, EMG sinyallerinin ve diğer sağlık parametrelerinin sorunsuz bir şekilde izlenmesini garanti eden, otomatik bir şekilde çalışan yeni bir yaklaşım sunulmaktadır. Gerçekleştirilen sistem, hastanın hayatı sinyallerini izlemek için sağlık sistemi için bir prototip olabilir.

Ayrıca bu sistem tüm eve kolayca kurulabilir ve elde edilen devasa veriler veri tabanında saklanabilmektedir. Sonuçlar bir uygulama aracılığıyla cep telefonundan veri tabanına aktararak hastanelerdeki hastaların yoğunluğu azaltılacaktır. Kullanılan kuvvet sensörü, kolu etkileyebilecek aşırı yüklenmelerden kolu korumaktadır.

Servo motorun amacı istenilen kol pozisyonu için motor pozisyonunun kontrol edilmesini kolaylaştırmaktır. Küçük servo motor kullanmanın avantajı daha hafif olmasıdır. Dezavantajı ise motor seçiminin küçük olması ve hareket noktasının potansiyel deformasyonu aşması, bu diğer ev tabanlı cihazlardan farklı olarak bir kompozit veya başka bir malzeme ile değiştirilebilir. Cihazlar arası iletişimi nesnelerin interneti (IoT) üzerinden yapılır ve tasarlanan android uygulaması ile eğitim verileri bulut üzerinden fizyoterapistlere iletilmektedir.

Gelecekte, ev ortamlarından rehabilitasyonun performans testlerine odaklanılmalıdır. Gelecekteki bir başka çalışma, sistemin özerkliğini geliştirmek için büyük veri ve makine öğreniminden yararlanmak hedeflenmektedir.

Muhtemel zorluklar hazır alınan elektronik elemanların kurdaki dalgalanma sonucu tahmin edilen üretim maliyetini aşmasıdır. Planlama dışındaki gelişmeler için B planı olarak ek bütçe ve gerekli durumlarda alternatif elektronik eleman tercihi yapmak planlanmaktadır.

Sonuç olarak, bu makale kapsamında; düşük maliyetli, taşınabilir ve hafif olarak ev tipi dirsek rehabilitasyon cihaz prototipi tasarlanmıştır. Bu cihaz dirsek egzersizlerini yapabilir ve rehabilitasyonda kullanılabilir. Cihazın sinir sıkışması, sinir hasarı, tendon hasarı ve spor yaralanmaları gibi durumların tedavisinde de kullanılabilmesi ön görülmektedir. Cihaz sayesinde aktif egzersizler yapılabilmektedir. Ancak cihaz için tasarlanan PID kontrolcünün konum hata değerlerinin normu $1,755^\circ$ olmakta birlikte, fizyoterapistler tarafından rehabilitasyon sürecindeki ilerlemenin izlenmesini gerek kılmaktadır. Bu makalede uzmanlar tarafından, hasta kullanıcı durumunun izlenmesinde IoT haberleşme ile kesintisiz olarak gerçekleştirilmektedir. Tüm bu durumlar karşılandığında en büyük beklenti ise geliştirilen prototipin piyasaya sürülerek hastalar tarafından kullanıma sunulmasıdır. Bu nedenle tasarımı ve üretimi ülkemize ait olan aktif aktüatörlü ilk taşınabilir ev tipi dirsek rehabilitasyon cihazı olarak piyasada yerini almış olacaktır.

6. Beyanname

6.1 Çalışma Sınırlamaları

Yazarlar, bu çalışmada araştırma sonucunu önemli ölçüde etkileyebilecek herhangi bir sınırlama ile karşılaşmadığını beyan eder.

6.2 Teşekkür

Yazarlar, bu çalışmanın kalitesini artıran yapıcı öneriler için anonim hakemlere teşekkürlerini sunar.

6.3 Yazar Katkıları

Mert Süleyman DEMİRSOY: Deneylerin yapılması, bilimsel yayın araştırması, makalenin oluşturulması, verilerin ve grafiklerin yorumlanması, bilgisayar ortamına aktarılması ve sistemin cad çizimleri ile montaj aşamasında görev alma.

Mustafa Çağrı KUTLU: Çalışma için fikir geliştirme, sonuçlara ulaşma yöntemlerini planlama ve çalışmanın oluşturulmasında sorumluluk alma, cihazda kullanılacak malzemelerin fizibilite açısından değerlendirmesi ve tedarik sürecinde görev alma.

Mohammed MANSOUR: Cihazdan elde edilen verilerin istatistiklerinin oluşturulması ve cihazın fizibilite araştırmasının yapılması.

Kaynakça

[1].Birinci, Ş. (2019). SAĞLIK İSTATİSTİK YILLIĞI. Sağlık Bakanlığı. doi:10.1080/09505438809526230

[2] M. Yıldız, “İnme Rehabilitasyonu İçin Giyilebilir Ev Bazlı Üst Ekstremitte Fonksiyonel Elektrik Stimülatörünün Geliştirilmesi.” online on 11 February 2022 at <https://acikbilim.yok.gov.tr/handle/20.500.12812/222163>

- [3] S. J. Ball, I. E. Brown, and H. Stephen H. Scott. "MEDARM: A Rehabilitation Robot with 5DOF at the Shoulder Complex." *IEEE/ASME International Conference on Advanced Intelligent*
- [4] T. Ripel, J. Krejsa, J. Hrbacek, & I. Cizmar, "Active elbow orthosis". *International Journal of Advanced Robotic Systems*, vol. 11, no. 9, pp. 143.
- [5] S. Crea, M. Cempini, S. Mazzoleni, M. C. Carrozza, F. Posteraro, & N. Vitiello, "Phase-II clinical validation of a powered exoskeleton for the treatment of elbow spasticity", *Frontiers in neuroscience*, vol. 11, pp. 261.
- [6] I. Vanderniepen, R. Van Ham, Orthopaedic rehabilitation: A powered elbow orthosis using compliant actuation. In *2009 IEEE International Conference on Rehabilitation Robotics* (pp. 172-177). IEEE.
- [7] L. B. Kyu "Development of Dynamic Model-Based Controller for Upper Limb Exoskeleton Robot." *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 3173-3178.
- [8] S. Zhibin, "Implementation of Resistance Training Using an Upper-Limb Exoskeleton Rehabilitation Device for Elbow Joint." *Journal of Medical and Biological Engineering* vol. 34, no. 2, pp. 188-96.
- [9] S. Islam, M. R., Kwak, D., Kabir, M. H., Hossain, M. ve K. S. Kwak, "The internet of things for health care: A comprehensive survey". *IEEE Access*, 3, pp. 678-708. doi:10.1109/ACCESS.2015.2437951
- [10] C. T. Freeman, A. M., Hughes, J. H., Burridge, P. H., Chappell, P. L. Lewin, E. Rogers, "Iterative learning control of FES applied to the upper extremity for rehabilitation. *Control Engineering Practice*, vol. 17, no. 3, pp. 368-381. doi:10.1016/J.CONENGPRAC.
- [11] M. Kutlu, C. Freeman, "A Home-Based Functional Electrical Stimulation System for Upper-Limb Stroke Rehabilitation."
- [12] S. Andersson, Active Muscle Control in Human Body Model Simulations - Implementation of a feedback control algorithm with standard keywords in LS-DYNA. 27 Şubat 2022 tarihinde <https://odr.chalmers.se/handle/20.500.12380/182123> adresinden erişildi.
- [13] A. Keemink, Q. L. van der Kooij, H. ve A. H. A. Stienen, "Admittance control for physical human-robot interaction" <https://doi.org/10.1177/0278364918768950>, vol. 37, pp. 11, pp. 1421-1444. doi:10.1177/0278364918768950
- [14] M. G. Carmichael, ve D. Liu, "Admittance control scheme for implementing model-based assistance- as-needed on a robot" *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 870-873. doi:10.1109/EMBC.2013.6609639
- [15] A. H. A. Stienenw, E. E. G. Hekman, H. Braak, A. M. M. Aalsma, F. C. T. Van Der Helm, ve H. Van Der Kooij, "Design of a rotational hydroelastic actuator for a powered exoskeleton for upper limb rehabilitation". *IEEE Transactions on Biomedical Engineering*, vol. 57, no. 3, pp. 728-735. doi:10.1109/TBME.2009.2018628
- [16] A. H. A. Stienen, J. G. McPherson, A. C. Schouten, ve J. P. A. Dewald, "The ACT-4D: A novel rehabilitation robot for the quantification of upper limb motor impairments following brain injury". *IEEE International Conference on Rehabilitation Robotics*. doi:10.1109/ICORR.2011.5975460



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Yapay Sinir Ağları ile Hava Durumu Tahmini ve Çok Katmanlı Ağ Modeli için LabVIEW Arayüz Tasarımı

Serdar ÖZKAYA* , Gökhan ATALI² 

¹ Mekatronik Mühendisliği Bölümü, Lisansüstü Eğitim Enstitüsü, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye. y195010056@subu.edu.tr

² Mekatronik Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye. gatali@subu.edu.tr

ÖZ

Yapay sinir ağları (YSA), insanın biyolojik sinir hücrelerinin çalışmasının taklit edilmesi sonucunda tahmin, sınıflandırma, optimizasyon, sinyal işleme, doğrusal olmayan sistemlerin modellenmesi gibi birçok alanda karşımıza çıkan problemlere çözüm üreten bir yöntemdir. YSA'nın tarihsel gelişiminde önce tek katmanlı algılayıcılar kullanılarak sadece doğrusal problemlere çözüm getirilmiştir. Doğrusal olmayan problemlerin çözümü için çok katmanlı algılayıcı (ÇKA) ağ modelleri geliştirilmiştir. Bir YSA'nın eğitiminde girdi ve çıktı değerlerinin birlikte verilmesi ile gerçekleşen öğrenme metodu gözetimli öğrenme metodu şeklinde adlandırılır. YSA'nın ÇKA modelinde gözetimli öğrenme metodu kullanılmaktadır. Bu çalışmada; doğrusal olmayan problemlerin çözümü için YSA'nın geri yayımlı ÇKA modeli kullanılarak LabVIEW ortamında bir ara yüz tasarlanmıştır. Gerçekleştirilen tasarım ile hava durumu tahmin problemine çözüm getirilmiştir. Tasarımda katmanlardaki nöron sayısı, öğrenme katsayısı, momentum katsayısı, iterasyon sayısı, başlangıç ağırlıkları gibi parametreler değiştirilerek ağın eğitilmesi sağlanmıştır ve test edilerek ağın performans ölçümü gerçekleştirilmiştir. Yapılan test işleminin sonucunda test verilerinin beklenen çıktı değerleri ile YSA'nın ürettiği değerler karşılaştırıldığında başarılı bir sonuç elde edilmiştir. Çalışmada Konya iline ait 45 günlük nem oranı (%), görüş mesafesi (km), basınç (mb), çığ noktası (°C), sıcaklık (°C) bilgilerini içeren bir veri seti kullanılmıştır.

Anahtar Kelimeler: Yapay Sinir Ağları, Çok Katmanlı Ağ, LabVIEW, Genelleştirilmiş Delta Öğrenme Metodu, Hava Tahmini

* Sorumlu yazarın e-posta adresi: y195010056@subu.edu.tr

Weather Forecasting with Artificial Neural Networks and LabVIEW Interface Design for Multi-Layer Network Model

ABSTRACT

Artificial neural networks (ANN) are a method that produces solutions to many problems by imitating the work of human biological nerve cells, problems such as prediction, classification, optimization, signal processing, and modeling of nonlinear systems. In the early stages of the historical development of ANN, only linear problems were solved by using single-layer perceptrons. Multilayer perceptron models have been developed to solve nonlinear problems. In the training of an ANN, the learning method that takes place by giving the input and output values together is called the supervised learning method. In the multilayer network model, the supervised learning method is used. In this study, for the solution of nonlinear problems, an interface is designed in the LabVIEW environment by using the Back Propagation model from ANN. With the emerging design, the weather forecast problem has been solved. By changing the parameters such as the number of neurons in the layers, the learning coefficient, the momentum coefficient, the number of iterations, and the initial weights, the network is trained, and the performance of the network is measured by testing it. As a result of the test process, a successful result was obtained by comparing the expected output values of the test data with the values produced by ANN. In the study, a dataset containing 45 daily humidity (%), visibility distance (km), pressure (mb), dew point (°C), and temperature (°C) information of Konya province was used

Keywords: Artificial Neural Networks (ANN), Multilayer Networks, LabVIEW, Generalized Delta Learning Method, Prediction Weather Forecasting

1 Giriş

İnsanlar genel olarak gördükleri ve yaşadıkları olaylar karşısında davranışlarında değişimler göstererek öğrenme işlemini gerçekleştirirler. Yaşadıkları her gün yeni tecrübeler elde ederler. Makine öğrenimi ile insanların tecrübelerini kullanarak doğru davranış gösterme özellikleri, makinelere kazandırılmak istenmektedir.

Makine öğreniminde yaygın olarak kullanılan yöntemlerden biri yapay sinir ağlarıdır. YSA matematiksel olarak net çözüm getirilemeyen yani doğrusal olmayan problemlerde yaygın olarak kullanılmaktadır. YSA; tıp, mühendislik, uzay, üretim, ekonomi gibi birçok alanda görüntü ve sinyal işleme, tahmin, optimizasyon, sınıflandırma gibi farklı uygulamalarla kullanılmaktadır.

Bu konu hakkında literatür incelendiğinde; Bukhari ve arkadaşları çalışmalarında diyabet hastalığını etkili bir şekilde tahmin etmek için yirmi gizli katmandan oluşan bir yapay sinir ağı modeli geliştirmişlerdir [1]. Jiang ve Gao yapmış oldukları çalışmada yüksek hızlı tren ray profillerinin aşınımını azaltmak amacıyla tasarımlarında optimizasyon sağlamak için genetik algoritma ile bağlantılı yapay sinir ağı modeli oluşturmuşlardır [2]. Majoros ve arkadaşları PhysioNet üzerinden açık erişimli EEG (elektroensefalografi) veri setini kullanarak bir yapay sinir ağı modeli oluşturmuşlar ve bu sinyalleri deneklerin hayallerinde canlandırdıkları davranış biçimlerine göre sınıflandırmışlardır [3]. Thakur ve arkadaşları yapmış oldukları bir çalışmada Hindistan'ın Ocak 2000 ile Aralık 2012 arasındaki tarihsel aylık ekonomik verilerini analiz ederek enflasyon tahmini için geri yayımlı bir yapay sinir ağı modeli oluşturmuşlardır [4]. Atalı ve arkadaşları çalışmalarında tahribat işlemi uyguladıkları görüntüleri ve orijinal hallerini bir takım görüntü işleme teknikleri uygulayarak eğitim ve test verisi şeklinde bir yapay sinir ağına vermişlerdir. Tahribatın derecesine göre ağın ürettiği çıktıları ve başarı düzeylerini karşılaştırmışlardır [5]. Akyüz ve arkadaşları çalışmalarında Antalya'ya ait 2000-2016 yılları arasında

ölçülen gerçek aylık ortalama buhar basıncı, aylık ortalama nisbi nem, ilgili ay ve yıl verilerini kullanarak geri beslemeli bir yapay sinir ağı modeli ile ortalama hava sıcaklığını %99 başarı oranıyla tahmin etmişlerdir [6]. Güç yapmış olduğu yüksek lisan tez çalışmasında Bilecik ilinin 2013 yılına ait saatlik ortalama rüzgar şiddeti, hava basıncı, su buharı basıncı, nispi nem ve hava sıcaklığı değerlerini barındıran 1794 adet veriyi tasarladığı YSA modelinde kullanarak %91 başarı oranı ile hava sıcaklığı tahmini yapmıştır. Verilerin %80'lik kısmını eğitim aşamasında kullanmıştır [7]. Yavuz ve arkadaşı çalışmalarında 1990 ile 2011 yılları arasındaki Meteoroloji Genel Müdürlüğünden Adana ilinin günlük hava durumu verileri alınarak elde edilen veri seti üzerinde çeşitli normalizasyon tekniklerini Matlab programı üzerinde tasarlanan bir yapay sinir ağı üzerinde kullanarak Ortalama Mutlak Yüzde Hata (MAPE, Mean Absolute Percentage Error) ve Hata Kareler Ortalaması (MSE, Mean Square Error) istatistiği yardımıyla değerlendirerek karşılaştırmışlardır [8]. Aydın ve arkadaşı çalışmalarında yerel saat zamanı ile her 15 dakika da Avrupa için uydu görüntüsü veren Eumetsat verilerinden elde edilen Kasım 2012'ye ait günlük 96 toplamda ise 2880 kızılötesi uydu görüntülerini dalgacık dönüşümü ve temel bileşenler analizi yöntemlerinden geçirerek yapay sinir ağı ve destek vektör makineleri algoritmaları ile sınıflandırmaya tabi tutmuşlardır. Yapay sinir ağı ile sınıflandırma sonucunda %84 ve destek vektör makineleri ile sınıflandırma sonucunda %93 oranında başarı elde etmişlerdir [9].

Bu çalışmada LabVIEW programı kullanılarak tahmin ve sınıflandırma problemlerinin uygulanabileceği görsel bir yazılım geliştirilmiştir. Yazılımda ÇKA modeli, Genelleştirilmiş Delta Algoritması (Geri Yayılım Algoritması) kullanılarak tasarlanmıştır. Yazılımda ağın yapısı, katmanlardaki nöron sayısı, öğrenme oranı, momentum katsayısı, iterasyon sayısı, tolerans miktarı, başlangıç ağırlıklarının seçimi kullanıcı tarafından belirlenmiştir. Eğitim esnasında oluşan hatanın grafiği gözlemlenmiştir ve test işleminden sonra ağın performansı ölçülerek beklenen değerler ile ağın ürettiği değerler karşılaştırılmıştır.

2 Yöntem ve Metot

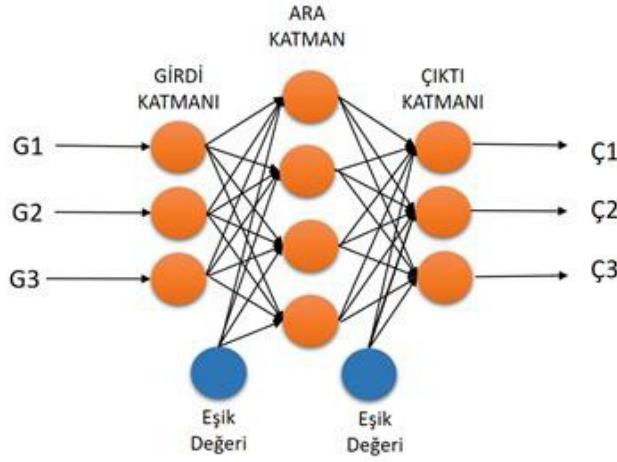
2.1 Yapay Sinir Ağları

YSA, insanın öğrenme özelliğinin taklit edilerek yeni bilgiler üretebilen, yeni bilgiler türetebilen, keşfedilme gibi yeteneklere sahip ve tüm bunları tek başına gerçekleştirebilen bilgisayar sistemleridir [10]. Paralel çalışma yapısına sahip basit işlemler gerçekleştiren bir işlemcidir ve deneyim ile elde edilmiş bilgiyi depolayan ve kullanılabilir kılmak için nöronlar arası bağlantı ağırlıklarını sürekli yineleyerek öğrenmeyi gerçekleştiren bir yapıdır [11]. Nöronlar arasında bulunan bağlantı ağırlıklarının sayısal bir değeri vardır ve bu değer bir nöronun girişinin gücünü veya önemini ifade eder. Bu ağırlıklar YSA da uzun süreli belleğin temel birimini oluşturmaktadır. Bir sinir ağı bu ağırlıkların değerini, sürekli olarak yineleyerek öğrenme işlemini gerçekleştirir. Bir YSA oluşturmak için ağda kullanılacak nöron sayısına, nöronlar arası bağlantıların nasıl olacağına yani ağın yapısına, hangi öğrenme algoritmasının kullanılacağına karar verilmesi gerekmektedir. Son olarak ağın eğitimi için ilk bağlantı ağırlıkları belirlenir ve ağın eğitimi başlatılır [12].

Bu çalışmada Konya ilinin 15 Haziran 2017 ve 29 Ağustos 2017 tarihleri arasındaki 45 günlük hava durumu verileri kullanılmıştır. Veri seti 15 günlük hava durumu verilerini içeren bir internet sitesinden alınan bilgilerle hazırlanmıştır [13]. Girdi verileri Nem Oranı (%), Görüş Mesafesi (km), Basınç (mb), Çiğ Noktası (°C) başlığı altında 4 adet öznitelik değerlerinden ve çıktı verileri Sıcaklık (°C) başlığı altında 1 adet öznitelik değerlerinden oluşmaktadır.

2.2 Çok Katmanlı Algılayıcılar

YSA'nın girdi ve çıktıları arasındaki ilişkilerin doğrusal olmadığı durumlarda kullanılan ÇKA, bilgi girişinin yapıldığı girdi katmanı, bir veya birden fazla ara (gizli) katman ve bir çıktı katmanından oluşmaktadır [14]. Şekil 1'de ÇKA modelinin yapısı gösterilmiştir.



Şekil 1: ÇKA modelinin yapısı

Girdi katmanında herhangi bir bilgi işleme olmaz. Gelen bilgiler olduğu gibi bir sonraki katmana aktarılır. Giriş ve çıkış katmanlardaki nöron sayısı problemin doğasına göre belirlenirken, gizli katmandaki nöron sayısı için herhangi bir yöntem bulunmamaktadır. Bu yüzden deneme yanılma yoluyla belirlenmektedir [15]. Her nöronun bir girdisi ve bir çıktısı vardır. Çıktılar bir sonraki katmanda bütün nöronlara gönderilir. Ara katmanda girdi katmanından gelen bilgiler işlenerek çıktı katmanına iletilir. Ara katmandaki nöronlar çıktı katmanındaki bütün nöronlar ile bağlantılıdır. Çıktı katmanı ara katmandan gelen bilgileri işleyerek ağıın girdi katmanından verilen girdilere karşılık ağıın ürettiği çıktıları dış dünyaya gönderir.

2.3 ÇKA Modelinin Öğrenme Metodu

ÇKA gözetimli öğrenme stratejisine göre çalışır. Yani ağıın eğitiminde hem girdiler hem de o girdilere karşılık gelen çıktılar birlikte verilir ve ağıın ürettiği çıktı değerleri ile doğru sonuçlar karşılaştırılarak yeni ağırlık değerleri belirlenir [16]. ÇKA modelinin öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş halidir. Genelleştirilmiş Delta Kuralında öğrenme ileri ve geri hesaplama olmak üzere iki aşamada gerçekleşir. İleri hesaplamada ağıın çıktısı hesaplanır. Geri hesaplamada ise ağıın ağırlık değerleri değiştirilir.

İleri hesaplama safhasında bilgi işleme, eğitim setindeki bir örneğin girdi katmanından ağa verilmesiyle başlar. Daha öncede belirtildiği gibi girdi katmanında herhangi bir bilgi işleme olmaz. Gelen girdi olduğu gibi ara katmana gönderilir. Girdi katmanındaki bir proses elemanın çıktısı ζ_k^i Denklem 1'de gösterildiği gibi hesaplanır.

$$\zeta_k^i = G_k \quad (1)$$

Burada G_k girdi katmanındaki k. proses elemanın girdi değerini göstermektedir. Ara katmanındaki bir proses elemanın net girdisi NET_j^a Denklem 2'de gösterildiği gibi hesaplanır.

$$NET_j^a = \sum_{k=1}^a A_{kj} \zeta_k^i \quad (2)$$

Burada A_{kj} k. girdi katmanı proses elemanını j. ara katmanı proses elemanına bağlayan bağlantının ağırlık değerini göstermektedir. Ara katmandaki bir proses elemanın çıktısı gelen net girdinin bir aktivasyon fonksiyonundan geçirilmesi ile hesaplanır. Aktivasyon fonksiyonunun sigmoid seçilmesi durumunda j. ara katman proses elemanının çıktısı ζ_j^a Denklem 3'te gösterildiği gibi hesaplanmaktadır.

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (3)$$

Burada β_j^a j. ara katman proses elemanına bağlanan eşik değerinin ağırlık değerini göstermektedir. Çıktı katman proses elemanlarının çıktı değerleri, ara katman proses elemanlarında olduğu gibi önce net girdi değerlerinin hesaplanması ve bir aktivasyon fonksiyonundan geçirilmesi elde edilir. Çıktı katmanının çıktı değerlerinin bulunması ile ileri hesaplama safhası tamamlanmış olur.

Geri hesaplama safhasında amaç; ağırlık çıktı değerleri ile olması gereken değerlerin farkı alınarak elde edilen hata değerlerini, bağlantı ağırlıklarına yayarak azaltmaktır. Çıktı katmanındaki m. proses elemanının hata değeri E_m Denklem 4'te gösterildiği gibi hesaplanır.

$$E_m = B_m - \zeta_m \quad (4)$$

Burada ζ_m m. proses elemanının çıktı değerini, B_m ise olması gereken değerini ifade etmektedir. Çıktı katmanındaki Toplam Hata (TH) değeri ise Denklem 5'te gösterildiği gibi hesaplanır.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (5)$$

Toplam hatayı en aza indirmek için yapılan ağırlık değişiminde iki durum söz konusudur. Bunlar;

- Ara katman ile çıktı katman arasındaki ağırlıkların değiştirilmesi
- Ara katmanlar arası veya ara katman ile girdi katman arasındaki ağırlıkların değiştirilmesidir.

Ara katman ile çıktı katman arasındaki ağırlıkların değiştirilmesi için öncelikle değişim miktarının hesaplanması gerekir. Ara katmandaki j. proses elemanı ile çıktı katmanındaki m. proses elemanı arasındaki bağlantının ağırlığındaki değişim miktarı ΔA_{jm}^a 'in t. iterasyondaki değeri Denklem 6'da gösterildiği hesaplanır.

$$\Delta A_{jm}^a(t) = \sigma \delta_m \zeta_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (6)$$

Burada σ öğrenme katsayısını, α ise moment sayısını göstermektedir. δ_m ise aktivasyon fonksiyonun türevi ile m. çıktı değerine ait hata miktarının çarpımıyla elde edilir. δ_m değerinin hesaplanmasında Denklem 7'de sunulan formül kullanılmaktadır.

$$\delta_m = f'(NET) E_m \quad (7)$$

Burada aktivasyon fonksiyonu olarak sigmoid fonksiyonunun kullanılması durumunda δ_m değerine ait formül Denklem 8'de gösterilen hali alacaktır.

$$\delta_m = \zeta_m(1 - \zeta_m)E_m \quad (8)$$

Bu durumda ara katman ile çıktı katman arasındaki ağırlıkların t . iterasyondaki değeri $A_{jm}^a(t)$ Denklem 9'da gösterildiği gibi hesaplanır.

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (9)$$

Eşik değeri bağlantı ağırlığının da benzer şekilde değiştirilmesi gerekir. Eşik değeri ile ilgili işlemler ağı yapısında eşik değeri kullanılıyorsa yapılmalıdır. Ara katman ile çıktı katman arası eşik değerinin bağlantı ağırlığındaki değişim miktarı $\Delta\beta_m^c$ t . iterasyondaki değeri Denklem 10'da gösterildiği gibi hesaplanır.

$$\Delta\beta_m^c(t) = \sigma\delta_m + \alpha\Delta\beta_m^c(t-1) \quad (10)$$

Ara katman çıktı katman arası eşik değeri bağlantı ağırlığının t . iterasyondaki yeni değeri Denklem 11'de gösterildiği gibidir.

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (11)$$

Ara katmanlar arası veya ara katman ile girdi katman arasındaki ağırlıkların değişim miktarı da benzer şekilde Denklem 12'de gösterildiği gibi hesaplanmaktadır.

$$\Delta A_{kj}^i(t) = \sigma\delta_j^a\zeta_k^i + \alpha\Delta A_{kj}^i(t-1) \quad (12)$$

Buradaki hata terimi δ_j^a aktivasyon fonksiyonunun sigmoid fonksiyonu seçilmesi durumunda Denklem 13'te gösterildiği gibi hesaplanmaktadır.

$$\delta_j^a = \zeta_j^a(1 - \zeta_j^a)\sum_m \delta_m A_{jm}^a \quad (13)$$

Bu durumda ağırlıkların t . iterasyondaki yeni değeri Denklem 14'te gösterildiği gibi hesaplanır.

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (14)$$

Ara katmanlar arası veya girdi katman ara katman arası eşik değeri bağlantı ağırlığı değişiminin de gerçekleşmesi gerekmektedir. Eşik değeri bağlantı ağırlığının değişim miktarı β_j^a t . iterasyondaki değeri Denklem 15'te gösterildiği gibi hesaplanır.

$$\Delta\beta_j^a(t) = \sigma\delta_j^a + \alpha\Delta\beta_j^a(t-1) \quad (15)$$

Eşik değeri bağlantı ağırlığının t . iterasyondaki yeni değeri Denklem 16'da gösterildiği gibi hesaplanır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta\beta_j^a(t) \quad (16)$$

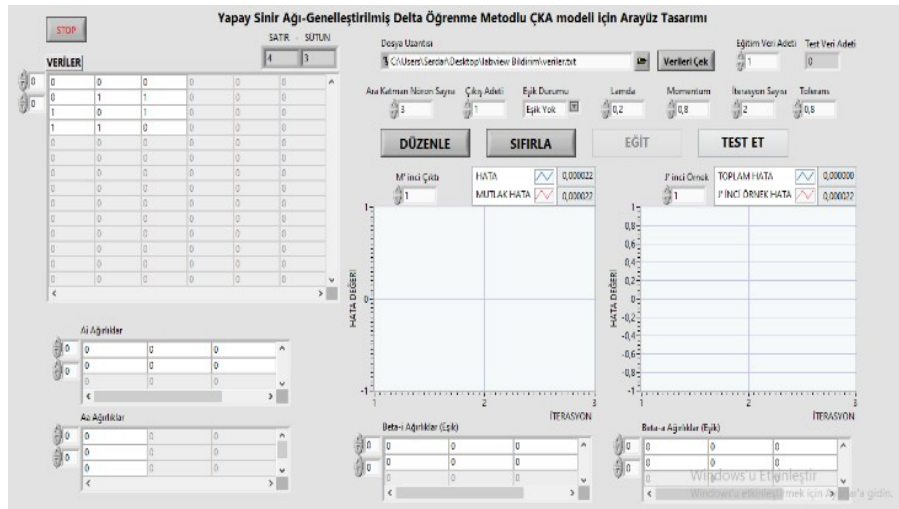
Ağırlık değerlerinin değiştirilmesi ile bir iterasyondaki ileri ve geri hesaplama aşamaları tamamlanmış olur. İkinci bir örnek verilmesiyle sonraki iterasyon başlar ve aynı işlemler öğrenme işlemi gerçekleşinceye kadar tekrarlanır.

3 Bulgular ve Tartışma

Bu çalışmada Konya iline ait 15 Haziran 2017 ve 29 Temmuz 2017 tarihleri arasındaki nem oranı (%), görüş mesafesi (km), basınç (mb), çiğ noktası ($^{\circ}\text{C}$), sıcaklık ($^{\circ}\text{C}$) bilgilerini içeren bir veri seti kullanılarak LabVIEW ortamında tasarlanan bir ara yüz ile geleceğe yönelik hava tahmini uygulaması gerçekleştirilmiştir.


3.1 LabVIEW Kullanıcı Arayüz Tasarımı

Grafiksel gösterimle yazılım yapılan LabVIEW programında öncelikli olarak Front panel üzerine konumlandırılan bilgilerin boyutlandırılmasına ve görünümüne dikkat edilmiştir. Tasarlanan ara yüz Şekil 2’de gösterilmiştir.



Şekil 2: LabVIEW yazılımı front panel görünümü

Tasarlanan ara yüzün dosya uzantısı kısmında YSA’ya verilecek eğitim ve test verilerinin hangi dosyadan yükleneceği seçilmektedir. Yüklenen veri setinde girdi ve çıktı değerleri birlikte olmalıdır. Veri seti aynı zamanda eğitim ve test verilerinin ikisini birden kapsamalıdır. Dosya uzantısının yanında yer alan “Eğitim Veri Adeti” kısmında, yüklenen veri setinin ilk kaç satırının eğitim verisi şeklinde kullanılacağı seçilmektedir. Girilen değerın altında kalan satırlar otomatik olarak test verisi şeklinde kabul edilecektir.



Şekil 3: YSA parametreler

YSA’nın öğrenme ve topolojik yapısını belirleyen parametreleri Şekil 3’te gösterilmiştir. “Ara Katman Nöron Sayısı”, “Çıkış Adeti”, “Eşik Durumu” gibi değerler ağın topolojik yapısını belirlemektedir. “Lamda”, “Momentum”, “İterasyon Sayısı”, “Tolerans” gibi değerler ağın öğrenme parametreleridir. “Ara Katman Nöron Sayısı” kısmında ağın gizli katmanında kaç adet proses elemanın kullanıldığı girilmektedir. “Çıkış Adeti” kısmında ağın kaç adet çıktısı olduğu girilmektedir. Ağda eşik değeri kullanılıp kullanılmaması durumu “Eşik Durumu” kısmından belirtilmektedir. “Lamda” kısmında ağın öğrenme katsayısı, “Momentum” kısmında ise momentum katsayısı girilmektedir. Ağın öğrenme işleminin kaç iterasyonda gerçekleşeceği “İterasyon Sayısı” kısmından belirtilmektedir. Test işlemi

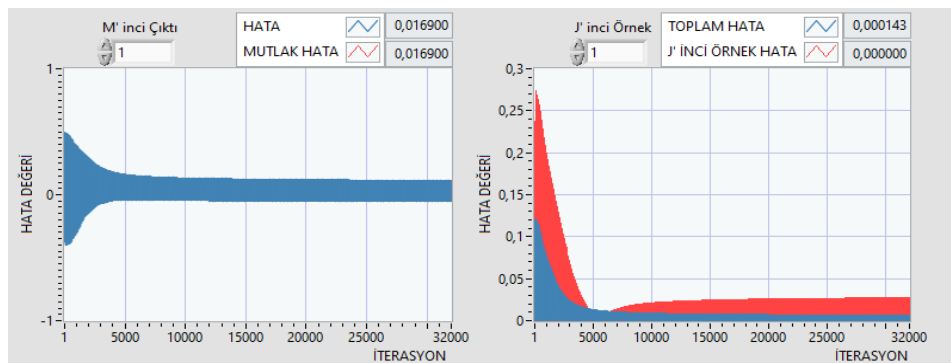
esnasında ağın ürettiği çıktı değerlerinin doğru kabul edilebilmesi için belirlenen tolerans değeri “Tolerans” kısmından girilmektedir.



Şekil 4: Bağlantı Ağırlıkları

Şekil 2’de görüldüğü üzere ağın parametre değerlerinin altında kalan kısımda “DÜZENLE”, “SIFIRLA”, “EĞİT” ve “TEST ET” şeklinde isimlendirilmiş 4 adet buton bulunmaktadır. “DÜZENLE” butonuna tıklanmadan önce ağın veri setinin yüklenmesi ve parametre değerlerinin girilmesi gerekmektedir. Butona tıkladığında yazılım, girilen parametre değerlerine göre ağın yapısını düzenlemektedir. “SIFIRLA” butonuna basıldığında girilen tüm parametre ve ağırlık değerleri sıfırlanmaktadır. “EĞİT” butonu ile ağın eğitimine başlanmakta, “TEST ET” butonu ile ağın test işlemine başlanmaktadır. “EĞİT” butonuna basmadan önce ilk ağırlık değerlerinin girilmesi gerekmektedir.

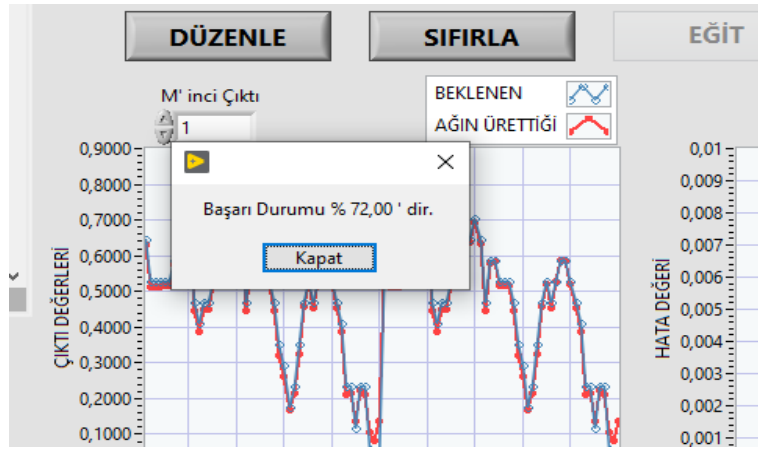
Bağlantı ağırlıklarının girildiği kısım Şekil 4’te gösterilmiştir. Bağlantı ağırlıklarını girmeden önce veri setinin yüklenmesi, çıkış adetinin belirtilmesi ve ağın topolojik yapısını belirleyen parametrelerin girilmesinin ardından düzenle butonuna tıklanması gerekmektedir. Butona tıkladığında yazılım, ağın birtakım parametrelerine ve topolojik yapısına göre hangi katmanda ne kadar bağlantı ağırlığı olacağını Şekil 4’te gösterilen diziler üzerinde otomatik olarak düzenlemektedir. Şekil 4 üzerinde görülen “Ai Ağırlıklar” kısmı giriş katmanı ile ara katman arasındaki, “Aa Ağırlıklar” kısmı ise ara katman ile çıktı katmanı arasındaki ağırlıkları ifade etmektedir.



Şekil 5: Hata grafikleri


Ağın eğitimi esnasında iterasyonlar boyunca oluşan hataların grafikleri Şekil 5’te gösterilmiştir. Bu grafiklerden soldaki hata ve mutlak hata değerlerinin iterasyonlar boyunca değişimini göstermektedir. Sağdaki grafik ise toplam hata ve her bir örneğin hata değerlerinin iterasyonlar boyunca değişimini göstermektedir. Grafikler üzerine sağ tıkladığında “Export” yazan kısım üzerine gelince açılan alt menüde grafik verilerini resim veya excel ortamında kayıt altına alabileceğimiz seçenekler

bulunmaktadır.



Şekil 6: Dialog Box


Test işleminin bitmesinin ardından başarı durumunun belirtildiği Dialog Box Şekil 6'da görülmektedir. Şekil üzerinde görülen “Kapat” butonuna tıklandığında Şekil 5'te görülen hata grafiklerinin yerini karşılaştırma ve toplam hata grafikleri almaktadır. Karşılaştırma ve toplam hata grafikleri Şekil 7'de gösterilmektedir.



Şekil 7: Karşılaştırma ve Toplam Hata grafikleri

Yazılımın Blok Diyagram tarafında toplamda 4 adet alt program (SubVI) oluşturulmuştur. Alt programların kullanılmasıyla yazılımın karmaşıklığı giderilmiş ve tekrar eden işlemler için kolaylık sağlanmıştır. Şekil 8'de yazılıma ait Blok Diyagram gösterilmiştir.

Yapay Sinir Ağları ile Hava Durumu Tahmini ve Çok Katmanlı Ağ Modeli için LabVIEW Arayüz Tasarımı



Şekil 8: Blok Diyagram

3.2 Hava Durumu Tahmini için ÇKA Modelinin LabVIEW de Gerçekleştirilmesi

Çalışmada toplam 30 adet eğitim verisi 15 adet test verisi kullanılmıştır. Kullanılan veriler öncelikle Denklem 17’de gösterilen formül kullanılarak Excel ortamında normalize edilmiştir.

$$X_{normal_i} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (17)$$

Veri seti Nem Oranı (%), Görüş Mesafesi (km), Basınç (mb), Çiğ Noktası (°C) başlığı altında dört adet girdi ve Sıcaklık (°C) başlığı altında bir adet çıktıdan oluşmaktadır. Uygulamada kullanılan eğitim verileri Tablo 1’de, test verileri ise Tablo 2’de sunulmuştur.

Tablo 1: Eğitim verisi

| Tarih | Girdi Katmanı Değerleri | | | | Çıktı Katmanı Değerleri |
|------------|-------------------------|---------------------|-------------|------------------|-------------------------|
| | Nem Oranı (%) | Görüş Mesafesi (km) | Basınç (mb) | Çiğ Noktası (°C) | Sıcaklık (°C) |
| 15.06.2017 | 67,5 | 31 | 36 | 17 | 27 |
| 16.06.2017 | 70 | 32 | 37 | 17 | 28 |
| 17.06.2017 | 72,5 | 33 | 38 | 18 | 29 |
| 18.06.2017 | 75 | 34 | 39 | 17 | 30 |
| 19.06.2017 | 75 | 34 | 39 | 19 | 30 |
| 20.06.2017 | 80 | 36 | 41 | 19 | 32 |
| 21.06.2017 | 77,5 | 35 | 40 | 19 | 31 |
| 22.06.2017 | 85 | 38 | 43 | 21 | 34 |
| 23.06.2017 | 82,5 | 37 | 42 | 23 | 33 |
| 24.06.2017 | 80 | 36 | 41 | 22 | 32 |
| 25.06.2017 | 82,5 | 37 | 42 | 23 | 33 |
| 26.06.2017 | 82,5 | 37 | 42 | 19 | 33 |

| | | | | | |
|------------|------|----|----|----|----|
| 27.06.2017 | 85 | 38 | 43 | 21 | 34 |
| 28.06.2017 | 80 | 36 | 41 | 22 | 32 |
| 29.06.2017 | 70 | 32 | 37 | 22 | 28 |
| 30.06.2017 | 62,5 | 29 | 34 | 19 | 25 |
| 1.07.2017 | 75 | 34 | 39 | 20 | 30 |
| 2.07.2017 | 77,5 | 35 | 40 | 19 | 31 |
| 3.07.2017 | 82,5 | 37 | 42 | 20 | 33 |
| 4.07.2017 | 75 | 34 | 39 | 21 | 30 |
| 5.07.2017 | 72,5 | 33 | 38 | 20 | 29 |
| 6.07.2017 | 75 | 34 | 39 | 19 | 30 |
| 7.07.2017 | 82,5 | 37 | 42 | 19 | 33 |
| 8.07.2017 | 70 | 32 | 37 | 17 | 28 |
| 9.07.2017 | 72,5 | 33 | 38 | 16 | 29 |
| 10.07.2017 | 72,5 | 33 | 38 | 16 | 29 |
| 11.07.2017 | 70 | 32 | 37 | 16 | 28 |
| 12.07.2017 | 70 | 32 | 37 | 16 | 28 |
| 13.07.2017 | 82,5 | 37 | 42 | 18 | 33 |
| 14.07.2017 | 90 | 40 | 45 | 21 | 36 |

Tablo 2: Test verisi

| Tarih | Girdi Katmanı Değerleri | | | | Çıktı Katmanı Değerleri |
|------------|-------------------------|---------------------|-------------|------------------|-------------------------|
| | Nem Oranı (%) | Görüş Mesafesi (km) | Basınç (mb) | Çiğ Noktası (°C) | Sıcaklık (°C) |
| 15.07.2017 | 90 | 40 | 45 | 22 | 36 |
| 16.07.2017 | 97,5 | 43 | 48 | 23 | 39 |
| 17.07.2017 | 97,5 | 43 | 48 | 24 | 39 |
| 18.07.2017 | 97,5 | 43 | 48 | 23 | 39 |
| 19.07.2017 | 82,5 | 37 | 42 | 22 | 33 |
| 20.07.2017 | 75 | 34 | 39 | 21 | 30 |
| 21.07.2017 | 67,5 | 31 | 36 | 20 | 27 |
| 22.07.2017 | 75 | 34 | 39 | 20 | 30 |
| 23.07.2017 | 80 | 36 | 41 | 20 | 32 |
| 24.07.2017 | 80 | 36 | 41 | 19 | 32 |
| 25.07.2017 | 77,5 | 35 | 40 | 19 | 31 |
| 26.07.2017 | 80 | 36 | 41 | 20 | 32 |
| 27.07.2017 | 85 | 38 | 43 | 20 | 34 |
| 28.07.2017 | 82,5 | 37 | 42 | 22 | 33 |
| 29.07.2017 | 82,5 | 37 | 42 | 21 | 33 |

Ağın topolojik yapısını belirleyen hususlardan biri katmanlardaki proses eleman sayısıdır. Çalışmada kullanılan YSA'nın topolojik yapısı girdi katmanında dört, ara katmanda üç, çıktı katmanında ise bir proses elemanından oluşmaktadır. Proses elemanı net girdilerinin hesaplanmasında ağırlıklı toplam

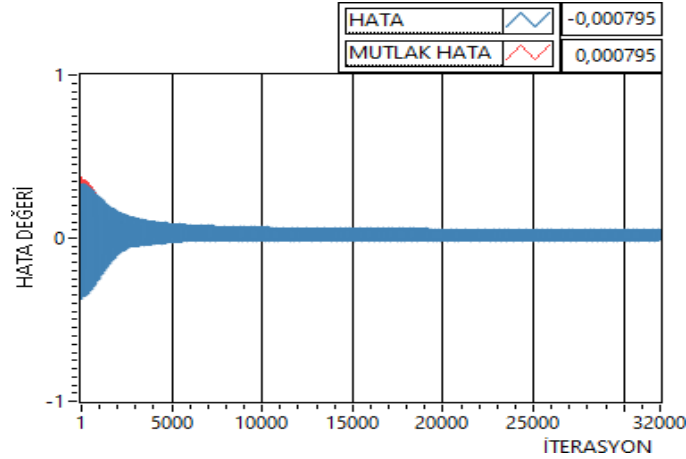
formülü kullanılmıştır. Aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmıştır. Katmanlar arası bağlantı ağırlıklarına ilave eşik değeri kullanılmamıştır.

| Ai Ağırlıklar | | | | |
|---------------|-----------|----------|-----------|---|
| 0 | 0,129952 | 0,570345 | 0,631894 | ^ |
| 0 | -0,923123 | 0,328932 | -0,256987 | ^ |
| | 0,214896 | 0,525896 | -0,325734 | ^ |
| | 0,98321 | 0,84374 | 0,741369 | ^ |
| | < | | > | |
| Aa Ağırlıklar | | | | |
| 0 | 0,164732 | 0 | 0 | ^ |
| 0 | 0,752624 | 0 | 0 | ^ |
| | -0,56987 | 0 | 0 | ^ |
| | < | | > | |

Şekil 9: Başlangıç Ağırlıkları


Öğrenme parametrelerinden Lamda değeri 0,8 ve Momentum değeri 0,2 olarak belirlenmiştir. Tolerans değeri 0,03 ve İterasyon sayısı 32000 olarak belirlenmiştir. Ağın ilk başlangıç ağırlık değerleri Şekil 9'da gösterilmiştir.

Eğitimin sonunda elde edilen Hata ve Mutlak Hata değerlerinin iterasyon boyunca değişimini gösteren grafik Şekil 10'da gösterilmiştir. Hata değeri, ağın ürettiği çıktı ile beklenen çıktı değeri arasındaki fark alınarak bulunur. Şekil 10'da gösterilen grafikten de anlaşıldığı üzere hata değeri belirli bir iterasyon boyunca sürekli düşmüş daha sonra sabit bir çizgi izlemeye başlamıştır. Yani hata değişim miktarı azalmıştır.



Şekil 10: Hata ve Mutlak Hata Grafığı

Ağa verilen örneklere ait hata değerleri ve toplam hata değerlerinin iterasyon boyunca değişimini gösteren grafik Şekil 11'de gösterilmiştir.



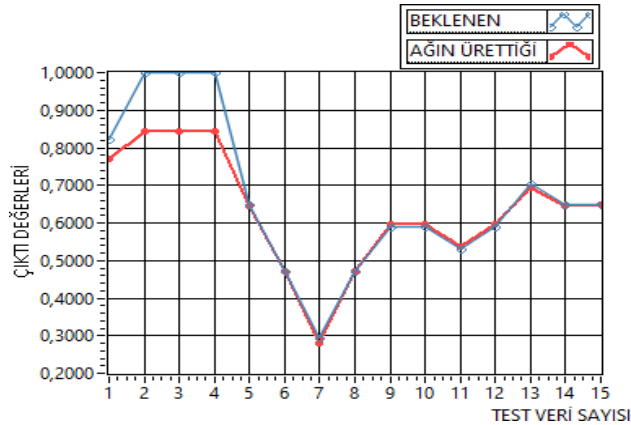
Şekil 11: Örnek ve Toplam Hata Grafiği

Eğitimin sonunda elde edilen yeni ağırlık değerleri Şekil 12’de belirtilmiştir.

| A _i Ağırlıklar | | | |
|---------------------------|-----------|-----------|-----------|
| 0 | -0,687477 | 0,866976 | -0,594286 |
| 0 | -0,940569 | -0,269159 | 0,130692 |
| | -0,602533 | 0,822527 | -1,55191 |
| | 0,267541 | 0,599099 | 0,223967 |
| A _a Ağırlıklar | | | |
| 0 | -3,33531 | 0 | 0 |
| 0 | 3,17672 | 0 | 0 |
| | -4,91732 | 0 | 0 |


Şekil 12: Eğitim Sonunda Elde Edilen Ağırlıklar

Yeni ağırlıklar kullanılarak yapılan test işlemi sonucunda ağın başarı durumu yüzde 73,33 çıkmıştır. Beklenen değerler ile ağın ürettiği çıktı değerlerinin karşılaştırıldığı grafik Şekil 13’te belirtilmiştir. Grafiği inceleyecek olursak ilk dört değer için aradaki farkın diğerlerine nazaran daha çok olduğu görülmektedir.




Şekil 13: Karşılaştırma Grafiği

Test verilerine ait toplam hata grafiği Şekil 14’te gösterilmiştir.



Şekil 14: Toplam Hata Grafiği

Ağın ürettiği çıktı değerleri ile beklenen değerler Tablo 3'te gösterilmiştir. Bu veriler kullanılarak Microsoft Excel ortamında dağılım grafiği çizdirilip eğilim çizgisi eklenmesiyle oluşan R^2 değerinin 0,9558 olduğu Şekil 15'te görülmektedir.



Şekil 15: Dağılım Grafiği

Tablo 3: Beklenen ve Ağın Ürettiği Çıktı Değerleri

| Beklenen Sıcaklık Değeri (°C) | Normalize Edilmiş Beklenen Çıktı Değeri | Ağın Ürettiği Çıktı Değeri | Ağın Ürettiği Sıcaklık Değeri (°C) | Yüzde Başarı (%) |
|-------------------------------|---|----------------------------|------------------------------------|------------------|
| 36 | 0,8235 | 0,7702 | 35,0934 | 93,52763 |
| 39 | 1 | 0,8447 | 36,3599 | 84,47 |
| 39 | 1 | 0,8444 | 36,3548 | 84,47 |
| 39 | 1 | 0,8447 | 36,3599 | 84,47 |
| 33 | 0,6471 | 0,6468 | 32,9956 | 99,9534 |
| 30 | 0,4706 | 0,4711 | 30,0087 | 99,8935 |
| 27 | 0,2941 | 0,2804 | 26,7668 | 95,3412 |
| 30 | 0,4706 | 0,4722 | 30,0274 | 99,6601 |
| 32 | 0,5882 | 0,5949 | 32,1133 | 98,8603 |
| 32 | 0,5882 | 0,5955 | 32,1235 | 98,7583 |
| 31 | 0,5294 | 0,5364 | 31,1188 | 98,6775 |
| 32 | 0,5882 | 0,5949 | 32,1133 | 98,8603 |
| 34 | 0,7059 | 0,6955 | 33,8235 | 98,5267 |
| 33 | 0,6471 | 0,6468 | 32,9956 | 99,9534 |
| 33 | 0,6471 | 0,6477 | 33,0109 | 99,9078 |

4 Sonuçlar

LabVIEW programında tasarlanan ara yüz kullanılarak Genelleştirilmiş Delta Öğrenme Kurallı YSA modeli ile doğrusal olmayan hava durum tahmin problemine çözüm getirilmiştir. Tasarlanan ara yüzün kullanıcılara sunduğu imkanlar şöyle listelenebilir.

1. Eğitim ve Test verilerinin ayrı ayrı yüklenmesine gerek duyulmamaktadır. Eğitim veri adedinin girilmesi ile bu ayırımın otomatik olarak yapılması sağlanmıştır.
2. Ana ekranda bulunan hata grafikleri ile eğitim esnasında eş zamanlı olarak hataların iterasyon boyunca değişimlerinin izlenebilmesine olanak sağlanmıştır.
3. Ara yüzde YSA'nın oluşturulması, eğitimi ve test işlemine dair tüm parametreler, grafikler ve diziler tek bir sayfada görülebilecek şekilde tasarlanmıştır.
4. Grafikler üzerine sağ tıklandığında "Export" yazan kısım üzerine gelince açılan alt menüde grafik verilerini resim veya excel ortamında kayıt altına alabileceğimiz seçenekler bulunmaktadır.
5. Geliştirilen tasarım ile doğrusal olmayan sınıflandırma, tahmin gibi problemlerine çözüm getirmeye olanak sağlanmıştır.

LabVIEW üzerinde nesneye dayalı programlama teknikleri kullanılması, ileriki çalışmalarda çeşitli algoritma ve çözüm yöntemlerinin kolaylıkla eklenebilmesine olanak tanır. Farklı öğrenme algoritmaları ve aktivasyon fonksiyonları eklenerek çalışmanın geliştirilmesi mümkündür.

5 Beyanname

5.1 Çalışma sınırları

Çalışmada herhangi bir sınır bulunmamaktadır.

5.2 Teşekkür

Çalışmaya olan katkılarından ötürü emeği geçen Elektrik Elektronik Mühendisi Şevket ÖZKAYA'ya ve Sakarya Uygulamalı Bilimler Üniversitesi Robot Teknolojileri ve Akıllı Sistemler Uygulama Araştırma Merkezine (ROTASAM) de çalışmaya sağladığı katkılardan dolayı teşekkür ederiz.

5.3 Finansman Kaynağı

Çalışmada herhangi bir finans kaynağı kullanılmamıştır.

5.4 Rakip Çıkarlar

Çalışma rakip çıkarlar içermemektedir.

5.5 Yazarların Katkıları

Serdar ÖZKAYA: Makale için fikir geliştirme, sonuçlara ulaşma yöntemlerini planlama, sonuçların açıklanması ve sunumu için sorumluluk alma, literatür taraması sorumluluğunu alma, makalenin tamamının oluşturulmasında katkı sağlama.

Gökhan ATALI: Makale için fikir geliştirme, sonuçlara ulaşma yöntemlerini planlama, sonuçların açıklanması ve sunumu için sorumluluk alma, literatür taraması sorumluluğunu alma, makalenin tamamının oluşturulmasında katkı sağlama.

6 Veri Kullanılabilirliği

Bu çalışmada 15 günlük hava durumu verilerini içeren bir internet sitesinden çekilerek hazırlanmış veri seti kullanılmıştır. [17].

Kaynakça

- [1] M. M. Bukhari, B. F. Alkhamees, S. Hussain, A. Gumaedi, A. Assiri ve S. S. Ullah, "An Improved Artificial Neural Network Model for Effective", *Complexity*, cilt 2021, 2021.
- [2] H. Jiang ve L. Gao, "Optimizing the Rail Profile for High-Speed Railways", *Sustainability*, cilt 12, no. 2, p. 658, 2020.
- [3] T. Majoros, S. Oniga ve Y. Xie, "Motor imagery EEG classification using feedforward neural network", *Annales Mathematicae Et Informaticae*, cilt 53, pp. 235-244, 2021.
- [4] M. Thakur, R. Bhattacharyya ve S. S. Mondal, "Artificial Neural Network Based Model for Forecasting of Inflation in India", *Fuzzy Information And Engineering*, cilt 8, no. 1, pp. 87-100, 2016.
- [5] G. Atalı, S. S. Özkan ve D. Karayel, "Image Damage Analysis With Morphological Image Processing Technique Using Artificial Neural Networks", *Academic Platform - Journal of Engineering and Science*, cilt 4, no. 1, pp. 0-0, 2016.
- [6] A. Ö. Akyüz, K. Kumaş, M. Ayan ve A. Güngör, "Antalya İli Meteorolojik Verileri Yardımıyla Hava Sıcaklığının Yapay Sinir Ağları Metodu ile Tahmini", *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, cilt 10, no. 1, pp. 146-154, 2020.
- [7] R. Güç, "Bilecik ili için güneş enerjisi analizi ve yapay sinir ağları ile hava sıcaklığı tahmini (Yayımlanmamış yüksek lisans tezi)", *Bilecik: Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü - Tez Koleksiyonu*, 2016.
- [8] S. Yavuz, M. Deveci, "İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi", *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 0, no. 40, pp. 167-187, 2015.
- [9] M. Aydın, E. Çelik, "Early detection of hazardous weather conditions in Turkey with satellite images using Support Vector Machines and Artificial Neural Networks", *2013 21st Signal Processing and Communications Applications Conference (SIU)*, Girne, Kıbrıs, 2013.
- [10] E. Öztemel, *Yapay Sinir Ağları*, İstanbul: Papatya Yayıncılık, 2006.
- [11] S. Haykin, *Neural Networks and Learning Machines*, New Jersey: Pearson Education, 2009.
- [12] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems. Second Edition*, England: Pearson Education, 2005.
- [13] "Hava Durumu 15 Günlük", [Çevrimiçi]. Available: <https://www.havadurumu15gunluk.net/>.
- [14] A. Arı ve M. E. Berberler, "Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı", *Acta Infologica*, cilt 1, no. 2, pp. 55-73, 2017.
- [15] E. N. Dizdaar ve O. Koçar, "İş Sağlığı Ve Güvenliği Yönetim Sistemlerinde Risklerin Yapay Sinir Ağlarıyla Değerlendirilmesi", *Academic Platform - Journal of Engineering and Science*, cilt 6, no. 3, pp. 73-83, 2018.
- [16] D. Kriesel, *A Brief Introduction to Neural Networks.*, 2007.
- [17] M. Kalaycı, "YSA Hava Durumu Tahmin", *GitHub*, Konya, 2018.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi

Süleyman AKTÜRK¹ , Kasım SERBEST^{2*} 

¹ Mekatronik Mühendisliği Bölümü, Lisansüstü Eğitim Enstitüsü, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye.

² Mekatronik Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye.

ÖZ

Yapay zekâ kavramı 1900'lü yılların ikinci çeyreğinden itibaren hayatımıza girmeye başlamıştır. Bugüne kadar ki süreçte bazen çok popüler olmuş, bazen de unutulmaya yüz tutmuştur. 2000'li yıllarda bilgisayar donanımlarının gelişmesi ve yapay sinir ağlarındaki gelişmeler Yapay zekâ araçlarının tekrardan yoğun kullanılmasına sebep olmuştur. Derin öğrenme çalışmaları yapay zekâ çalışmalarının lokomotifi konumundadır. Derin öğrenme sadece bilgisayar biliminde ve nesne algılama görevinde değil, birçok disiplinde ve birçok görevde kullanılmaktadır. Derin öğrenme çalışmaları için farklı mimariler, farklı donanımlar, farklı yazılım çerçeveleri geliştirilmiştir. Derin öğrenme araçlarının ve mimarilerinin bu kadar fazla olması özellikle problemlerinin çözümü için derin öğrenme araçlarını kullanmak isteyen araştırmacıların kafasını karıştırabilmekte veya işini zorlaştırabilmektedir. Bu çalışmada derin öğrenme kavramı hakkında bir anlayış oluşturmayı hedefliyoruz. Derin öğrenme kavramını ve onu oluşturan alt bileşenleri sistematik olarak sunuyoruz. Akabinde günümüzde yaygın olarak kullanılan ana akım derin öğrenme çerçevelerini sunuyoruz. Bu çerçevelerin performans, zaman, doğruluk, Google da arama, GitHub'da takip edilme gibi farklı ölçütlere göre incelendiği araştırmalardan bir derleme hazırlanmıştır. Bu çalışmanın özellikle derin öğrenme araçlarına aşina olmayan ancak çalışmalarında derin öğrenme araçlarını kullanmak isteyen araştırmacı ve okuyucular için bir kılavuz olmasını arzu ediyoruz.

Anahtar Kelimeler: Makine öğrenmesi, yapay sinir ağları, derin öğrenme kütüphaneleri

A Review of Deep Learning Libraries for Object Detection

ABSTRACT

The idea of artificial intelligence has been in our lives since the second quarter of the 20th century. Up to now, it has enjoyed great popularity in some cases, and in others it has been forgotten. In the 2000s, the development of computer hardware and developments in artificial neural networks led to an extensive use of artificial intelligence algorithms. Deep learning studies are the pioneers of artificial intelligence studies. Deep learning is not only used in computer science and object detection, but also in many disciplines and many tasks. Different architectures, hardware and software frameworks have been developed for deep learning studies. The fact that there are so many deep learning tools and architectures can confuse the work of researchers who want to use deep

* Sorumlu yazarın e-posta adresi: kserbest@subu.edu.tr

learning tools to solve their problems. In this study we want to create an understanding of the concept of deep learning. We present the concept of deep learning and its subcomponents systematically. We then introduce the common deep learning frameworks that are widely used recently. A review was created from the studies in which these frameworks were examined according to different criteria such as performance, time, accuracy, searched on Google, followed by GitHub. In this study, we would like to be a guide for researchers and readers who are unfamiliar with deep learning algorithms but want to use deep learning tools in their studies.

Keywords: Machine learning, neural network, deep learning libraries

1 Giriş

Yapay zekâ uygulamaları hava durumu tahmini, ekonomik göstergeler, günlük haberlerin yazılması, yeni sanat eserlerinin oluşturulması, kişisel sağlık takibi, mühendislik hesaplamaları, görüntü işleme gibi birçok alanda karşımıza çıkmaktadır. Bu uygulamalardan biri de nesne tespittir. Nesne tespiti bir görüntü içindeki nesnenin belirginleştirilerek zeminden ayırt edilmesi işlemidir [1]. Diğer bir tanımla nesne tespiti görüntüde bulunan belirli nesnelerin konum ve sınıflarının belirlenmesidir. Nesne tespitinde nesnelere genellikle dikdörtgen çerçevelerle işaretlenmektedir [2]. Nesne tespiti temel bir bilgisayarlı görü görevidir. Bu göreve dayalı olarak yüz tanıma, yaya tanıma, insan uzuvlarının tespiti, nesne takibi, yüzey alanı tespiti vb. birçok gerçek dünya problemi çözülmektedir. Tüm bu uygulamaların temelinde iyi bir nesne algılama algoritması bulunmaktadır.

İnsan beyni görüntüleri kolaylıkla tespit edebilmektedir. Ancak bir makine olan bilgisayar için binlerce pikselden oluşan görüntü içinden nesne tespiti bir dizi karmaşık süreçlerle gerçekleşmektedir. Bilgisayarlı görü uygulamalarında nesne tespit uygulamaları sığ ve derin nesne tespit uygulamaları olarak ele alınabilir. Genellikle makine öğrenmesi metotlarına dayalı sığ yöntemler Histogram Yönelimli Gradyan (HOG), Ölçekten Bağımsız Öznitelik Dönüşümü (SIFT), Destek vektör makineleri (SVMs), Adaptive Boosting (Ada-Boost) gibi sınıflandırıcılar kullanılmaktadır [3]. Derin öğrenme uygulamalarından önce nesne algılama uygulamaları teklif oluşturma, özellik vektörü çıkarma, bölge sınıflandırması aşamalarından oluşmaktaydı. Bu aşamalar uygulayıcı tarafından düzenlenmekteydi. Derin öğrenme ile klasik nesne algılama sürecindeki özelliklerin elle oluşturulması işi özellik oluşturucular tarafında gerçekleştirilmeye başlamıştır. Derin öğrenme yöntemlerinin 2012 yılından itibaren nesne tespit uygulamalarındaki başarı oranı giderek artmaktadır [4]. Derin öğrenme makine öğrenmesinin bir alt dalı olarak veri temsillerini öğrenebilen çok katmanlı ağlar olarak ifade edilir. Veri temsillerinin oluşturulması aşamasında derin öğrenme ağları içerisinde birden çok katmanda birden çok işlem gerçekleştirilmektedir [5].

Bu çalışmada öncelikle yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları hakkında temel bilgiler verilerek okuyucular için bir ön hazırlık yapılmıştır. Daha sonra derin öğrenme çerçeveleri üzerine detaylı bilgiler verilmiş ve bu alandaki güncel araştırma sonuçları sunulmuştur. Bu çalışmanın birincil amacı derin öğrenme alanındaki yeni araştırmacılara ve konuya ilgi duyan okuyuculara derin öğrenme yönteminin temel prensiplerini aktararak nesne tespitine yönelik farklı algoritmalar hakkında bilgiler sunmaktır. Çalışmanın ikincil amacı ise derin öğrenme ile nesne tespiti alanında Türkçe bir kaynak oluşturmaktır. Derin öğrenme alanına yönelik Türkçe olarak hazırlanmış derleme kaynak sayısı son derece sınırlıdır. Hatta yaptığımız araştırmalara göre derin öğrenme ile nesne tespiti alanında son yıllarda hazırlanmış bir çalışma bulunmamaktadır. Çalışmanın ilerleyen bölümlerinde yapay sinir ağları, derin öğrenme modelleri ve derin öğrenme kütüphaneleri hakkında sistematik bilgiler sunulmaktadır.

2 Metodoloji

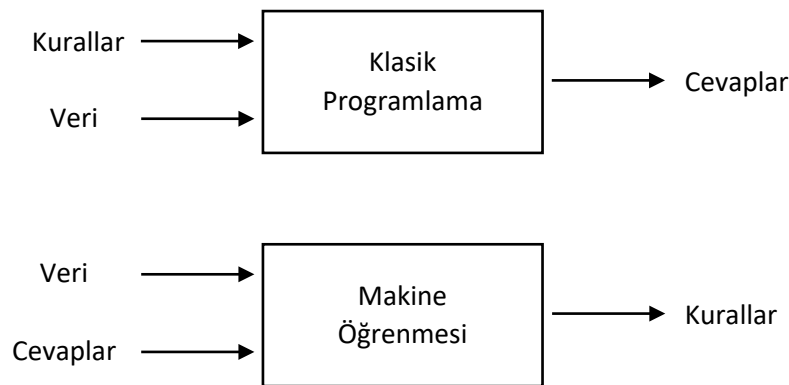
Derin öğrenme -özellikle de derin öğrenme ile nesne tespiti- alanında yapılan çalışmalara ulaşmak için Web of Science, Scopus, IEEE Xplore, Google Akademik ve Yök Akademik veri tabanları kullanılmıştır. Bu veri tabanlarında hem Türkçe hem de İngilizce olarak derin öğrenme (deep learning), nesne tespiti (object detection), duruş tahmini (pose estimation), derin öğrenme kütüphaneleri-algoritmaları (deep learning libraries-algorithms) gibi anahtar kelimeler ve bunların anlamlı kelime grupları ile araştırma yapılmıştır. Özellikle son beş yılda yapılan çalışmalar detaylı olarak incelenmiş ve sonuçları sistematik olarak derlenmiştir. Bu bölümde yapay zekâ, makine öğrenmesi, yapay sinir ağları, derin öğrenme, derin öğrenme katmanları, evrimsel sinir ağları, derin öğrenme modelleri ve derin öğrenme kütüphaneleri hakkında farklı çalışmalardan derlenen bilgiler yer almaktadır.

2.1 Yapay Zekâ

Yapay zekâ (AI) 1950’li yıllardan itibaren belirli duraklama evrelerini aşarak günümüze gelmiştir. Yapay zekanın çıkışı “Bilgisayarlar düşünebilir mi?” sorusuna cevap arama girişimiyle ilişkilidir. Yapay zekâ “Normalde insanlar tarafından yerine getirilen düşünsel faaliyetlerin otonom hale getirilmesi” olarak tanımlanabilir [6]. Bu bağlamda insan gibi düşünen, insan gibi davranışlar sergileyen uygulamalara yapay zekâ uygulamaları ismi verilebilir [7]. Yapay zekaya sahip sistemlerin insana özgü akıl yürütme, anlam çıkartma, genelleme yapma ve geçmiş deneyimlerden öğrenme gibi yüksek seviye zihinsel aktiviteleri yerine getirmesi beklenir. Problem çözümü, oyunların modellenmesi, bilgilerin modellenmesi, uzman sistemler, doğal dil işleme, ses işleme, örüntü tanıma, makine öğrenmesi ve derin öğrenme, bilgisayar yaratıcılığı, robotik gibi konular yapay zekanın ilgi alanı olarak ifade edilebilir [8]. Uzman Sistemler, Bulanık Mantık, Genetik Algoritmalar, Yapay Sinir Ağları gibi yapay zekanın alt dalları, birçok problem alanında son yıllarda çok sık kullanılmaktadır [9].

2.2 Makine Öğrenmesi

Klasik programlamada yazılımcı bilgisayara ne yapacağını söyler. Klasik yapay zekâ uygulamalarında ise veri ve kurallar sisteme yüklenir ve sistemin bu verilere ve kurallara dayanarak sonuç üretmesi beklenir. Makine öğrenmesi (ML) tüm bu yöntemleri kökünden değiştirecek bir paradigma sunmaktadır. Makine öğrenmesi veri ve beklenen çıktıları kullanarak, yeni verilere özgün cevaplar üretebilecek kuralları öğrenebilen sistemler kurgular [6]. Makine öğrenmesi; bilgisayarın öğrenmesi ve sonrasında da tahminde bulunabilmesi için en uygun algoritmayı oluşturmayı amaçlamaktadır. Bu algoritmalar klasik bilgisayar programlaması için oluşturulan algoritmalar gibi sıralı talimatları uygulamak yerine eğitim setinde karşılaştığı örneklerden öğrenip genelleme yaparak öğrendiği bilgiyi yeni durumlara uyarlayabilmektedir [10]. Şekil 1’de makine öğrenmesi yaklaşımı ve klasik programlama arasındaki temel farklılık gösterilmektedir.



Şekil 1: Makine öğrenmesi ve klasik programlama arasındaki fark [6]

Makine öğrenmesi; gözetimli, gözetimsiz ve yarışmacı olarak üçe ayrılabilir. Gözetimli öğrenmede ağın gerçek çıkışı olması gereken çıkışla kıyaslanır. Gerçek çıkışla olması gereken çıkış arasındaki fark en aza indirilmeye çalışılır. Bu şekilde ağırlıklar değiştirilerek sürekli denemeler yapılır. Gözetimsiz öğrenmede ağa giriş verilir ancak çıkış verilmaz. Giriş bilgilerine göre ağırlıklarının kendisinin ayarlaması beklenir. Yarışmacı öğrenmede ise girişteki verileri belirli sayıda sınıfa ayırması beklenir [9]. Şekil 2’de farklı makine öğrenmesi yöntemleri yer almaktadır.




Şekil 2: Makine öğrenmesi yöntemleri [9]

Makine öğrenmesi istatistikle yakından alakalıdır. Ancak birçok yönden ayrılmaktadırlar. Makine öğrenmesi büyük veriyle çalışmaya yatkındır. İstatistik yöntemleri büyük veri karşısında yetersiz kalmaktadır [6]. Makine öğrenmesinde amaç deneyimlerden öğrenmek ve bu yolla performansı iyileştirmektir. Deneyim sayısı ne kadar artarsa öğrenme de o kadar iyi olmaktadır. Dolayısıyla Makine öğrenmesi artan veri miktarıyla daha da önemli bir hal almıştır [11]. Makine öğrenmesinde öğrenilecek olgunun temsilleri sisteme giriş olarak sunulur. Her temsilin çıkışı ne kadar etkileyeceği ağ tarafından belirlenir. Burada temsilcileri iyi belirlemek önemlidir. Klasik makine öğrenmesinde temsilciler elle oluşturulmaktadır [4].

2.3 Yapay Sinir Ağları

Yapay sinir ağları (YSA) insan beynindeki benzer sinir hücrelerinin birbiri ile ilişkilendirilmesiyle oluşur. En temel insani özelliklerden olan öğrenme yeteneğine sahiptir. Her proses elemanı birbirine ağırlıklarla bağlanmıştır. Öğrenme dediğimiz olgu bu ağırlıkların ağ tarafından değiştirilerek en doğru sonucu verecek hale getirilmesidir. Sonuçta girdilere göre ağırlıklar eğitilerek yeni durumları öğrenmesi sağlanır [12].

Bir yapay sinir ağı yapısı genel olarak giriş katmanı (girdi değerleri ya da öznitelikler), gizli katmanlar ve çıktı katmanı olmak üzere üç ana bölümden oluşur. Girdi katmanında başka bir sinir ağından gelen çıktı değerleri ya da işleme tabi tutulacak nesneye ait öznitelikler bulunur. Gizli katmanlar bu öznitelikleri ve belirli ağırlık değerlerini kullanarak özellik haritası çıkarırlar. Bu özellikler aktivasyon fonksiyonları ile çıktı katmanında anlamlı bir sonuç üretilmesini sağlarlar [10]. Şekil 3’te verilen model incelendiğinde x girişleri w ağırlıklarıyla çarpılarak toplam fonksiyonundan geçirilmektedir. Elde edilen toplam $F(\text{net})$ transfer fonksiyonuyla çıkışa aktarılmaktadır [7].



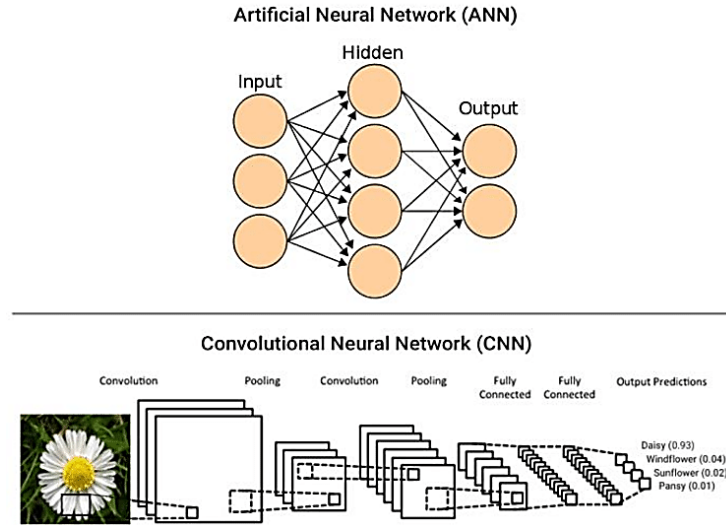
Şekil 3: Bir sinir hücresinin matematiksel modeli [7]

2.4 Derin Öğrenme

Derin öğrenme (DL), birden çok işleme katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyiyle verilerin temsillerini öğrenmesine olanak tanır. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi diğer birçok alanda son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, bir makinenin önceki katmandaki temsilden her katmandaki gösterimi hesaplamak için kullanılan dahili parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder [13].


Derin öğrenme klasik makine öğrenmesindeki veri temsillerini elle oluşturma yükünden kurtulmaya imkân vermiştir. Derin öğrenme, birbirini takip eden katmanlarda veriler işlenirken giderek artan şekilde daha kullanışlı temsiller elde ederler. Derin öğrenmenin özellik çıkarım yükünü üzerine alması, onun popüler olmasını sağlamıştır. Günümüzde derin öğrenme çalışmaları hızla artmaktadır [14]. Büyük veri setlerinin artması, bilgisayar donanımlarının güçlenmesi derin öğrenme çalışmalarını desteklemektedir.

Derin öğrenmedeki derinlik ifadesi birbirini takip eden katmalardır [6]. Derin öğrenme, derin sinir ağları çok katmanlı yapay sinir ağları olarak da ifade edilebilir. YSA dönüşümü ileri beslemeli sinir ağları, geri beslemeli sinir ağları ve çok katmanlı sinir ağları şeklinde ifade edilebilir. En popüler derin sinir ağlarından biri Evrişimli Sinir Ağı'dır (CNN). Bu adı, evrişim adı verilen matrisler arasındaki matematiksel doğrusal işlemde alır. CNN'nin evrişimli katman, doğrusal olmayan katman, havuz katmanı ve tam bağlantılı katman gibi birden çok katmanı vardır [15]. CNN'ler özellikle bilgisayarlı görü alanında üst düzey başarılar elde etmiştir [4]. Şekil 4'te bir YSA ve CNN'in topolojik yapısı yer almaktadır. Bir sınıflama probleminde CNN'nin çıktıkları girdinin ait olduğu sınıflardır. CNN'nin eğitim aşaması genellikle zaman alıcı ve kaynak tüketicidir. Eğitimden sonraki tahmin aşaması hızlıdır ve az kaynak tüketir [16].



Şekil 4: YSA (üstte) ve CNN (altta) farklı topolojileri [17]


Bahsedilen kavramlar arasındaki ilişki şu şekilde ifade edilebilir; makine öğrenmesi yapay zekânın bir alt dalıdır. YSA ise makine öğrenmesinin bir sınıfı olarak kabul edilebilir. CNN'ler ise YSA'ların zamanla geliştirilmiş halidir ve aynı zamanda Derin Öğrenme kavramı altında kullanılmaktadır. Derin öğrenme ayrıca temelinde bulunan YSA ve CNN yapılarıyla beraber yapay zekânın bir alanı olarak kabul edilebilir (Şekil 5) ve makine öğrenmesi alanından ayrılabilir [18].



Şekil 5: Yapay zekâ yöntemlerinin temsili gösterimi [6]


2.5 Derin Öğrenme Katmanları

Geleneksel makine öğrenmesi algoritmaları doğrusal yapıdadır. Ancak derin öğrenme algoritmaları çözümü aranan probleme göre değişiklik gösteren katmanlardan ve süreçlerden meydana gelir. Derin öğrenme yaklaşımları önişleme, boyutsal indirgeme, özellik çıkarma ve sınıflandırma katmanlarını bir arada bulundururlar (Şekil 6) [9]. Derin öğrenmenin temel mimarisi olan CNN ses işleme gibi alanlarda da kullanılmasına rağmen genellikle görüntü işleme, görüntü sınıflandırma, görüntü üzerinde örüntü algılama gibi alanlarda meşhur olmuştur [8].




Şekil 6: CNN genel mimarisi [9]

- **Giriş (input) katmanı:** CNN'nin ilk katmanıdır. Ham verilerin bulunduğu katmandır. Giriş verilerinin ağırlık yapısına göre seçilmesi önemlidir. Eğer giriş veri boyutu yüksek seçilirse eğitim ve test aşamasında kullanılacak kaynak miktarı artırabilir. Veri boyutunun düşük seçilmesi ise ağırlık başarısını düşürebilmektedir. Giriş verilerinin optimizasyonu ağırlık çıktıları açısından önemlidir [18].
- **Evrişim (Convolution) katmanı:** Evrişim karmaşık işlemleri basitleştirmek için kullanılan matematiksel bir işlemdir. Evrişim katmanı giriş katmanından gelen veriler üzerinde küçük boyutlu filtreler uygulayarak özellik haritaları çıkarır. Bu şekilde giriş verisinden daha küçük matrisler elde edilir (Şekil 7) [7].
- **Aktivasyon katmanı:** YSA'da olduğu gibi CNN'ler de de aktivasyon fonksiyonu kullanılır. Aktivasyon işlemi giriş sinyali üzerinde yapılan doğrusal olmayan aktarmayı ifade eder. YSA'larda aktivasyon fonksiyonu olarak sigmoid tercih edilmektedir. CNN'de ise aktivasyon fonksiyonu olarak Düzeltilmiş Doğrusal Birimler (ReLU) tercih edilir [9]. ReLU fonksiyonu $h(y) = \max(0, y)$ şeklinde ifade edilebilir. ReLU aktivasyon fonksiyonu ve türevinin grafiği Şekil 8' de verilmiştir [19].




Şekil 7: Evrişim işlemi [7]




Şekil 8: ReLU fonksiyonu ve türevinin grafiği [19]

- **Havuzlama (Pooling) Katmanı:** Havuzlama katmanında amaç girdi boyutlarını düşürmektir. Giriş boyutları bazı filtre matrisleri kullanılarak (maksimum, minimum, ortalama vb.) azaltılır. Havuzlama esnasında veri kayıpları oluşur. Veri kayıplarının oluşması nedeniyle sonuç performansının düşmesi söz konusudur. Fakat havuzlama sonucunda ağıın aşırı ezberlemesi de engellenmiş olur. Havuzlama katmanında filtre matrisinin ne kadar adım atacağı değişebilir [8]. Havuzlama katmanına ait gösterim Şekil 9’da sunulmuştur.




Şekil 9: Havuzlama katmanın şematik gösterimi [20]

- **Tam Bağlı (Fully Connected) Katman:** Evrişimli sinir ağlarında genellikle konvolüsyon, ReLu ve havuzlama katmanından sonra tam bağlantı katmanı yerleştirilir. Bu katmandaki tüm nöronlar bir dizi şeklindedir. Kendinden önceki katmanların tüm nöronları bu katmana bağlıdır. Kendinden önceki tüm katmanların sınıf skorlarını optimize eder. Bu şekilde baskın ağırlıklara bakılarak sınıf tahmini yapılabilir (Şekil 10) [7].
- **Seyreltme (Dropout) katmanı:** Çok katmanlı sinir ağlarında ağıın ezberlemesi problemine karşı geliştirilmiş bir yöntemdir. Bir eşik değeri kullanılarak gereksiz ya da zayıf bilgiler unutulur. Böylelikle ağıın aşırı ezberlemesi engellenmiş olur [8]. Seyreltme işlemi sinir silme, bağlantı silme veya her ikisini silme şeklinde olabilir (Şekil 11).




Şekil 10: Tam bağlı katman yapısı [7]



Şekil 11: Seyreltme katmanı sonrası bağlantı şekli [9]


- **Sınıflandırma (Classification) katmanı:** Derin öğrenmede sınıflandırma işleminin yapıldığı katmandır. Bu katmanın çıkış değeri sınıf sayısı x sınıflandırılacak nesne adedi şeklinde bir matristir. Sınıflandırılacak her nesne için sınıf adedi kadar 0-1 aralığında çıkışlar elde edilir. Her nesne için 1'e en yakın değer ait olduğu sınıfı işaret etmektedir. Başarisından dolayı genellikle softmax sınıflandırıcısı tercih edilmektedir (Şekil 12) [18].



Şekil 12: Softmax fonksiyonu [21]

2.6 CNN Ağının Eğitilmesi

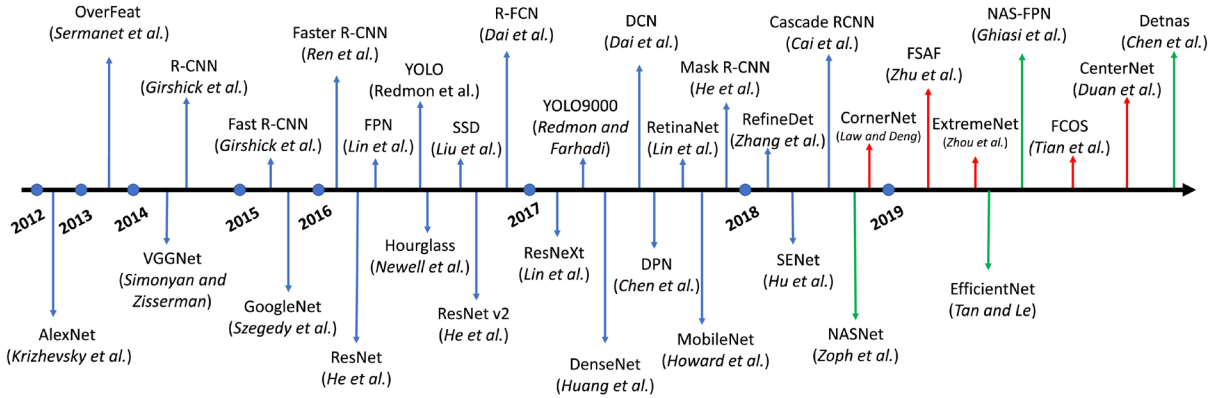
CNN eğitimi için öncelikle ağı yapısı planlanır. Ağda hangi katmanların olacağı, hangi sıraya göre dizileceği belirlenir. Akabinde giriş parametre sayısı, filtre sayısı ve boyutları belirlenir. Eğitim setinden bir veri alınarak sıralanan katmanlarda işlenerek çıkış değeri okunur (ileri yayılım). Elde edilen çıkış ile olması gereken çıkış kıyaslanır. Kıyaslama sonucunda hesaplanan hata tekrar katmanlardan bu defa ters yönde geçirilerek ağırlıklara dağıtılır (geri yayılım). Ağırlıklar güncellenerek toplam hata düşürülmeye çalışılır. Eğitim kümesindeki tüm elemanlar ağa uygulanarak ağırlıklar dinamik olarak güncellenir. Tüm veri seti belirlediğimiz döngü adedince ağa tekrardan uygulanarak toplam hata düşürülmeye çalışılır. Eğitim aşaması bittikten sonra test sırasında sadece ileri yayılım gerçekleştirilip toplam hata hesaplanarak ağı öğrenme başarısı puanlanır. Şekil 14'te bir CNN ağının eğitim ve test işlemine yönelik bir grafik yer almaktadır.



Şekil 13: CNN'nin eğitim ve test işlemlerinin karşılaştırması [19]

2.7 Derin Öğrenme Modelleri

Derin öğrenme nesne algılamadaki başarısından sonra popüler olmaya başlamıştır. Günümüze kadar birçok derin öğrenme modeli bilgisayarlı görme görevleri için tasarlandı ve bu alanlarda birçok başarı elde ettiler. Bu modellerden ilki LeCun tarafından hazırlanmış olan LeNet tir. 2012 yılındaki ImageNet yarışmasında başarılı olan AlexNet derin öğrenmenin yeniden parlamasına sebep olmuştur. Zaman içerisinde birçok mimari geliştirilmiştir. Şekil 14'te derin öğrenme mimarilerinden bazılarının yer verilmiştir. Bu mimariler özellikle bilgisayar görmesi görevlerinde giderek artan miktarda başarıya imza atmışlardır. Derin öğrenme modellerinin zaman içerisinde katman sayıları artırılmıştır. Algılayıcı yapıları iyileştirilerek daha iyi sonuçlar elde edilmeye çalışılmıştır. Özellikle son dönemki mimarilerde çapasız (kırmızı) algılayıcılara ve AutoML (yeşil) mimarilere ilgi artmıştır [4].



Şekil 14: Bazı derin öğrenme mimarilerinin zaman çizelgesi [4]

2.7.1 LeNet

1998 yılında Yann LeCun ve arkadaşları tarafından geliştirilmiştir [22]. Başarılı İlk CNN olarak bilinir. 0 ile 9 arasındaki sayıların görsellerini kullanarak sınıflandırma yapmaktadır. Ağın çıkışı 10 adet sınıftan oluşmaktadır. Giriş olarak 32x32 pikselden oluşan 1024 parametreden oluşmaktadır. Toplamda 7 katmandan oluşmaktadır (Şekil 15.A).

2.7.2 AlexNet


Krizhevsky ve arkadaşlarının çalışması 2012 ImageNet görsel tanıma yarışmasında birinci olmuştur. Örüntü tanıma hata oranını %15 e kadar düşüren bu çalışma [23] derin öğrenme mimarilerinin görüntü tanıma uygulamalarında kullanılmasının popüler olmasına neden oldu. AlexNet mimarisi 5 konvolüsyon katmanı, havuzlama katmanı ve 3 tam bağlantılı katmandan oluşmaktadır (Şekil 15.B)

2.7.3 ZF Net

AlexNet'in ImageNet yarışmasındaki başarısının ardından yapılan yarışmalarda derin öğrenme yöntemleri daha sık kullanılmaya başlanmıştır ve her defasında daha yüksek başarılar elde edilmiştir. Zeiler ve Fergus'un çalışması ZF Net [24] 2013 yılında %11,2'lik hata oranı ile birinci olmuştur. ZF Net modelinde, ilk katmanda AlexNet'in uyguladığı 11x11 boyutlu filtreler kullanmak yerine, 7x7 boyutundaki filtreleri ve havuzlama katmanında 2 adım kayma miktarı kullanılmıştır (Şekil 15.C)

2.7.4 VggNet

VggNet 2014 ImageNet yarışmasında %7.3'lük hata oranıyla birinci olmuştur. Simonyan ve Zisserman tarafından Oxford üniversitesinde tasarlanan bu mimari 6 farklı mimari ortaya koymuşlardır. Bu 6 farklı modelde 11, 13, 16, 19 konvolüsyon katmanlıdan oluşmaktadır [25]. Literatürde vgg-16 vgg-19 gibi fraksiyonları da almaktadır.

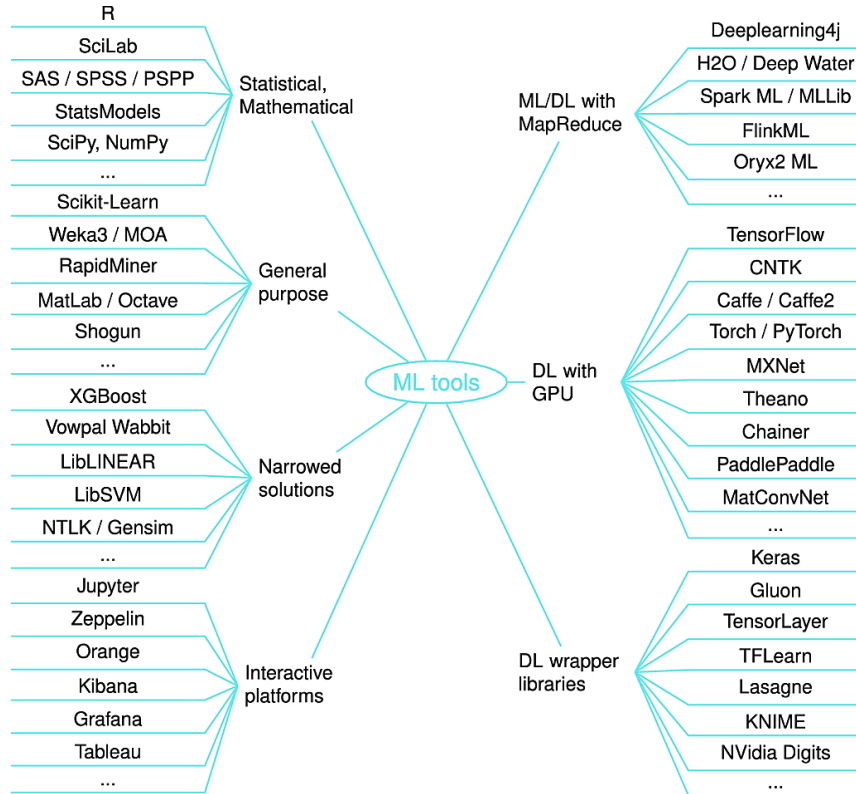


Şekil 15: Bazı derin öğrenme mimarilerinin şematik gösterimi. A; LeNet [22], B; AlexNet [23], C; ZF Net [24]

Literatürde, yukarıda sayılanlar haricinde birçok mimari bulunmaktadır. GoogleNet, ResNet, DenseNet, You only look once (YOLO) bunlardan bazıları olarak sayılabilir. Sonuç olarak derin öğrenme mimarileri hala nesne algılama uygulamalarında en gözde metotlar olarak karşımıza çıkmaktadır.

2.8 Derin Öğrenme Kütüphaneleri

Derin Öğrenme uygulamaları Makine Öğrenmesinin bir alt kümesidir. Makine öğrenmesi ve derin öğrenme uygulamalarını geliştirmek için birçok uygulama çerçevesi ortaya çıkmıştır. Bir problem genellikle bu çerçevelerden bir tanesiyle çözülememektedir. Kütüphanelerin birden fazlasının bir arada kullanılmasıyla çözüme gidilmektedir [26]. Şekil 16'da farklı makine öğrenmesi araçlarının sınıflandırması yer almaktadır.




Şekil 16: Farklı makine öğrenmesi araçları [26]

Derin öğrenmenin popülerliği her geçen gün artmaktadır. Buna paralel olarak farklı derin öğrenme çerçeveleri geliştirilmektedir. TensorFlow (2014), Keras (2014), Theano (2008), caffe (2012), CNTK (2016) bunlara örnek olarak gösterilebilir [27], [28]. Bu derin öğrenme kütüphaneleri Python, c++, java gibi farklı programlama dilleri temel alınarak geliştirilmiştir [29].

2.8.1 TensorFlow

TensorFlow Makine öğrenmesi ve derin öğrenme projelerini baştan sona tasarlayıp sonuçları görebileceğimiz bir ortam sunar [30]. Google Brain ekibi tarafından 2015 yılında açık kaynaklı bir proje olarak yayınlanmıştır. Birbirinde farklı ortamlarda çalışabilir. Farklı programlama dilleri ve farklı donanımlarda çalışabilir. Bu kütüphanedeki yapı temel olarak bir dizi hesaplamalardan meydana gelen veri akış grafiklerinden oluşmaktadır. Bu akış grafikleri düğümlerin durumunu kaydetmek, güncellemek için dallanma ve döngü kontrolüne izin veren bir veri akışı hesaplaması sunar [31]. TensorFlow, otomatik farklılaştırma ve parametre paylaşma yetenekleri nedeniyle farklı mimari türlerini destekler. TensorFlow, paylaşılan parametreleri güncellemek için iş birliği yapan çoklu hesaplama kaynaklarını kullanarak veri akış grafiği modelinin paralel yürütülmesi yoluyla paralellliği destekler. Paralel çalışma yeteneği ciddi performans artışlarına izin verir [14]. TensorFlow ayrıca mobil ve Nesnelerin İnterneti (IoT) cihazlar için

optimize edilmiş çıkarım yapma sürümünü de sunmaktadır. Düşük donanım özelliklerinde etkin sonuçlar vermesi hedeflenmiştir [32]. TensorFlow ile Google ve Amazon gibi bulut ortamlarında model oluşturmak, eğitmek ve test etmek mümkündür. Şekil 17’de TensorFlow mimari katmanlarına yer verilmiştir.



Şekil 17: TensorFlow mimari katmanlarının şematik gösterimi [31]

2.8.2 Keras

Keras, Python’da geliştirilmiş bir derin öğrenme kütüphanesidir. Derin öğrenme modellerinin geliştirilmesi eğitim ve test edilmesi görevlerini yerine getirir [6]. Kullanıcılara yönelik daha kolay araçlar geliştirmeye odaklanmıştır bu nedenle kullanıcı dostudur. TensorFlow ve Theano üzerinde üst düzey uygulama programlama arayüzü (API)’ler sunar. 2021’in başlarında 400.000’den fazla bireysel kullanıcıyla Keras, hem endüstri hem de araştırma topluluğu genelinde güçlü bir şekilde benimsenmiştir [33]. Aynı kodun değişmeden hem merkezi işlem birimi (CPU), hem de grafik işlem birimi (GPU)’da çalışmasını sağlar. Derin öğrenme modellerinin hızlıca prototipleştirilmesini sağlayan API’ler sunar. Evrişimli ağlar, yinelemeli ağlar ve her ikisinin birlikte çalışabilmesi için önceden tanımlı araçlar sunar.

2.8.3 Theano

Theano, Montreal Üniversitesi’nden araştırmacılar ve geliştiriciler tarafından geliştirilmiştir. Theano, Berkeley Software Distribution (BSD) lisansı altında lisanslanan ücretsiz, açık kaynaklı bir yazılımdır. Dünya çapında geniş ve çok aktif bir geliştirici ve kullanıcı topluluğuna dayanır. Theano, derin öğrenme modelleri oluşturmayı kolaylaştıran temel bir matematiksel ifade kütüphanesidir. Theano, çok boyutlu dizileri içeren matematiksel ifadeleri verimli bir şekilde tanımlamaya, optimize etmeye ve değerlendirmeye izin veren bir Python kitaplığı olarak tanımlanabilir. Piyasaya sunulduğundan bu yana, özellikle makine öğrenimi topluluğunda çok fazla kullanılan CPU ve GPU matematiksel derleyicilerinden biri olmuştur [34].

Theano, birçok modern makine öğrenimi modelinde inşa edilen ve kullanılan çok sayıda üstyapı ile 2008’den beri aktif ve sürekli olarak geliştirildi. Ancak, Theano’nun geliştiricilerinden Yoshua Bengio, 2017’de Theano’daki geliştirmenin sona ereceğini duyurdu [35].

2.8.4 Caffe ve Caffe2

Caffe, derin öğrenme algoritmalarını uygulamak için Kaliforniya Üniversitesi, Berkeley tarafından geliştirilen açık kaynaklı bir platformdur. Kodlar, GPU hesaplama için kullanılan Bilgisayar Birleşik Cihaz Mimarisi (CUDA) kütüphanesi ile C++’da yazılır. Ayrıca CUDA kütüphanesi, Python/Numpy ve MATLAB’ı destekler. Caffe, ilk olarak görüntü işleme için tasarlanmasına rağmen daha sonradan ses tanıma, robotik, astronomi ve sinir bilimi için kullanılmıştır [36]. Derin Sinir Ağları (DNN), Caffe’de katman katman tanımlanır. Katman, bir modelin özü ve hesaplamaların temel birimidir. Veriler, Caffe’ye

veri katmanları aracılığıyla girer. Kabul edilen veri kaynakları, verimli veri tabanları (LevelDB veya LMDB), Hiyerarşik Veri Formatı (HDF5) veya yaygın görüntü formatlarıdır (örn. GIF, TIFF, JPEG, PNG, PDF). Nisan 2017’de son kararlı sürümü yayımlanmıştır [26]. Caffe2, Caffe'nin geliştiricisi Yangqing Jia tarafından geliştirilmiştir. Yangqing jia, Facebook’da çalışmaya başladıktan sonra, NVIDIA ve Facebook ile birlikte caffe tabanlı Caffe2 çerçevesini geliştirdiler. Caffe2, büyük ölçekli dağıtılmış eğitim desteği, mobil dağıtım, yeni donanım desteği nicelenmiş hesaplama gibi bazı Caffe sınırlılıklarını iyileştirdi. Caffe2, NVIDIA desteğine sahiptir. Ayrıca python ve c++ API desteği de mevcuttur.

2.8.5 Microsoft CNTK

CNTK, Microsoft Araştırma Ekibi tarafından geliştirilmiştir. Birden çok GPU veya sunucu üzerinde birçok Sinir Ağı türünü eğitmek ve test etmek için geliştirilmiş açık kaynaklı bir DL çerçevesidir. CNTK, İleri Beslemeli, Evrişimli, Tekrarlayan, Uzun Kısa Süreli Bellek (LSTM) gibi farklı DL mimarilerini destekler. CNTK arayüzü, hem GPU (CUDA) hem de CPU platformlarında Python, C ++ ve C # gibi çeşitli dillerin farklı API'lerini destekler. CNTK ileri ve geri işlemlerde yinelenen hesaplamaları kaldıracak şekilde ve minimum bellek kullanacak şekilde c++ ile yazılmıştır [37]. CNTK, Python, C # veya C ++ programlarınıza bir kitaplık olarak dahil edilebilir veya kendi model açıklama dili (BrainScript) aracılığıyla bağımsız bir makine öğrenimi aracı olarak kullanılabilir. Ek olarak, Java programlarında CNTK model değerlendirme işlevini kullanılabilir [38]. Geliştirme ekibi 2.7 sürümü ile CNTK'nın geliştirilme sürecinin sonlandırıldığını duyurmuştur. Ve yeni özellik eklenmeyeceğini duyurmuştur [39].

2.8.6 Torch

Makine öğrenimi algoritmaları için destek sunan BSD lisanslı bilimsel hesap kütüphanesidir. Facebook, Twitter, Google gibi kuruluşlar tarafından desteklenmektedir. Hem CPU hem de GPU’da çalışabilir. Esas olarak büyük ölçekli öğrenme (konuşma, görüntü ve video uygulamaları), denetimli öğrenme, denetimsiz öğrenme, pekiştirmeli öğrenme, Sinir Ağları, optimizasyon, grafik modeller, görüntü işleme için kullanılır. Son sürüm olan Torch7 ile geliştirmesi durdurulmuştur [26].

2.8.7 PyTorch

PyTorch, Facebook’un AI araştırma grubu tarafından Ekim 2016’da tanıtıldı. PyTorch, API aracılığıyla derin öğrenme modelleri oluşturmayı kolaylaştıran Python tabanlı bir derin öğrenme çerçevesidir. Statik hesaplama grafikleri kullanan diğer popüler derin öğrenme çerçevelerinin çoğunun aksine PyTorch, karmaşık mimariler oluşturmada daha fazla esneklik sağlayan dinamik hesaplama kullanır [14]. PyTorch, birçok kütüphaneyle entegre çalışır. Büyük, küçük birçok sinir ağında yüksek performans sunar. PyTorch'daki bellek kullanımı, Torch veya bazı alternatiflere kıyasla son derece verimlidir. Derin öğrenme modellerinizin maksimum düzeyde bellek açısından verimli olmasını sağlamak için GPU’ya özel bellek ayırıcıları mevcuttur. Buda, eskisinden daha büyük derin öğrenme modellerini eğitmenizi sağlar [40]. Kütüphane bir BSD lisansı altında ücretsiz olarak sunulur. Facebook, Twitter, NVIDIA ve diğer birçok kuruluş tarafından desteklenmektedir.


2.8.8 MXNet

MXNet, Carnegie Mellon Üniversitesi, Washington Üniversitesi ve Microsoft arasındaki iş birliği ile ortaya çıkmış açık kaynaklı bir derin öğrenme çerçevesidir. C, Python, MATLAB, JavaScript, R, Julia ve Scala dahil olmak üzere farklı programlama dillerini kullanarak derin sinir ağlarının eğitimine izin veren ölçeklenebilir bir çerçevedir. MXNet, çoklu CPU'larda veya GPU'larda veri paralellliğini destekler ve model paralellğine de izin verir. MXNet, özellikle derin sinir ağları için makine öğrenimi algoritmalarının geliştirilmesini kolaylaştıran çok dilli bir makine öğrenimi (ML) kitaplığıdır. MXNet, hesaplama ve bellek açısından verimlidir ve mobil cihazlardan dağıtılmış GPU kümelerine kadar çeşitli heterojen sistemlerde çalışır [41].

2.8.9 Chainer

Chainer, DL modelleri için Python tabanlı, bağımsız bir açık kaynaklı çerçevedir. Chainer çekirdek geliştirici ekibi, çoğunlukla Tokyo Üniversitesi'nden mühendislerle bir ML girişimi olan Preferred Networks, Inc.'de çalışmaktadır. CNN, Tekrarlayan Sinir Ağı (RNN), pekiştirmeli öğrenme (RL) ve değişken otomatik kodlayıcılar dahil olmak üzere eksiksiz bir DL modelleri yelpazesi sunar [42]. Chainer, model oluşturmak ve eğitmek için üst düzey API'ler sunar. Aynı zamanda endüstriyel uygulamalar için kütüphaneler içerir. Chainer, CUDA hesaplamasını destekler. Bir GPU'dan yararlanmak için yalnızca birkaç satır kod gerektirir. Ayrıca çok az çabayla birden fazla GPU üzerinde çalışır [43]. Temmuz 2020 de son versiyon olan 7.7.0 versiyonu yayınlanmıştır [44].

Şekil 18'de farklı derin öğrenme kütüphanelerine ait bir grafik yer almaktadır. Sırasıyla soldan sağa kullanılan donanımlar, derin öğrenme çerçeveleri, kütüphanelerin yazıldığı programlama dilleri, kütüphanelerin lisansları ve kütüphanelerle geliştirme yapılabilecek programlama dilleri. Araçların hemen hepsi CPU/GPU üzerinde çalışabilmektedir. Python, c/c++, java dilleri kütüphaneleri geliştirmek için kullanılmıştır. Yine birçok dil bu kütüphanelerle geliştirme yapmaya müsaade etmektedir [45].




Şekil 18: Derin öğrenme kütüphaneleri ve API'lerin gösterimi [45]

3 Sonuç ve Tartışma

Derin öğrenme kütüphaneleri birçok görev için sıklıkla kullanılmaktadır. Araştırma ekiplerinden, bireysel çalışmalara, ticari uygulamalara kadar birçok alanda derin öğrenme çalışmaları mevcuttur. Özellikle bilgisayarlı görü uygulamalarındaki nesne algılama görevi derin öğrenme algoritmalarının geliştirilmesi için motivasyon olmuştur. Nesne algılama uygulamalarında parametrelerin fazlalığı veri boyutunun büyük olması bu alandaki iş yükünü bir hayli artırmıştır. Nesne tespitindeki zorlukların aşılması için daha fazla çabalar ortaya koyulmuştur ve bu çabalar derin öğrenme ekosistemini geliştirmiştir. Nesne algılamadaki çalışmaların başarısı diğer problem alanlarındaki başarıyı da olumlu yönde etkilemiş ve artırmıştır. Günümüzde derin öğrenme ekosistemi devasa bir büyüklüğe sahiptir. Bu çeşitlilik yeni uygulamalar geliştirecek kişi veya ekipler için bir karmaşaya da sebep olmaktadır. Sürekli genişleyen derin öğrenme kütüphaneleri arasında tercih yapmak başlı başına bir beceri haline gelmiştir.


Kütüphanelerin genişlemesi beraberinde bu kütüphanelerin incelendiği araştırmaları getirmiştir. Birçok araştırmacı zaman içerisinde yaygın kullanılan derin öğrenme kütüphanelerini farklı açılardan ele alarak kıyaslamışlardır. Bu bölümde literatürdeki derin öğrenme kütüphanelerinin karşılaştırmalı incelemesi yer almaktadır.

Elshawi ve arkadaşlarının [14] gerçekleştirdiği çalışmada, TensorFlow , MXNet , PyTorch , Theano , Chainer ve Keras kütüphaneleri hem CPU hem de GPU üzerinde çalıştırılmıştır. Kütüphanelerin eğitim süresi, doğruluk, yakınsama, kaynak kullanımı açısından performansları karşılaştırılmıştır. Ayrıca farklı derin öğrenme mimarileri ve farklı veri setlerinin kaynak kullanımı ve performans üzerine etkisi incelenmiştir. Elshawi'nin çalışmasında MNIST veri setinin diğer veri setlerine göre doğruluk oranının yüksek olduğu ifade edilmiştir (Şekil 19). Keras kütüphanesinin tüm veri setlerinde daha iyi bir doğruluğa sahip olduğunu gözlemişleridir.




Şekil 19: Farklı veri setleri ile farklı derin öğrenme kütüphanelerinin doğruluk karşılaştırması [14]

Şekil 20'de CNN ve LSTM mimarilerinin farklı farklı veri setlerindeki eğitim süreleri ele alınmıştır. MNIST veri seti eğitim süresi olarak hem CNN hem de LSTM ağında, tüm kütüphanelerde, en az zamana sahip veri seti olarak gözlenmiştir.




Şekil 20: Derin öğrenme kütüphanelerinin CNN ve LSTM mimarileri ile farklı veri setleri üzerinde eğitim süresi karşılaştırması [14]

Yine aynı çalışmada CPU yüzde kullanım oranları kıyaslanmıştır. Şekil 21’de özellikle CNN ağının CPU kullanımı LSTM’ ye göre daha fazla olduğu gözlenmiştir. PyTorch her iki ağ için ortalamada CPU’yu en çok kullanan çerçevedir.



Şekil 21: Derin öğrenme kütüphanelerinin CNN ve LSTM mimarileri ile farklı veri setleri üzerinde ortalama CPU kullanım oranı [14]

Farklı veri setlerinde çerçevelerin en yüksek doğruluğa ulaşma başarısına bakıldığında (Şekil 22) En yüksek performansı PyTorch’ un gösterdiği gözlenmiştir. CIFAR-100 veri setinde en düşük doğruluk oranına sahip çerçeve TensorFlow olarak gözlenmiştir.



Şekil 22: Derin öğrenme kütüphanelerinin farklı veri setleriyle eğitimindeki iterasyon-doğruluk grafiği [14]

Bahrampour [46] ve arkadaşları gerçekleştirdikleri çalışmada: Caffe, Neon, TensorFlow, Theano ve Torch adlı beş derin öğrenme çerçevesini genişletilebilirlik (diğer işlevleri etkilemeden yeni işlev ekleyebilme), hız ve kaynak kullanımı açısından karşılaştırmışlardır. Araştırma sonucunda Theano ve Torch'un en kolay genişletilebilir çerçeveler olduğunu, CPU için sırasıyla Torch ve Theano'nun daha iyi performans verdiğini belirtmişlerdir. Theano'nun, LSTM ağlarının eğitimi ve dağıtımı için GPU'da en iyi performansı elde ettiğini gözlenmiştir. Tensorflow'un esnek olduğunu ancak performans açısından rekabetçi olmadığını ifade edilmiştir.


Wu ve arkadaşlarının [47] gerçekleştirmiş olduğu çalışmada: Tensorflow, Caffe, Torch ve Theano çerçeveleri performans, doğruluk ve kaynak kullanımı açısından karşılaştırılmıştır. Karşılaştırmalar MNIST ve CIFAR-10 datasetleri kullanılarak gerçekleştirilmiştir. MNIST veri seti üzerinde Eğitim süresi en az olan CPU kullanarak Caffe çerçevesi, GPU kullanarak ise TensorFlow olduğu gözlenmiştir (Tablo 1). Test aşamasında ise GPU'da Theano, CPU'da ise TensorFlow olarak gözlenmiştir. CIFAR-10 veri setinin doğruluk oranlarının MNIST' a kıyasla bir hayli düşük olduğu gözlenmiştir.

Tablo 1: Sırasıyla MNIST ve CIFAR10 veri seti değerlendirme sonuçları [47]


| Frameworks | Training Time (s) | Testing Time (s) | Accuracy (%) |
|------------|-------------------|------------------|--------------|
| TF-CPU | 1,114.34 | 2.73 | 99.24±0.05 |
| Caffe-CPU | 512.18 | 3.33 | 99.04±0.02 |
| Torch-CPU | 9,647.34 | 56.52 | 99.24±0.00 |
| Theano-CPU | 11,555.43 | 4.49 | 99.08±0.00 |
| TF-GPU | 68.51 | 0.26 | 99.21±0.03 |
| Caffe-GPU | 97.02 | 0.55 | 99.14±0.03 |
| Torch-GPU | 338.46 | 1.73 | 99.22±0.00 |
| Theano-GPU | 560.04 | 0.19 | 99.05±0.00 |

| Frameworks | Training Time (s) | Testing Time (s) | Accuracy (%) |
|------------|-------------------|------------------|--------------|
| TF-CPU | 219,169.14 | 4.80 | 86.90 |
| Caffe-CPU | 1,730.89 | 14.35 | 75.39 |
| Torch-CPU | 54,830.26 | 114.48 | 66.20 |
| Theano-CPU | 646.9 | 0.91 | 56.04 |
| TF-GPU | 12,477.05 | 2.34 | 87.00 |
| Caffe-GPU | 163.51 | 1.36 | 75.52 |
| Torch-GPU | 1,906.56 | 3.77 | 65.96 |
| Theano-GPU | 105.27 | 0.10 | 54.49 |

Liu ve arkadaşlarının [48] gerçekleştirdiği çalışmada: popüler derin öğrenme çerçevelerinin çeşitli dağıtılmış sürümleri araştırılmıştır. Derin öğrenme çerçeveleri zaman, hafıza kullanımı ve doğruluk açısından kıyaslanmıştır. Bu çalışmada TensorFlow sürümlerinin hem eğitim hem de test aşamasında daha yüksek performans gösterdikleri gözlenmiştir (Şekil 23).

**Şekil 23:** Derin öğrenme kütüphanelerinin iterasyon sayısına göre eğitim ve test performansları [48]

Shi ve arkadaşları [49] gerçekleştirdikleri çalışmada: tek GPU, çoklu GPU ve çok düğümlü ortamlar üzerinden Caffe-MPI, CNTK, MXNet ve TensorFlow derin öğrenme çerçevelerinin çalışma performansı değerlendirilmiştir. Önce DNN'leri SGD ile eğitirken standart süreçlerin performanslarını ölçmüşlerdir. Ardından bu çerçevelerin çalışma performansını AlexNet, GoogleNet ve ResNet-50 ile karşılaştırmışlardır. Dai ve arkadaşları [50] mobil cihazlarda derin öğrenme araçlarının kullanımı ile ilgili bir çalışma gerçekleştirmişlerdir. Bu çalışmada bazı derin öğrenme çerçevelerinin kaynak kullanımı, çıkarım süresi, enerji tüketimi gibi konularda kıyaslamalar sunulmuştur (Şekil 24).


**Şekil 24:** Mobil cihazlarda farklı mimarilerin farklı çerçevelerdeki performansı [49]

Liu ve arkadaşlarının [29] gerçekleştirdiği çalışmada, derin öğrenme çerçevelerinin hataları araştırılmıştır. Çalışma sonucunda 1) incelenen tüm derin öğrenme çerçevelerinde önemli sayıda teknik hata mevcuttur. 2) derin öğrenme çerçevelerinde tasarım hatası, arıza hatası, belge hatası, test hatası, gereksinim hatası, uyum hatası ve algoritma hatası vardır. 3) Derin öğrenme çerçevesindeki teknik hatanın çoğunluğu tasarım hatası (% 24.07 - % 65.27), bunu ihtiyaç hatası (% 7.09 - % 31.48) ve algoritma hatası (% 5.62 - % 20.67) izlemektedir. Bazı projelerde, uyumluluk hatası %10'dan fazladır (Tablo 2). Bu bulguların derin öğrenme çalışmalarını olumsuz etkilediği vurgulanmıştır.

Tablo 2: Her bir derin öğrenme çerçevesinin teknik hatalarının kendi içinde dağılımı [29]

| | TensorFlow | Keras | Caffe | PyTorch | MXNet | CNTK | DL4J |
|----------------|------------|--------|--------|---------|--------|--------|--------|
| %design | 57.03% | 24.07% | 48.75% | 59.73% | 63.13% | 65.27% | 55.90% |
| %requirement | 17.56% | 7.40% | 5.62% | 12.80% | 11.01% | 7.41% | 20.67% |
| %algorithm | 7.09% | 31.48% | 10.00% | 10.45% | 10.16% | 10.53% | 13.92% |
| %compatibility | 3.78% | 35.18% | 11.87% | 7.37% | 2.96% | 3.95% | 0.21% |
| %documentation | 1.27% | 0.00% | 15.62% | 0.81% | 0.42% | 0.83% | 0.42% |
| %test | 7.70% | 0.00% | 3.12% | 4.61% | 3.81% | 4.50% | 0.63% |
| %defect | 5.53% | 1.85% | 5.00% | 4.20% | 8.47% | 7.48% | 8.22% |

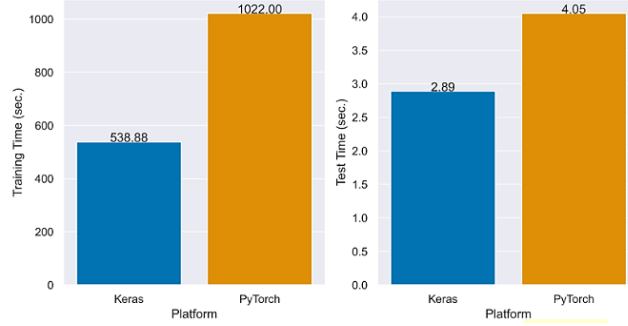
Yapıcı ve arkadaşı [35] Torch, Theano, Caffe, Caffe2, MXNet, Keras, TensorFlow ve Computational Network Tool Kit (CNTK) gibi en sık kullanılan DL çerçevelerinin performans karşılaştırmasını yapmışlardır (Şekil 25). Ayrıca kütüphanelerin GPU performanslarını da test etmişlerdir. TensorFlow kütüphanesinin tüm öbeklerde en iyi performansı verdiğini gözlemlemiştir.



Şekil 25: Derin öğrenme kütüphanelerinin öbek büyüklüğü ve iterasyon karşılaştırması [34]


Kabakuş'un [27] gerçekleştirdiği çalışmada Keras ve Pytorch derin öğrenme çerçeveleri farklı mimariler kullanılarak karşılaştırılmıştır. Şekil 26'da CNN için Keras ve PyTorch için eğitim ve test süreleri ve doğruluğu verilmiştir. Keras PyTorch'a kıyasla hem daha hızlı sonuç vermiştir hem de doğruluğu daha yüksek çıkmıştır.

| Platform | Accuracy (%) |
|----------|--------------|
| Keras | 78.43 |
| PyTorch | 76.54 |



Şekil 26: VGG16 ile Keras ve PyTorch karşılaştırması [27]

Mahmud ve arkadaşının [51] yaptığı çalışmada DL araçlarının göreceli karşılaştırması sunulmuştur (Şekil 27). Yapılan çalışmada Google Trend' de derin öğrenme araçlarının aranma oranı beş yıllık dönemde araştırılmıştır. Son yıllara doğru Keras ve TensorFlow' un popülerliğinin arttığı gözlenmiştir (Şekil 27.a). Yine aynı çalışmada arXiv'deki makalelerde 2020'nin ilk çeyreğinde bahsedilme oranları ele alınmıştır. TensorFlow, PyTorch ve Keras en çok bahsedilen çerçevelerdir (Şekil 27.b). GitHub üzerindeki popülerlik araştırmasında ise yine TensorFlow en çok ilgiyi gören çerçeve olmuştur. Keras ve Caffe'nin onu takip ettiği gözlenmiştir (Şekil 27.c). Keras diğer çerçevelerle uyumlu çalışma anlamında en esnek olan araç olarak belirtilmiştir (Şekil 27.d). Son olarak bu çalışmada donanım tabanlı ölçeklenebilirliğe vurgu yapılmıştır. Gelecekte DL sistemleri için donanımsal gelişmelerin önem kazanacağı ifade edilmiştir (Şekil 27.e)



Şekil 27: a) Google Trendlerinde yıllara göre aranma, b) 2020'nin ilk çeyreğinde gönderilen makale sayısına göre, c) github toplulukları, d) birlikte çalışabilirlik, e) donanım tabanlı ölçeklendirilebilirlik [51]

Sonuç olarak TensorFlow şu anda en popüler Derin Öğrenme çerçevelerinden biridir. Keras, daha basit bir ara yüz sağlamak için TensorFlow'un üzerinde çalışan yüksek seviyeli bir API olarak sunulmuştur. Caffe, görüntü işleme alanına yönelik bir başka popüler Derin Öğrenme çerçevesidir, PyTorch ise daha genç bir çerçevedir ancak popülerlik kazanmakta ve TensorFlow'un rakibi olarak kabul edilmektedir. Bahsettiğimiz bu çerçeveler, geliştiriciler tarafından model eğitimi ve çıkarım için en çok kullanılan çerçevelerdir [50]. Derin öğrenme çerçeveleri her geçen gün geliştirilmektedir. Geliştirmelerin artması daha yüksek performans, daha az kaynak kullanımı, daha kolay uygulanabilirlik gibi amaçlar taşımaktadır. Bununla beraber araçların sayısının artması kafa karışıklığı ve uygulama seçim zorluğu getirmektedir. Karmaşayı engellemek ve tercihleri olumlu yönde etkilemek için çerçevelerin kıyaslandığı araştırma çalışmaları yapılmaktadır. Gerçekleştirdiğimiz bu çalışmayla derin öğrenme alanına geniş bir bakış açısı sunulmuştur. Literatürde ilgili alanda yapılan çalışmalar karşılaştırmalı bir şekilde ele alınmıştır. Derin öğrenme çalışmaları özellikle bulut tabanlı platformlara doğru kaymaktadır. Bir diğer önemli platform ise IoT ve mobil algılama çalışmalarıdır. Bundan sonraki süreçte araştırmacıların bulut platformların derin öğrenme çalışmalarındaki performanslarını kıyaslayan çalışmalara yöneleceği düşünülmektedir.

4 Beyanname

4.1 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

4.2 Yazarların Katkıları

Süleyman AKTÜRK: Derleme için fikirlerin oluşturulması, araştırma sırasında literatür taraması ile ilgili sorumluluk almak, yazının tümü veya asıl bölümün oluşturulması için sorumluluk almak, makaleyi teslim etmeden önce sadece imla ve dil bilgisi açısından değil aynı zamanda entelektüel içerik açısından yeniden çalışma yapmak.

Sorumlu Yazar Kasım SERBEST: Bulguların mantıklı açıklanması ve sunumu için sorumluluk almak, araştırma sırasında literatür taraması ile ilgili sorumluluk almak, yazının tümü veya asıl bölümün oluşturulması için sorumluluk almak, makaleyi teslim etmeden önce sadece imla ve dil bilgisi açısından değil aynı zamanda entelektüel içerik açısından yeniden çalışma yapmak.

Kaynakça

- [1] E. Şimşek, Ö. Barış, and G. tümüklü Özyer, "Foto-kapan Görüntülerinde Hareketli Nesne Tespiti," *Erzincan Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 12, no. 2, pp. 902–919, Aug. 2019, doi: 10.18185/erzifbed.509571.
- [2] E. Kiliç, S. Öztürk, E. Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği, A. Kelimeler Evrişimli Sinir Ağları, A. Sayımı, and H. Görüntüleme, "İnsansız Hava Aracı Görüntülerinde Evrişimli Sinir Ağı Kullanarak Araç Sayımı için Yeni Bir Haritalama Yöntemi."
- [3] Ö. Er and H. Ş. Bilge, "Bir Küçük Nesne Tespit Zorluğu Olarak Hava Görüntülerinden Araç Tespiti Vehicle Detection From Aerial Imagery As A Small Object Detection Difficulty VERİ BİLİMİ DERGİSİ www.dergipark.gov.tr/veri," Jan. 2021. Accessed: Mar. 29, 2021. [Online]. Available: www.dergipark.gov.tr/veri.
- [4] X. Wu, D. Sahoo, and S. C. H. Hoi, "Recent advances in deep learning for object detection," *Neurocomputing*, vol. 396, pp. 39–64, 2020, doi: 10.1016/j.neucom.2020.01.085.

- [5] A. Şeker, B. Diri, and H. H. Balık, “Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme,” *Gazi Mühendislik Bilim. Derg.*, vol. 3, no. 3, pp. 47–64, Dec. 2017, Accessed: May 18, 2021. [Online]. Available: <https://dergipark.org.tr/en/pub/gmbd/372661>.
- [6] F. Chollet, *Deep Learning with Phyton*. 2018.
- [7] F. DOĞAN and İ. TÜRKOĞLU, “Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme,” *DÜMF Mühendislik Derg.*, vol. 10, no. 2, pp. 409–445, Jun. 2019, doi: 10.24012/dumf.411130.
- [8] V. V. Nabiyev, “Yapay Zeka (6. baskı),” *Ankara: Seçkin Yayıncılık*, 2021.
- [9] Prof.Dr. Çetin Elmas, *Yapay Zeka Uygulamaları*, 4th ed. Ankara: Seçkin Yayıncılık, 2018.
- [10] S. Murat, B. Mühendisliği, A. Dalı, and Y. Lisans, “İNSANSIZ HAVA ARACI GÖRÜNTÜLERİNDEN DERİN ÖĞRENME YÖNTEMLERİYLE NESNE TANIMA YÜKSEK LİSANS TEZİ,” Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, 2021. Accessed: May 02, 2021. [Online]. Available: <http://openaccess.maltepe.edu.tr/xmlui/handle/20.500.12415/7379>.
- [11] N. Gürsakal, “Makine Öğrenmesi,” *Baskı, Bursa Dora Basım Yayın Dağıtım Ltd. Şti*, 2018.
- [12] E. Öztemel, “Yapay sinir ağları,” *PapatyaYayıncılık, İstanbul*, 2003.
- [13] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553. Nature Publishing Group, pp. 436–444, May 27, 2015, doi: 10.1038/nature14539.
- [14] R. Elshawi, A. Wahab, A. Barnawi, and S. Sakr, “DLBench: a comprehensive experimental evaluation of deep learning frameworks,” *Clust. Comput. J. Networks, Softw. Tools Appl.*, p. 1, 2021, doi: 10.1007/s10586-021-03240-4.
- [15] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” in *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017*, Mar. 2018, vol. 2018-Janua, pp. 1–6, doi: 10.1109/ICEngTechnol.2017.8308186.
- [16] C. Min, J. Xu, L. Xiao, D. Zhao, Y. Nie, and B. Dai, “Attentional graph neural network for parking-slot detection,” *IEEE Robot. Autom. Lett.*, vol. 6, no. 2, pp. 3445–3450, Apr. 2021, doi: 10.1109/LRA.2021.3064270.
- [17] I. Gogul and V. S. Kumar, “Flower species recognition system using convolution neural networks and transfer learning,” Oct. 2017, doi: 10.1109/ICSCN.2017.8085675.
- [18] Ö. İnik and E. Ülker, “Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri,” *Gaziosmanpaşa Bilim. Araştırma Derg.*, vol. ISSN, no. 6.3, 2017.
- [19] J. S. Dramsch, “70 years of machine learning in geoscience in review,” Jun. 2020, doi: 10.1016/bs.agph.2020.08.002.
- [20] M. Yani, B. Irawan, and C. Setiningsih, “Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry’s Nail,” in *Journal of Physics: Conference Series*, May 2019, vol. 1201, no. 1, doi: 10.1088/1742-6596/1201/1/012052.
- [21] N. Nabiyev and S. Malekzadeh, *Anomalous Sound Localization Estimation*. 2021.
- [22] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [23] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Adv. Neural Inf. Process. Syst.*, vol. 25, pp. 1097–1105, 2012.
- [24] M. D. Zeiler and R. Fergus, “Visualizing and understanding convolutional networks,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2014, vol. 8689 LNCS, no. PART 1, pp. 818–833, doi: 10.1007/978-3-319-10590-1_53.
- [25] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” Sep. 2015, Accessed: May 18, 2021. [Online]. Available: <http://www.robots.ox.ac.uk/>.
- [26] G. Nguyen *et al.*, “Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey,” *Artif. Intell. Rev.*, vol. 52, pp. 77–124, 2019, doi: 10.1007/s10462-018-09679-z.

- [27] A. T. KABAKUŞ, “A Comparison of the State-of-the-Art Deep Learning Platforms: An Experimental Study,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 3, no. 3, pp. 169–182, Sep. 2020, doi: 10.35377/saucis.03.03.776573.
- [28] K. Dinghofer and F. Hartung, “Analysis of Criteria for the Selection of Machine Learning Frameworks,” in *2020 International Conference on Computing, Networking and Communications, ICNC 2020*, Feb. 2020, pp. 373–377, doi: 10.1109/ICNC47757.2020.9049650.
- [29] J. Liu, Q. Huang, X. Xia, E. Shihab, D. Lo, and S. Li, “Is Using Deep Learning Frameworks Free? Characterizing Technical Debt in Deep Learning Frameworks,” in *2020 IEEE/ACM 42nd International Conference on Software Engineering: Software Engineering in Society (ICSE-SEIS)*, 2020, pp. 1–10.
- [30] “Neden TensorFlow.” <https://www.tensorflow.org/about?hl=tr> (accessed May 19, 2021).
- [31] M. Abadi *et al.*, “TensorFlow: A system for large-scale machine learning,” 2016.
- [32] “TensorFlow Lite | Mobil ve Uç Cihazlar için Makine Öğrenimi.” <https://www.tensorflow.org/lite/?hl=tr> (accessed May 19, 2021).
- [33] “Neden Keras’ı seçmelisiniz?” https://keras.io/why_keras/ (accessed May 19, 2021).
- [34] The Theano Development Team *et al.*, “Theano: A Python framework for fast computation of mathematical expressions,” May 2016, Accessed: May 19, 2021. [Online]. Available: <http://arxiv.org/abs/1605.02688>.
- [35] M. M. Yapıcı and N. Topaloğlu, “Performance comparison of deep learning frameworks,” 2021. Accessed: May 18, 2021. [Online]. Available: <https://dergipark.org.tr/tr/pub/ci>.
- [36] A. Uçar, Ö. H. Üniversitesi, and M. Bölümü, “Derin öğrenmenin Caffe kullanılarak grafik işleme kartlarında değerlendirilmesi Mehmet Safa BİNGÖL,” 2018.
- [37] G. Al-Bdour, R. Al-Qurran, M. Al-Ayyoub, and A. Shatnawi, “Benchmarking open source deep learning frameworks,” *Int. J. Electr. Comput. Eng.*, vol. 10, no. 5, pp. 5479–5486, 2020, doi: 10.11591/ijece.v10i5.pp5479-5486.
- [38] “The Microsoft Cognitive Toolkit - Cognitive Toolkit - CNTK | Microsoft Docs.” <https://docs.microsoft.com/tr-tr/cognitive-toolkit/> (accessed May 20, 2021).
- [39] “CNTK_2_7_Release_Notes - Bilişsel Araç Seti - CNTK | Microsoft Docs.” https://docs.microsoft.com/en-us/cognitive-toolkit/releasenotes/cntk_2_7_release_notes (accessed May 20, 2021).
- [40] “pytorch/pytorch: Tensors and Dynamic neural networks in Python with strong GPU acceleration.” <https://github.com/pytorch/pytorch> (accessed May 20, 2021).
- [41] T. Chen *et al.*, “MXNet: A Flexible and Efficient Machine Learning Library for Heterogeneous Distributed Systems,” Dec. 2015, Accessed: May 20, 2021. [Online]. Available: <http://arxiv.org/abs/1512.01274>.
- [42] S. Tokui, K. Oono, S. Hido, and J. Clayton, “Chainer: a Next-Generation Open Source Framework for Deep Learning.”
- [43] “Chainer – A flexible framework of neural networks — Chainer 7.7.0 documentation.” <https://docs.chainer.org/en/stable/> (accessed May 20, 2021).
- [44] “chainer/chainer: A flexible framework of neural networks for deep learning.” <https://github.com/chainer/chainer> (accessed May 20, 2021).
- [45] W. Dai and D. Berleant, “Benchmarking contemporary deep learning hardware and frameworks: A survey of qualitative metrics,” in *Proceedings - 2019 IEEE 1st International Conference on Cognitive Machine Intelligence, CogMI 2019*, Dec. 2019, pp. 148–155, doi: 10.1109/CogMI48466.2019.00029.
- [46] S. Bahrapour, N. Ramakrishnan, L. Schott, and M. Shah, “Comparative Study of Deep Learning Software Frameworks,” Nov. 2015, Accessed: May 19, 2021. [Online]. Available: <http://arxiv.org/abs/1511.06435>.
- [47] Y. Wu *et al.*, “A Comparative Measurement Study of Deep Learning as a Service Framework,” *ieeexplore.ieee.org*, doi: 10.1109/TSC.2019.2928551.
- [48] J. Liu *et al.*, “Usability Study of Distributed Deep Learning Frameworks For Convolutional Neural Networks,” 2018. Accessed: May 21, 2021. [Online]. Available: <https://caffe2.ai/>.

- [49] S. Shi, Q. Wang, and X. Chu, “Performance Modeling and Evaluation of Distributed Deep Learning Frameworks on GPUs,” in *2018 IEEE 16th Intl Conf on Dependable, Autonomic and Secure Computing, 16th Intl Conf on Pervasive Intelligence and Computing, 4th Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress(DASC/PiCom/DataCom/CyberSciTech)*, 2018, pp. 949–957, doi: 10.1109/DASC/PiCom/DataCom/CyberSciTec.2018.000-4.
- [50] Y. Dai, R. Zhang, R. Xue, B. Liu, and T. Li, “Towards Efficient Execution of Mainstream Deep Learning Frameworks on Mobile Devices: Architectural Implications,” *IEEE Trans. Comput. Des. Integr. Circuits Syst.*, vol. 40, no. 3, pp. 453–466, Mar. 2020, doi: 10.1109/TCAD.2020.3003233.
- [51] M. Mahmud, M. S. Kaiser, T. M. McGinnity, and A. Hussain, “Deep Learning in Mining Biological Data,” *Cognitive Computation*, vol. 13, no. 1. Springer, p. 3, Jan. 01, 2021, doi: 10.1007/s12559-020-09773-x.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

YOLO – Based Waste Detection

Kenan Erin¹ , Bünyamin Bingöl² , Barış Boru³ 

¹ Mechatronics Engineering Department, Sakarya University of Applied Sciences,

² Electrical and Electronics Engineering Department, Sakarya University of Applied Sciences,

³ Mechatronics Engineering Department, Sakarya University of Applied Sciences,

ABSTRACT

The management of recycling wastes is one of the most important issues because of the increasing production rates. The collecting and recycling of waste are also becoming more crucial for economic and environmental reasons because landfill space is becoming more and more limited. Automatic sorting systems are defined as systems that separate recyclable waste materials with robotic manipulators where human intervention is minimal. In this study, while determining the type of waste, the location of the waste will be determined in 3D with a depth camera and image processing techniques.

Keywords: YOLO, RealSense, Waste Recognition, 3D Position Measurement

1 Introduction

One of the biggest issues facing developed nations is the separation of recyclable materials. Waste, particularly plastic waste, is growing daily. Increased plastic manufacture leads to some issues, including ecological, water, and air pollution. It is possible to recycle waste and lessen adverse environmental effects by practicing effective recycling.

The two categories of recycling sorting procedures are manual sorting and automatic sorting. Large recycling operations cannot use manual sorting processes, which are frequently described as workers visually identifying and classifying recyclables. Automatic separation systems are systems where human intervention is minimal and the efficiency obtained from recycling materials is high.

Systems for separating plastic, paper, metal, etc. are an essential step in the trash recycling process. A system with high accuracy will recycle better. While a badly constructed system results in significant cost losses, a well-recycled system ensures the reuse of waste and energy generation.

With the research studies carried out in recent years, reversible separation systems have an important place in the literature today. The techniques applied in waste separation and the results obtained are shown in the literature review. Studies on the existing literature can be summarized as follows. Tatzer et al. [1] carried out the detection of waste materials by the hyperspectral imaging method in their study. In the experimental setup, paper and cardboard wastes from the separation process were used. After the study, they separated paper and cardboard with a success rate of over 90%. Scavino et al. [2] developed a prototype mechanism for the automatic detection and separation of plastic bottle waste on the conveyor. They can overcome the problems of detecting low light and deformed bottles thanks to the hardware they utilized in the study and the software they developed. In the study, which was tested on 50 plastic materials, a successful classification of 97% was obtained. Ozkan et al. [3] provided image processing-based separation of recycled plastic materials in their study. Images that were taken via camera were first used to identify plastic wastes, and then various methods of image processing were used to remove noise from the image. Support Vector Machine (SVM) algorithm was used to classify plastic waste, and the successful classification rate was determined to be approximately 90%. Meng and Chu [4] carried out waste detection on the dataset in their study. The authors obtained 10108

* Corresponding Author's email: kenanerin@subu.edu.tr

images with dataset augmentation methods for 2527 images. Then, they used the SVM+HOG, Simple CNN, Resnet50, and HOG+CNN algorithms to separate this dataset into five different categories: cardboard, glass, metal, plastic, and general waste. After comparing the performance of the algorithms they had used, they came to the conclusion that ResNet50 had achieved the highest level of success (92.25%). Li and Wei [5] detected waste on the data set they collected from the camera in their study. They extracted the data set they collected to 20000 pictures with various methods. Then, with the Inception-V3 model, they classified the pictures into 4 categories as recyclable waste, household waste, hazardous waste and general waste. At the end of the study, they determined training success as 99.3% and test success as 93.2%. In their study, Jingyi et al. [6] performed waste recognition and separation with a mobile manipulator. First, they detected the garbage with the algorithm they created on the TACO data set in the literature, which they called GarbageNet. Then, in order for the mobile manipulator to separate the waste, they determined the position of the waste and the grip position on the 3D image. At the end of the study, they revealed that the waste collection process in closed areas works successfully with the mobile manipulator.

In our study, the images captured by the camera were used to detect waste in real time and identify its location. First, training was conducted for 4 different wastes, metal, paper, glass, and plastic, over the data set. Then YOLOv4 algorithm was used for real-time work in waste detection. Using the 3D camera, the location of the image in 3D and the center of the image, whose type was identified, were both determined.

2 Material and Method

In this section, the algorithm and hardwares used to solve the problem are explained.

2.1 YOLO (You Look Only Once)

The YOLOv4 algorithm was used in problem-solving. The most important reason why the YOLOv4 algorithm is preferred is that its performance is quite high compared to its others versions, as shown in Figure 1.




Figure 1. Comparison of YOLO Models [1]

YOLO, an object detection technique used for real-time image processing, has lately gained popularity. Figure 3 shows its general structure. The YOLO Algorithm can predict faster than other algorithms. YOLO applies a CNN (Convolutional Neural Network) to the picture, divides the picture into grids, calculates bounding boxes and the appropriate confidence score for each grid, and calculates the bounding boxes with the estimated confidence score [7]. Figure 2 shows how the rules of the Yolo algorithm limit the detection of objects in an image. These boundaries are indicated by rectangles between detected objects [8].

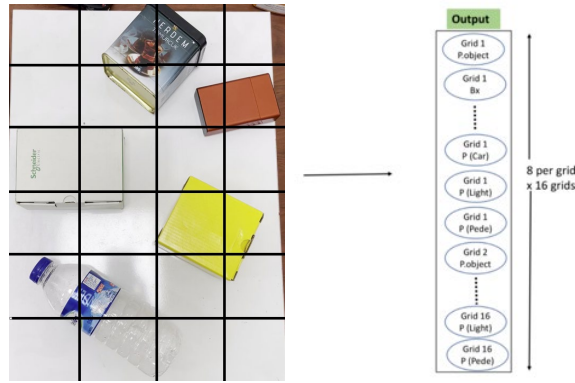


Figure 1: Structure of the YOLO algorithm

The Yolo algorithm can process images at around 40-90 FPS (Frames per second). Therefore, it is very fast compared to other methods. This shows that a video can be processed by the Yolo Algorithm in real-time with a delay of a few milliseconds [7].

Compared to another object detection method, Yolo is said to be 1000 times faster than R-CNN and 100 times faster than Faster R-CNN.

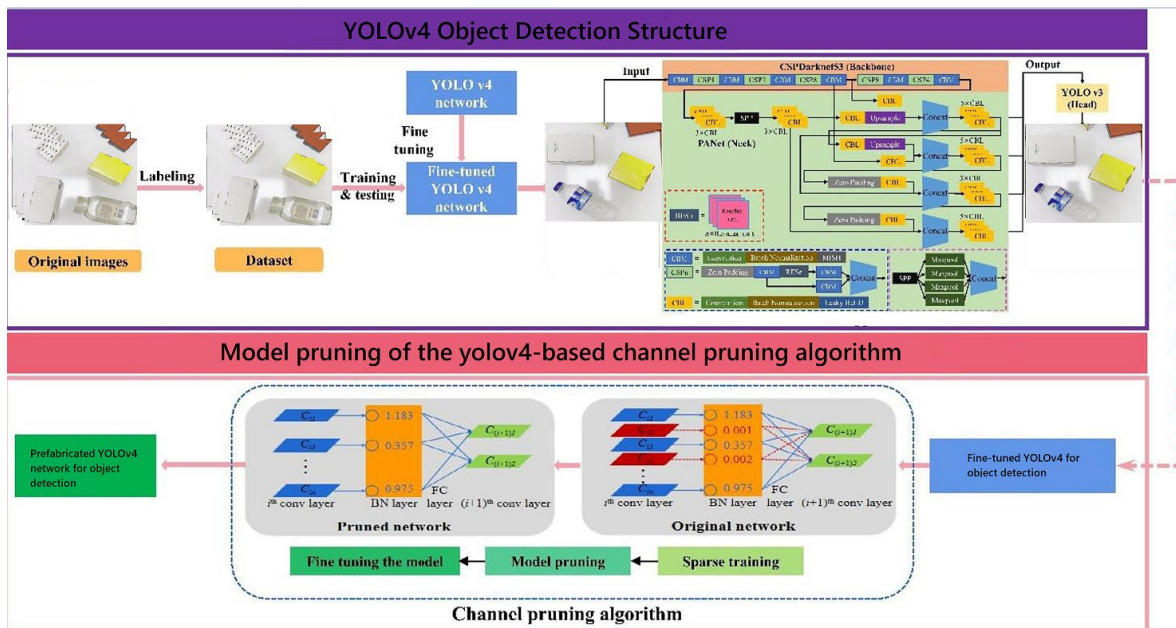


Figure 2: YOLOv4 Structure

2.2 3D Position Measurement

To separate the detected waste using a manipulator, the location of the waste must be known in 3 dimensions. In the study, the Intel RealSense D415 camera, which is a 3D camera, was used to detect the location of the waste. The camera used is shown in figure 4.



Figure 4: Intel RealSense 3D Camera

The transition from the 2D coordinate system to the 3D coordinate system is shown in Figure 5. In the picture shown in Figure 2, the coordinates of the 2-dimensional picture are given as (X_i, Y_i) . Then,

from the (X_i, Y_i) coordinates, the 3D coordinate (X_s, Y_s, Z_s) system was switched. X_s and Y_s positions are calculated in equation 1, Z_s position is calculated directly by the camera. In Equation 1, (c_x, c_y) represents the optical center of the camera and (f_x, f_y) represents the focal length of the camera. The c_x, c_y, f_x, f_y are constant parameters and these all adjusted by camera calibration.

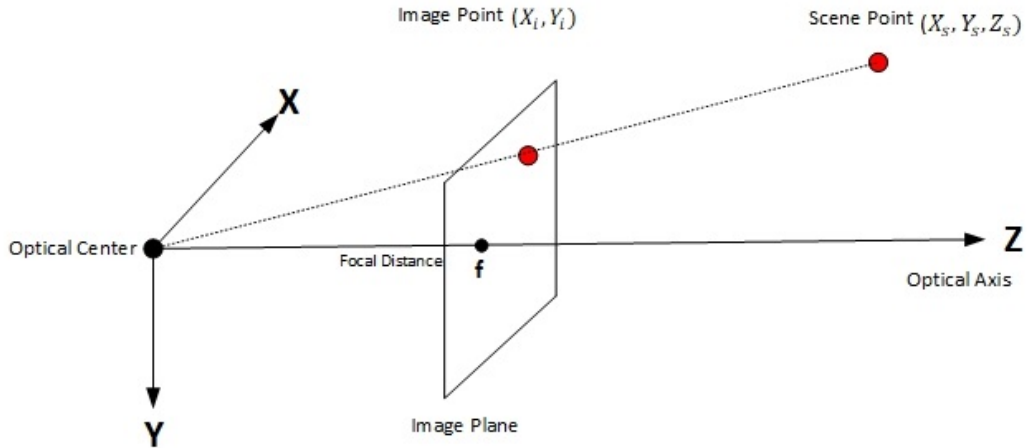


Figure 5: Transition from picture coordinate system to camera coordinate system.

$$X_s = Z_s * \frac{X_i - c_x}{f_x} \tag{1}$$

$$Y_s = Z_s * \frac{Y_i - c_y}{f_y}$$

2.3 Data Set

Data size is a big factor in deep learning models. The more data, the better the model performs. For this reason, the data set needs to be enlarged. The created data set is deformed such as adding blur and noise with image processing techniques, thus providing a better performance of the model even under difficult conditions. In addition, horizontal mirroring and vertical mirroring were applied. The classes and dimensions of the data set used are shown in Table 1.

Table 1: Size of Classes in the Dataset.

| Class | Data | Size | Total |
|---------|-------|------|-------|
| Paper | Train | 552 | 678 |
| | Test | 126 | |
| Metal | Train | 332 | 396 |
| | Test | 63 | |
| Glass | Train | 378 | 498 |
| | Test | 120 | |
| Plastic | Train | 324 | 402 |
| | Test | 78 | |

All data to be trained are divided into two sets, “training” and “test” data, as shown in Table 2. With these allocated data, the training was started and the training results were explained in detail in Chapter 4.

Table 2: Proportions of "Training" and "Testing" Datasets to be Included in Training.

| Data | Size (%) |
|-------|-------------|
| Train | 1.580 (%80) |
| Test | 394 (%20) |

3. Real-Time Waste Detection

In the study, real-time waste detection was performed after data set training and location detection. The experimental setup to detect waste is shown in Figure 6.




Figure 6: The experimental setup

In the experimental setup, 4 different wastes, metal, paper, glass, and plastic, were detected by using pyrealsense2, OpenCV libraries, and YOLOv4 algorithm on the images taken from the camera in the python environment. The study was tested on the Nvidia Jetson AGX Xavier card, the center and 3D position of the waste were calculated for the decomposition process. Real-time waste detection with images taken from the camera is shown in Figure 7.

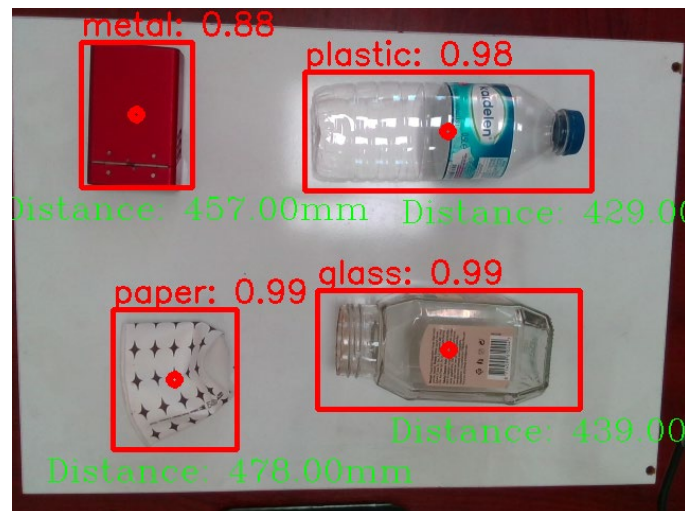


Figure 7: Real-Time Waste Detection

4 Results and Discussion

Within the scope of the study, YOLOv4 and YOLOv4-Tiny algorithms were used and the best result was obtained from the YOLOv4 model. In this model, images with a resolution of 416 x 416 were used as input. The training was completed in 1,000 epochs. Accuracy, verification accuracy, loss, and verification loss results obtained as a result of the training are shown in Table 3.

Table 3: Training Results

| Model | Accuracy | Verification Accuracy | Loss | Verification Loss |
|-------------|----------|-----------------------|--------|-------------------|
| YOLOv4-Tiny | 0.9265 | 0.9296 | 0.7984 | 0.7565 |
| YOLOv4 | 0.9571 | 0.9587 | 0.7798 | 0.7307 |

Confusion matrix, recall, precision, f-1 score, and intersect over union (IoU) were used as evaluation criteria.

TP (True Positive): These are the cases where the actual value is 1 as well as the predicted value.

TF (True False): These are the cases where the actual value is 0 and the predicted value is not 0.

Accuracy is found by taking the arithmetic mean precision (mAP) of the average precision (AP) values of the classes. Equation 3 shows the formulas.

$$AP = \left(\frac{1}{n}\right) \sum_{Recall_i} Precision(Recall_i) = 1 \quad (3)$$

$$mAp = \frac{1}{|classes|} \sum_{c \in classes} \frac{\#TP(c)}{\#TP(c) + \#FP(c)}$$

Recall is known as the hit rate and is expected to be high. It is a measure of how much TP or TN the classifier has correctly estimated. Equation 4 shows how the sensitivity is calculated.

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

Precision is a measure of how accurate or incorrect is the prediction from all classes. Like recall, precision is expected to be high. Equation 5 shows how precision is calculated.

$$precision = \frac{TP}{TP + FP} \quad (5)$$

The classifier's performance is measured by the f-1 score. It is the harmonic mean of sensitivity and precision. Equation 6 shows how the f-1 score is calculated.

$$F1 = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (6)$$

The IoU is used for each bounding box to measure the overlap between the predicted bounding box and the actual bounding box. Figure 8 shows the structure.

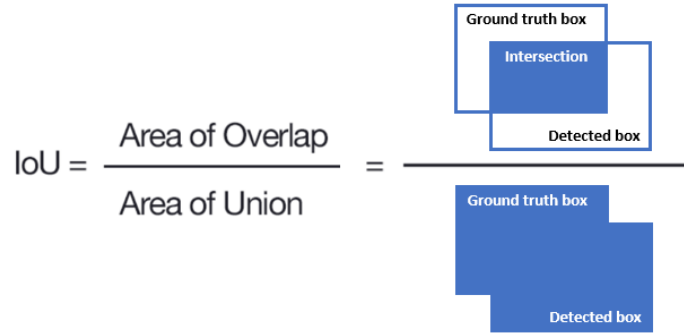


Figure 8: IoU Structure

The results of the evaluation are shown in Table 4, the confusion matrix of the model. Table 5 shows the classification results of the trained models.

Table 4: Confusion Matrix

| Models | Classes | TP | TF | AP(%) |
|-------------|---------|-----|-----|-------|
| YOLOv4-Tiny | Paper | 547 | 131 | 84 |
| | Metal | 276 | 120 | 62 |
| | Glass | 397 | 101 | 92 |
| | Plastic | 305 | 97 | 90 |
| YOLOv4 | Paper | 558 | 120 | 87 |
| | Metal | 294 | 102 | 68 |
| | Glass | 412 | 86 | 96 |
| | Plastic | 339 | 63 | 95 |

Table 5: Classification Result of Trained Model

| Model | Sensitivity | Precision | F1 | IoU(%) | mAP(%) |
|-------------|-------------|-----------|------|--------|--------|
| YOLOv4-Tiny | 0.91 | 0.63 | 0.74 | 74.56 | 81.56 |
| YOLOv4 | 0.90 | 0.91 | 0.92 | 78.36 | 90.23 |

According to the study's findings, the YOLOv4 algorithm was successful in detecting 4 different types of waste. In future studies, it is planned to create a prototype mechanism to separate the wastes coming from the real conveyor line with a robotic manipulator.

5. Declarations

5.1 Funding source

This study was financed by Sakarya University of Applied Sciences BAP coordinator with project number 022-2022.

5.2 Authors' Contributions

Kenan Erin : Design and implementation of the research, Analysis of the result, Writing of the manuscript.

Bünyamin Bingöl: Design and implementation of the research, Analysis of the result, Writing of the manuscript.

Barış Boru: Design and implementation of the research, Analysis of the result, Writing of the manuscript.

References

- [1] Tatzer, P., Wolf, M., Panner, T. (2005). Industrial application for inline material sorting using hyperspectral imaging in the NIR range. *Real-Time Imaging*, 11(2), 99-107.
- [2] Scavino, E., Wahab, D. A., Hussain, A., Basri, H., Mustafa, M. M. (2009). Application of automated image analysis to the identification and extraction of recyclable plastic bottles. *Journal of Zhejiang University SCIENCE A*, 10(6), 794-799.
- [3] Özkan, K., Ergin, S., Işık, Ş., & Işıklı, İ. (2015). A new classification scheme of plastic wastes based upon recycling labels. *Waste Management*, 35, 29-35.
- [4] Meng, S., & Chu, W. T. (2020, February). A study of garbage classification with convolutional neural networks. In *2020 Indo-Taiwan 2nd International Conference on Computing, Analytics and Networks (Indo-Taiwan ICAN)* (pp. 152-157). IEEE.
- [5] Cao, L., & Xiang, W. (2020, June). Application of convolutional neural network based on transfer learning for garbage classification. In *2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC)* (pp. 1032-1036). IEEE.
- [6] Liu, J., Balatti, P., Ellis, K., Hadjvelichkov, D., Stoyanov, D., Ajoudani, A., & Kanoulas, D. (2021, July). Garbage collection and sorting with a mobile manipulator using deep learning and whole-body control. In *2020 IEEE-RAS 20th International Conference on Humanoid Robots (Humanoids)* (pp. 408-414). IEEE.
- [7] S. Shinde, A. Kothari, and V. Gupta, "YOLO based Human Action Recognition and Localization," in *Procedia Computer Science*, Jan. 2018, vol. 133, pp. 831–838, doi: 10.1016/j.procs.2018.07.112.
- [8] Hendry and R. C. Chen, "Automatic License Plate Recognition via sliding-window darknet-YOLO deep learning," *Image Vis. Comput.*, vol. 87, pp. 47–56, Jul. 2019, doi: 10.1016/j.imavis.2019.04.007



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

A Review of Visual Attention Research Using Eye-Tracking Technologies

Ozgun Ahmet EFETURK^{1,2}, Gizem TURGUT² , Hamid ASADI DERESHGI^{1,3*} , Aziz YILMAZ^{1,4}

¹Artificial Intelligence Studies, Application and Research Center (ArelMED-I), Istanbul Arel University, 34537 Istanbul, Turkey

²Department of Psychology, Istanbul Arel University, 34537 Istanbul, Turkey

³Department of Biomedical Engineering, Istanbul Arel University, 34537 Istanbul, Turkey

⁴Department of Electrical and Electronics Engineering, Istanbul Arel University, 34537 Istanbul, Turkey

ABSTRACT

The purpose of this review paper was to examine the study on visual attentional bias processes and eye movements in this process and evaluate individuals' responses to positive and negative stimuli. The selective attention processes that individuals show to environmental stimuli and the eye movement behaviors. Accordingly, these are associated with autonomous defense mechanisms that occur during survival. This situation may differ according to various characteristics of the individual. Another differentiated situation is the individual's psychological well-being in the attention shift process. Many studies have shown that individuals with anxiety-related disorders or depression show more intense sensitivity to threatening stimuli. The eye-tracking method is important for characterizing and detecting individual differences reflected in the individual's attention switching process and attentional bias. Consequently, the differences in the reaction time of individuals with high levels of anxiety/depression were negative stimuli compared to other (positive, neutral) stimuli. Currently, the processes of attentional bias caused by threatening factors in individuals continue to be examined. Information on this situation is quite important for the detection and treatment processes of many psychological diseases. Therefore, the observation of eye movement behavior that is significant for the detection of other psycho-physiological conditions (cognitive, visual fatigue) that cause attentional bias.

Keywords: Eye tracking, attentional bias, anxiety, depression, addiction, eating disorder

1 Introduction

Attention, filtering out other perceptible information and selectively focusing on a piece of information creates a kind of arousal state that can deal with limited processing deficits [1]. Attention can be considered an internal force that spontaneously or voluntarily creates a mental, sensory or dynamic expectation and supports the perception of stimuli and the production of responses [2]. Additionally, according to the network attention model developed by [3], there are three interrelated and simultaneously differentiated components of attention (see Table 1), namely, alertness, orientation, and executive control. Understanding this model is important to the explanation of any attentional process, such as attentional bias. Another important phenomenon of attention is attentional shifting and orienting processes. For instance, the eyes and head can be used to look at an object voluntarily. This is mostly referring to overt attention. Additionally, there is no need for eye and head movement for covert attention. These processes are evolutionarily developed [4-5]. Attention in nature is the result of a long cognitive evolutionary

* Corresponding Author's email: hamidasadi@arel.edu.tr

process of living organisms, it is a fundamental activity that concerns the survival of all life forms. This process plays a role in regulating the complex mental process of humans during the perception of environmental stimuli. It includes all cognitive steps like decision-making skills. Amongst evolutionary processes, attention primarily affects the perception, selection and adjustment of environmental stimuli. It is decisive for the continuation and evolution of the species because it helps to settle at the desired point in the environment and to detect the prey of predators or potential competitors [6]. Cisler et al. (2010) in a comparison that examined attentional bias towards threatening and neutral stimuli, it was found that they presented a different distribution of attention towards threatening stimuli. The mechanism of attentional bias is understood by examining three interrelated aspects. The first is to observe the components of attentional bias, second, mechanisms for mediating the expression of these components, and finally, the stage of information processing in which mediated mechanisms operate. The components of attentional bias refer to observable traits and measure attentional bias (such as what attentional bias looks like). The observable characteristics of attention bias are stated as facilitated attention (more rapid recognition of a threatening stimulus than a neutral stimulus), difficulty in disengagement (longer separation time from the threatening stimulus compared to the neutral stimulus), and attentional avoidance (tendency to distract attention from the threatening stimulus and to deal with other stimuli) [7].

Table 1: Summary of attention networks model.

| Attention Networks | Components | Definition |
|--------------------|---------------------------------|--|
| Alerting | Sustained, Alertness | The ability to allocate attention for a long time. |
| Orienting | Divided and Selective Attention | The capability to limit attention to a specific potential sensory input. |
| Executive | Attention Shifts and Control | The ability to regulate attention. |

The World Health Organization has declared that depression and anxiety are mental disorders that have the highest prevalence among countries and cultures. While anxiety and depression disturb an individual's performance, a high percentage of people do not pay attention to them. Attentional bias towards threatening stimuli plays a significant role in the diagnostic and treatment processes of anxiety and depression-related diseases [7-8]. Today, thanks to technological advances, the amount of information that people get has increased and exposes them to more stimuli. The negative effects of this situation on people can turn into a variety of mental disorders. Another hypothesis regarding this issue is when other cognitive components are considered, it is reported that depression and anxiety-related disorders can interact with cognitive processes in a variety of ways [9].

This review paper has covered the paradigms and the results obtained regarding the attentional bias proposed in the open literature. Moreover, it gives some information about significant of engineering skills such as image processing and machine learning in the attention studies. The paper is organized as follows. The paradigms and factors affecting attentional bias presented in the open literature are provided in Sections 2 and 3, respectively. Finally, the concluding remarks are reviewed in Section 4.

2 Paradigms and Stimuli for Attention Bias Measurement

In order to better understand the processes of formation and correction of attentional bias, various tests have been developed in relation to traditional neuropsychological methods. The most common are; Dot-Probe Test [10], Visual Search Test [11], Modified Stroop Test [12], Spatial Cueing Test [13] and Attentional Blink Test [14]. During the Dot-Probe test, two images are displayed simultaneously (around 500 ms), one negative and the other positive or negative. After the presentation of two images, a marker (star, etc.) is displayed on the side of one of the images. With the right and left arrow keys, the participant is asked to indicate the direction of the signal. Attention bias inferences are made by comparing the signal time following the negative stimulus and the time of the displayed signal after the positive/neutral stimulus. During the task, the reaction time to the negative stimulus signal should be shorter than the positive/neutral stimulus. Various types of words (threatening and neutral) are shown in the changed Stroop test. Participants are invited to indicate their color no matter what the word means. Attentional biases are determined by comparing reaction times to threatening and neutral words.

The Stroop task is one of the most common measurement methods for measuring attention bias in anxiety. However, it cannot be considered the most ideal method because of its interpretative problems. In

addition, the spatial distribution of attention is difficult to measure. Visual Search Test was developed by Treisman (1977). Participants are asked to identify a target stimulus that is integrated into a distracting stimulus matrix. The Spatial Cueing Test was designed by Posner (1980). Participants are asked to look at the Centre Point on the screen. A negative stimulus and another positive/neutral stimulus are randomly displayed on the right and left of the dot, then the attention bias is measured based on changes in demonstrated attention. The Spatial Cueing test assesses if presenting participants with a target in the same position as the previous index influences the reaction time and the correct response rate. The task consists of three valid, neutral and invalid sub-dimensions. Valid attempts are those in which the target is displayed in the same location as the presented flag. Neutral tests are tests with no sign after the target. Invalid tests are tests in which the target is in the opposite direction of the signal presented. As expected in the results, the average reaction time should be faster on valid tests than on invalid tests. The Attentional Blink test demonstrates a fast and distracting flow of visual presentations. Two target stimuli (two different letters) are embedded in this stimulus stream. At the end of the presentation, participants should indicate if they have seen the target stimuli. In the emotional version of this task, the threat level of one of the two target stimuli is variable (e.g., one stimulus is threatening and the other is neutral). The expected responses from the applied tasks are summarized in Table 2.

Table 2. Summary of paradigms and measurement for attentional bias.

| Process of Measure | Task | Index of Attentional Bias |
|--------------------|---|---|
| Dot-Probe | Two stimuli at the same time, respond to target appearing after on threatening (congruent) or neutral (incongruent) location. | Faster or slower reaction times in threatened trials. |
| Spatial Cuing | One single stimuli (negative or neutral) react to a cued or uncued target. | Latency in reaction time for the negative stimulus. |
| Visual Search | Finding the threatening target in a series of neutral distractors or finding the neutral target in a series of threatening distractors. | Faster reaction on trial with threatening target stimuli, slower reaction on trial with neutral target stimuli. |
| Attentional Blink | Two stimulus (one of negative) in the slides of other stimulus. | Saliency and reaction time of the negative stimulus. |
| Modified Stroop | Name of the color of negative and neutral words. | Slower color naming for the negative words. |

Physiologic measures are also used to increase the validity and reliability of cognitive tests applied in attention studies. The eye-tracker method is the most widely used in studies on visual attention, and the other is the ERP (Event Related Potential) method with electroencephalography (EEG) [15]. In the eye tracker method, participants' responses to stimuli are examined by various metrics such as reaction times, saccade times, and fixation times [16]. In ERP studies, the N2-Posterior-Contralateral (N2PC) component, which is the most popular amongst the many ERP components, is used in attention studies [17].

3 Taxonomy of Previous Study

The data obtained with the eye tracking method makes it possible to measure the location where the eye is fixed in real-time during an experiment. These measures are important for understanding which cognitive processes are effective during the experiment [18].

3.1 Attentional Bias

Identifying the specific features of attention to a threatening stimulus is important for the psychophysiological measurement of anxiety and depression. Literature survey shows that there are many studies about the attentional bias. For example, Macdonald and Tatler (2017) carried out a study in which they examined the effects of eye movements and social perception during interaction in natural environments. Social roles were assigned to the participants by wearing a wearable eye tracker, and some were assigned the role of chef and some of them as a waiter. Consequently, it was observed that the average time to look at the given object was shorter when the roles were assigned than when the roles

were unassigned. The data obtained were interpreted as social contexts influencing eye behaviours [19]. Vazquez et al. (2018) conducted a study measuring the attention performance of patients with clinical depression before and after cognitive behavioural therapy and the application of positive psychology. Following the study, it was observed that after treatments were applied in attention performance and bias, positive outcomes were achieved relative to previous treatments [20]. A two-step research was conducted by Han et al. (2019). They focused on how the negative online news that people are exposed to on social media influences social confidence and helping behaviour. Following the first experience, they noticed that during the eye movement task performed, they were more inclined to show an attentional bias toward negative news and were more affected by it. In the second experiment, the positive news was presented to one group of participants as well as negative news to another group. The group with negative news was found to be less helpful in their behaviour. In the third phase of the experiment, headlines with neutral content were changed to negative, and one neutral and one negative were presented to participants. At the end of the third phase, participants were observed to display a negative cognitive bias, low aiding behaviour, and low social confidence after reading the negative headlines [21]. Hessels et al. (2019) investigated changes in one person's gaze as a function of the other person's facial expressions and the behaviour of the other person's gaze during face-to-face communication. The study was a two-step process. As a result of the first stage, during the communication, participants' eye movements were observed to be affected as they spoke and listened. Subsequent to the second phase, observed that eye movements did not change as a function of stimulus and that social context was more effective [22]. Shen et al. (2021) conducted a study to detect depression by analysing eye movement behaviour using the classification methodology. They collected information by asking participants to freely view three different emotional stimuli (happy, sad, neutral). Using the data classification method, they created a %77 successful estimation algorithm with the Support Vector Machine (SVM) [23].

3.2 Addiction

In recent years, substance addiction has increased. In particular, it is stated that substance abuse results from attentional bias that is characterized against substance-related stimuli [24-25]. The onset of lapse and relapse, which is common in addiction treatment processes, is explained by the dual process model. This model includes reflective and automatically evolving processes. Reflective processes require conscious decision-making. Methods such as cognitive behavioural therapy develop methods for preventing the reflexive process. Automated processes imply more attentive biases. It involves unconscious processes which make it difficult for people to concentrate on the environmental stimuli related to the substance and avoid paying attention to those stimuli [26]. Many studies have been and continue to be conducted with a view to developing methods to prevent the attentional bias that people develop with regard to substance-related stimuli. Parvaz et al. (2021) conducted a study on drug addicts to create a shift in bias with the Cognitive Reappraisal method of attention bias processes. Two groups of cocaine users and nonusers were included in this experiment. This experiment investigated spontaneous attentional bias toward drug-containing stimuli. This experiment was applied to the stimuli presented by closely monitoring the length of the participants' gaze and minimizing the expected confusion. Subsequent to the study, it was observed that the cognitive re-evaluation study applied during the experiment systematically reduced attention bias to substance-related stimuli [27].

3.3 Eating Disorders

Today, another behaviour pattern that has a high prevalence and has adverse physiological and psychological effects occurs with abnormal eating disorders [28]. Attention bias, which is a component of cognitive bias, is important for the diagnosis and prevention of eating disorders. Following studies on the efficacy of attention bias on eating disorders, studies have shown that people with eating disorders are sensitive to food stimuli [29]. Shafran et al. (2007) carried out an extensive study to explain the relationship between eating disorders and attentional biases in the first phase of the study, the clinical diagnosis of eating disorder (23 females) was studied, among them (19 females) they had a high level of anxiety, and as a control group; individuals with high, moderate and low anxiety (74 females) were included in the study.

In the second stage, persons with eating disorders (82 females) and healthy persons (44 females) were included. In both phases of the study, the probe point task was grouped and illustrated (in relation to food, form, and weight). Following the initial study, a related attentional bias was found in the images with negative diet and neutral weight in participants with eating disorders. At the end of the second step, the results indicated the results of the first step and, further, the attention bias to negative and neutral images was identified [30].

Popien et al. (2015) investigated the response of people with and without eating disorders to food-related stimulation. Participants were provided with high and low-calorie images. During the experiment, which lasted about 8 minutes, eye measurements were taken in both groups using an eye tracer. At the end of the study, it was observed that participant with binge eating was more likely to react to images containing food, regardless of whether they were high in calories or low, compared to controls [31]. Jose et al. (2022) compared individuals with High Body Dissatisfaction (HBD) to healthy individuals with Low Body Dissatisfaction (LBD), examining whether patients with Anorexia Nervosa (AN) have longer fixation duration and greater number of fixations in weight-related body regions. In this work, 66 women (25 with LBD, 18 with HBD and 23 AN) were participated in the experimental study. All of the participant were immersed in a virtual world with an avatar that had been embodied by their body measured. Participant's eye movement metrics was recorded with eye tracker features of the virtual reality headset. During the experiment researchers were focused on the area of interest of the weight related of scene and compared with non-related areas. Researchers were focused on the eye movements of participants and compared with whether their gaze on weight-related areas of the scene or not weight-related areas. Consequently, participant with anorexia nervosa have long duration and high number of fixation on weight-related areas than other groups of participant [32].

3.4 Cognitive Load

Eye tracking methods has shown to be effective for detecting cognitive load in attention studies. In the open literature, there are many studies about the correlation between cognitive load and attention. For example, Marandi et al. (2018) investigated the consideration of age-related long-term cognitive performance on eye fatigue. In this study, they observed longer fixation time, shorter saccade time and lower performance in other cognitive tests in older adults [33]. Yamada and Kobayashi (2018) developed an automatic learning model to detect auditory cognitive tasks and mental intensity using an eye monitoring method. In their model, mental fatigue was identified at 91% [34]. Wang et al. (2019) conducted a study to estimate eye fatigue by obtaining data from virtual glasses containing eye trackers using optometric testing methods. In this study, different measurements such as positive-negative relative congruence, pupil dilation, and corneal angle difference in both eyes were considered. Additionally, 105 participants aged 19-51 with normal vision were subjected to the four-step test. Consequently, data on the increase in eye fatigue at each step were modelled with the vector support machine algorithm [35]. Li et al. (2020) developed a virtual reality environment using commercial machinery. A portable eye tracker is installed for participants to be included in the simulation environment. The blinking rate, blinking time, pupil diameter, and eye position were chosen to determine and classify mental fatigue according to the applied method. The findings of the study include information on the potential for the detection of mental fatigue to reduce the risk of workplace accidents [36]. Lin et al. (2021) investigated eye movement behaviours in their study using a visual fatigue questionnaire, a critical fusion frequency, and an ocular follow-up device. Thirty-three respondents were included in the study. Test participants' scores were analysed using the regression analysis method. As a result of the study, it was reported that eye movement behaviours are a determining factor in detecting visual fatigue and a suitable method in studies conducted for this purpose [37]. Zheng et al. (2021) studied the relationships between visual fatigue questionnaire, contrast sensitivity, accommodative and vergence methods and eye fatigue and its subjective symptoms. It should be noted that 104 young participants (79 women, and 25 men) were included in this study. The results showed that visual fatigue was strongly associated with the ability to encode visual details at the binocular level [38].

4 Conclusions

The study of eye movements is known to have started following Javal (1879) first noticed differences in eye movements of individuals while reading a text. The first eye-monitoring device was developed by Huey (1908) [39]. Buswell (1937) was the first to document differences in eye behaviour when reading orally and quietly. Today, eye-monitoring devices; are used in different fields of scientific research such as neuroscience, experimental psychology, marketing and engineering. Fields of this type use an eye-tracking methodology to investigate visual/cognitive processes. In the field of clinical psychology, it is seen that the most common method used to modify the negative attentional bias in individuals is the dot-probe method. In this study, investigations about the use of the eye tracker in the detection and treatment processes of various psychopathological conditions are presented. Based on the studies, we see that the detection of eye movement behaviours is important for the detection of unconscious processes in the attention processes of people suffering from certain disorders.

5 Declarations

5.1 Study Limitations

None.

5.2 Acknowledgements

Special thanks to the ArelMED-I members for their motivations, recommendations and feedback.

5.3 Funding Source

None.

5.4 Competing Interests

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

5.5 Authors' Contributions

Ozgun Ahmet EFETURK contributed with the paper writing and revisions.

Gizem TURGUT contributed with the paper writing and revisions.

Hamid ASADI DERESHGI contributed with the paper writing and revisions.

Aziz YILMAZ contributed with the paper writing and revisions.

References

- [1] Colombini, E. L., da Silva Simoes, A., & Ribeiro, C. H. C. (2014). An attentional model for intelligent robotics agents (Doctoral dissertation, Instituto Tecnológico de Aeronáutica, São José dos Campos, Brazil).
- [2] James, W., Burkhardt, F., Bowers, F., & Skrupskelis, I. K. (1890). The principles of psychology (Vol. 1, No. 2). London: Macmillan.
- [3] Fan, J., Raz, A., & Posner, M. I. (2003). Attentional mechanisms.
- [4] De Haan, B., Morgan, P. S., & Rorden, C. (2008). Covert orienting of attention and overt eye movements activate identical brain regions. *Brain research*, 1204, 102-111.
- [5] Haladjian, H. H., & Montemayor, C. (2015). On the evolution of conscious attention. *Psychonomic Bulletin & Review*, 22(3), 595-613.

- [6] Santana, A., & Colombini, E. (2021). Neural Attention Models in Deep Learning: Survey and Taxonomy. arXiv preprint arXiv:2112.05909.
- [7] Cisler, J. M., & Koster, E. H. (2010). Mechanisms of attentional biases towards threat in anxiety disorders: An integrative review. *Clinical psychology review*, 30(2), 203-216.
- [8] Harrison, A. J., & Gibb, B. E. (2015). Attentional biases in currently depressed children: An eye-tracking study of biases in sustained attention to emotional stimuli. *Journal of Clinical Child & Adolescent Psychology*, 44(6), 1008-1014.
- [9] Bradley, B., & Mathews, A. (1983). Negative self-schemata in clinical depression. *British Journal of Clinical Psychology*, 22(3), 173-181.
- [10] MacLeod, C., Mathews, A., & Tata, P. (1986). Attentional bias in emotional disorders. *Journal of abnormal psychology*, 95(1), 15.
- [11] Treisman, A. (1977). Focused attention in the perception and retrieval of multidimensional stimuli. *Perception & Psychophysics*, 22(1), 1-11.
- [12] Stroop, J. R. (1935). Studies of interference in serial verbal reactions. *Journal of experimental psychology*, 18(6), 643.
- [13] Posner, M. I. (2016). Orienting of attention: Then and now. *Quarterly journal of experimental psychology*, 69(10), 1864-1875.
- [14] Raymond, J. E., Shapiro, K. L., & Arnell, K. M. (1992). Temporary suppression of visual processing in an RSVP task: An attentional blink?. *Journal of experimental psychology: Human perception and performance*, 18(3), 849.
- [15] Pfabigan, D. M., & Tran, U. S. (2015). Behavioral and physiological bases of attentional biases: paradigms, participants, and stimuli. *Frontiers in psychology*, 6, 686.
- [16] Valuch, C., Pflüger, L. S., Wallner, B., Laeng, B., & Ansorge, U. (2015). Using eye tracking to test for individual differences in attention to attractive faces. *Frontiers in Psychology*, 6, 42.
- [17] Kiss, M., Van Velzen, J., & Eimer, M. (2008). The N2pc component and its links to attention shifts and spatially selective visual processing. *Psychophysiology*, 45(2), 240-249.
- [18] Beesley, T., Pearson, D., & Le Pelley, M. (2019). Eye tracking as a tool for examining cognitive processes. In *Biophysical measurement in experimental social science research* (pp. 1-30). Academic Press.
- [19] Macdonald, R., & Tatler, B. (2018). Gaze in a real-world social interaction: A dual eye-tracking study. *The Quarterly journal of experimental psychology*.
- [20] Vazquez, C., Duque, A., Blanco, I., Pascual, T., Poyato, N., Lopez-Gomez, I., & Chaves, C. (2018). CBT and positive psychology interventions for clinical depression promote healthy attentional biases: An eye-tracking study. *Depression and anxiety*, 35(10), 966-973.
- [21] Han, L., Sun, R., Gao, F., Zhou, Y., & Jou, M. (2019). The effect of negative energy news on social trust and helping behavior. *Computers in Human Behavior*, 92, 128-138.
- [22] Hessels, R. S., Holleman, G. A., Kingstone, A., Hooge, I. T., & Kemner, C. (2019). Gaze allocation in face-to-face communication is affected primarily by task structure and social context, not stimulus-driven factors. *Cognition*, 184, 28-43.
- [23] Yang, J., Li, L., Shen, F., Zeng, L., & Li, R. (2021, April). Identification of depression using support vector machine with different connectivity. In *Journal of Physics: Conference Series* (Vol. 1883, No. 1, p. 012013). IOP Publishing.
- [24] Boffo, M., Pronk, T., Wiers, R. W., & Mannarini, S. (2015). Combining cognitive bias modification training with motivational support in alcohol dependent outpatients: study protocol for a randomised controlled trial. *Trials*, 16(1), 1-14.
- [25] Heitmann, J., van Hemel-Ruiter, M. E., Vermeulen, K. M., Ostafin, B. D., MacLeod, C., Wiers, R. W., ... & de Jong, P. J. (2017). Internet-based attentional bias modification training as add-on to regular treatment in alcohol and cannabis dependent outpatients: a study protocol of a randomized control trial. *BMC psychiatry*, 17(1), 1-13.
- [26] Field, M., & Cox, W. M. (2008). Attentional bias in addictive behaviors: a review of its development, causes, and consequences. *Drug and alcohol dependence*, 97(1-2), 1-20.
- [27] Parvaz, M. A., Malaker, P., Zilverstand, A., Moeller, S. J., Alia-Klein, N., & Goldstein, R. Z. (2021). Attention bias modification in drug addiction: Enhancing control of subsequent habits. *Proceedings of the National Academy of Sciences*, 118(23), e2012941118.
- [28] Napolitano, M. A., Head, S., Babyak, M. A., & Blumenthal, J. A. (2001). Binge eating disorder and night eating syndrome: psychological and behavioral characteristics. *International Journal of Eating Disorders*, 30(2), 193-203.

- [29] Ouyang, L., & Yingqi, W. U. (2021, October). A Review of Attention Bias and Eating Disorder. In 2021 International Conference on Public Relations and Social Sciences (ICPRSS 2021) (pp. 841-845). Atlantis Press.
- [30] Shafran, R., Lee, M., Cooper, Z., Palmer, R. L., & Fairburn, C. G. (2007). Attentional bias in eating disorders. *International Journal of Eating Disorders*, 40(4), 369-380.
- [31] Popien, A., Frayn, M., von Ranson, K. M., & Sears, C. R. (2015). Eye gaze tracking reveals heightened attention to food in adults with binge eating when viewing images of real-world scenes. *Appetite*, 91, 233-240.
- [32] Gutierrez-Maldonado, J., Clua i Sánchez, M., Porrás-García, B., Ferrer-García, M., Serrano, E., Carulla, M., ... & Ascione, M. (2022). Body-Related Attentional Bias in Anorexia Nervosa and Body Dissatisfaction in Females: An Eye-Tracking and Virtual Reality New Paradigm. In *International Conference on Human-Computer Interaction* (pp. 443-454). Springer, Cham.
- [33] Zargari Marandi, R., Madeleine, P., Omland, Ø., Vuillerme, N., & Samani, A. (2018). Eye movement characteristics reflected fatigue development in both young and elderly individuals. *Scientific reports*, 8(1), 1-10.
- [34] Yamada, Y., & Kobayashi, M. (2018). Detecting mental fatigue from eye-tracking data gathered while watching video: Evaluation in younger and older adults. *Artificial intelligence in medicine*, 91, 39-48.
- [35] Wang, Y., Zhai, G., Chen, S., Min, X., Gao, Z., & Song, X. (2019). Assessment of eye fatigue caused by head-mounted displays using eye-tracking. *Biomedical engineering online*, 18(1), 1-19.
- [36] Li, J., Li, H., Umer, W., Wang, H., Xing, X., Zhao, S., & Hou, J. (2020). Identification and classification of construction equipment operators' mental fatigue using wearable eye-tracking technology. *Automation in Construction*, 109, 103000.
- [37] Lin, H. J., Chou, L. W., Chang, K. M., Wang, J. F., Chen, S. H., & Hendradi, R. (2022). Visual fatigue estimation by eye tracker with regression analysis. *Journal of Sensors*, 2022.
- [38] Zheng, F., Hou, F., Chen, R., Mei, J., Huang, P., Chen, B., & Wang, Y. (2021). Investigation of the relationship between subjective symptoms of visual fatigue and visual functions. *Frontiers in Neuroscience*, 15.
- [39] Dodge, R. (1908). *The Psychology and Pedagogy of Reading, with a review of the history of reading and writing, and of methods, texts, and hygiene in reading*. By Edmund Burke Huey, Ph. D., Professor of Psychology and Education in the Western University of Pennsylvania. Pp. xvi+ 469. New York, The Macmillan Co. 1908. *Science*, 28(710), 178-179.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).