




# BİLGİSAYAR BİLİMLERİ VE TEKNOLOJİLERİ DERGİSİ

JOURNAL OF COMPUTER SCIENCE AND TECHNOLOGIES



EDİTÖR: DOÇ. DR. Erdiñç AVAROĞLU  
ISSN 2717 - 8579



*Bilgisayar Bilimleri ve Teknolojileri Dergisi*

# **BİLGİSAYAR BİLİMLERİ VE TEKNOLOJİLERİ DERGİSİ**

**CİLT 2, SAYI 2**

**ISSN: 2717-8579**

**ARALIK 2021**



Bilgisayar Bilimleri ve Teknolojileri Dergisi

## Dergi Hakkında

Bilgisayar Bilimleri ve Teknolojileri Dergisi bilim ve teknolojideki gelişmelere paralel olarak bilgisayar bilimleri ve teknolojileri alanında yeni gelişmelerle ilgili yapılan çalışmaları yayınlayan bir dergidir.

## Amaç & Kapsam

BIBTED Dergisi,

✚ Bilgisayar Bilimleri ve Teknolojileri Dergisinin amacı bilgisayar alanında yapılan özgün çalışmaları yayınlamaktır. Yazım kurallarına uygun olarak hazırlanan eser, dergi editörlüğünce değerlendirme için hakemlere gönderilir. Bilgisayar Bilimleri ve Teknolojileri Dergisinde **KÖR HAKEMLİK** uygulaması mevcuttur. Yayımlanmasına, hakemlerin görüşü doğrultusunda Dergi Editör ve Yayın Kurulu karar verir. Gönderilen makaleler yayınlansın veya yayınlanmasın iade edilmez. Dergimizde yayınlanan yazıların her türlü sorumluluğu (bilimsel, mesleki, hukuki, etik vb.) yazarlara aittir. Yayımlanan yazıların telif hakkı dergiye aittir ve referans gösterilmeden aktarılamaz. Araştırmacılar arasındaki bilimsel iletişimi oluşturmak amacıyla aşağıda nitelikleri açıklanan, başka bir yerde yayımlanmamış makaleler Türkçe ve İngilizce olarak kabul edilmekte ancak Türkçe Kabul edilen makalenin özetinin İngilizce de basılması zorunluluğu vardır.

Aşağıdaki türlerdeki makaleler dergide yayına kabul edilmektedir:

- ✚ **Araştırma makalesi:** Özgün bir araştırmayı sonuçlarıyla birlikte sunan makale,
- ✚ **Derleme makale:** Bilgisayar Mühendisliği alanında belli bir konuda yeterli sayıda bilimsel makaleyi tarayıp, özetleyen, değerlendirme yapan ve bulguları yorumlayan makale,
- ✚ **Endüstriyel makale:** Bu alanda endüstride yapılan araştırma ve geliştirilen yeni ürün veya teknolojilerin açıklandığı makale,
- ✚ **Tez çalışması:** Lisansüstü düzeyde yapılan özgün bir tez çalışmasının genişletilmiş özetini içeren yazı,
- ✚ **Kitap yorumu:** Bilgisayar mühendisliği alanında yayınlanmış yeni bir kitabın tanıtılması ve değerlendirilmesi.
- ✚ **Kısa Bildiri:** Yapılan bir araştırmanın önemli bulgularını açıklayan yeni bir yöntem veya teknik tanımlayan yazılar.

Bütün yazıların Telif Hakkı Devri, yazarlarına bir form gönderilmek suretiyle alınır. Telif Hakkı Devir Formu göndermeyen yazarların yayımları işleme konmaz. Yayımlanmasına karar verilen yazılar üzerine yazarlarınca hiçbir eklenti yapılamaz.

Her yazı konusu ile ilgili en az iki hakeme gönderilerek şekil ve içerik bakımından incelenir. Dergide yayınlanabilecek nitelikteki yazılar dizgisi yapıldıktan sonra, yazarlarına gönderilerek baskı öncesi gözden istenir. Makale içinde, dergide basıldığı haliyle gözükken hataların sorumluluğu yazarlarına aittir. Hata, editörlük ofisinden kaynaklandığı takdirde düzeltme yayınlanabilir.

## Derginin Kapsamı;

Bilgisayar Bilimleri ve Teknolojileri Dergisinin kapsamı, akıllı sistemler, algoritmalar, benzetim, bilgisayar ağları, bilgisayar grafiği, bilgisayarla görme, bilgisayar mimarisi, bilgiye erişim, bilimsel hesaplama, bilişim güvenliği, biyoenformatik, kriptografi, paralel işleme, doğal dil işleme donanım, görüntü işleme, hesaplama kuramı, işaret işleme, işletim sistemleri, makine öğrenmesi, mobil sistemler, modelleme, tıbbi bilişim, veri madenciliği, veri tabanı sistemleri, yazılım mühendisliği, siber güvenlik, yapay zeka dahil olmak üzere bilgisayar bilimleri ve teknolojilerin tüm alanları içerir.

## Yayımlanma Sıklığı

Yılda 2 sayı

## ISSN

2717-8579

## WEB

<https://dergipark.org.tr/tr/pub/bibtred>

## İletişim

[eavaroglu@mersin.edu.tr](mailto:eavaroglu@mersin.edu.tr) / [ttuncer@firat.edu.tr](mailto:ttuncer@firat.edu.tr) / [kemaladem@gmail.com](mailto:kemaladem@gmail.com)



Bilgisayar Bilimleri ve Teknolojileri Dergisi

---

#### EDİTÖR

**Doç. Dr. Erdiñç AVAROÇLU**

Mersin Üniversitesi, Mühendislik Fakültesi / Bilgisayar Mühendisliği, Mersin

---

#### EDİTÖR YARDIMCILARI

**Doç. Dr. Taner TUNCER**

Fırat Üniversitesi, Mühendislik Fakültesi / Bilgisayar Mühendisliği, Elâzığ

**Dr. Öğr. Üyesi. Kemal ADEM**

Aksaray Üniversitesi, İktisadi ve İdari Bilimler Fakültesi / Yönetim Bilişim Sistemleri, Aksaray

---

#### EDİTÖR KURULU

- **Prof. Dr. Zeki YETKİN, MERSİN ÜNİVERSİTESİ**
- **Doç. Dr. İsmail KOYUNCU, AYFON KOCATEPE ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Murat TUNA, KIRKLARELİ ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Abdullah ELEWİ, MERSİN ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Abdullah Erhan AKKAYA, İNÖNÜ ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Lütfiye KUŞAK, MERSİN ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Fatma Bünyal ÜNEL, MERSİN ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Çiğdem ACI, MERSİN ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Soner KIZILOLUK, TURGUT ÖZAL ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Selman YAKUT, TURGUT ÖZAL ÜNİVERSİTESİ**

---

#### DANIŞMA KURULU

- **Prof. Dr. Ahmet Bedri ÖZER, FIRAT ÜNİVERSİTESİ**
- **Prof. Dr. Murat YAKAR, MERSİN ÜNİVERSİTESİ**
- **Doç. Dr. Fatih ÖZKAYNAK, FIRAT ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Mehmet ACI, MERSİN ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Murat TUNA, KIRKLARELİ ÜNİVERSİTESİ**
- **Doç. Dr. İsmail KOYUNCU, AYFON KOCATEPE ÜNİVERSİTESİ**

---

#### DİL EDİTÖRLERİ

- **Dr. Öğr. Üyesi Abdullah ELEWİ, MERSİN ÜNİVERSİTESİ**
- **Dr. Öğr. Üyesi Abdullah Erhan AKKAYA, İNÖNÜ ÜNİVERSİTESİ**
- **Arş. Gör. Dr. Dilek SABANCI, GAZİOSMANPAŞA ÜNİVERSİTESİ**

---

#### MİZANPAJ

- **Arş. Gör. Semih KAHVECİ, MERSİN ÜNİVERSİTESİ**



Bilgisayar Bilimleri ve Teknolojileri Dergisi

# İçindekiler

## Contents

### ARAŞTIRMA MAKALELERİ; RESEARCH ARTICLES;

#### S.No

---

- 36-42 *Öneri Algoritmalarının Film Önerme Problemi Üzerinde Karşılaştırılması: MovieLens Örneği*  
*Comparison of Recommendation Algorithms on the Movie Recommendation Problem: The MovieLens Example*  
**Muhammed Bilal Bozkurt, Çiğdem İnan Acı**
- 43-50 *COVID-19 veri seti kullanarak ön-eğitilmiş modellerin sınıflandırma performanslarının karşılaştırılması*  
*Comparison of the classification performances of pre-trained models using the COVID-19 data set*  
**Melisa Uçkuner, Hamza Erol**
- 51-57 *HAVADA ve KARADA HAREKET EDEBİLEN 3 BOYUTLU TÜNEL HARİTALAMA ROBOTU*  
*3-DIMENSIONAL TUNNEL MAPPING ROBOT MOVING IN AIR and ON LAND*  
**Eray SAKARYA, Ahmet ALKAN**
- 58-65 *Makine Öğrenmesine Dayalı Mobil İngilizce Öğrenme Uygulaması*  
*Mobile English Learning Application Based on Machine Learning*  
**Esracan Güngör, Sinem Ak, Zeynep Orman**

### DERLEME MAKALELERİ; REVIEW ARTICLES;

#### S.No

---

- 66-71 *Büyük veri analitiği için yüksek performans hesaplama: çözüm ortamları ve kodlama*  
*High performance computing for big data analytics: solution environments and coding*  
**Hamza Erol**



Araştırma Makalesi

## Öneri Algoritmalarının Film Önerme Problemi Üzerinde Karşılaştırılması: MovieLens Örneği

Muhammed Bilal Bozkurt<sup>1</sup>, Çiğdem İnan Acı<sup>\*1</sup>

<sup>1</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

### Anahtar Kelimeler:

Öneri Sistemleri  
Yapay Zeka  
Veri Madenciliği  
MovieLens

### ÖZ

Öneri sistemleri kullanıcılara en kısa yoldan istedikleri öğeye ulaşmasını sağlamayı amaçlar. Kullanıcının geçmiş davranışları, öğelerin içerikleri ve daha birçok parametrenin dâhil edildiği birçok farklı öneri yaklaşımı bulunmaktadır. Bunlar kullanıcı memnuniyeti, hız, performans gibi alanlarda farklı sonuçlar sunmaktadır. Kullanıcıya yapılan önerinin en iyi ve en kısa yoldan yapılması kullanıcının memnuniyetini artırır. Bu sebeple günümüzde birçok şirket, öneri algoritmalarını performans ve doğruluk bakımından geliştirmenin yollarını aramaktadır. Bu çalışmada MovieLens veri kümesini kullanarak üç farklı öneri sistemi geliştirilmiş performansları karşılaştırılmıştır.

## Comparison of Recommendation Algorithms on the Movie Recommendation Problem: The MovieLens Example

### Keywords:

Recommendation Systems  
Artificial Intelligence  
Data Mining  
MovieLens

### ABSTRACT

Recommendation algorithms enables users to access the specific item which they might be looking for through shortest way. There are many recommendation algorithms which include parameters such as user's past actions, contents of items and further additional parameters could be included. Mentioned algorithms provide varying results in regard to user satisfaction, speed and performance. A suggestion made in most effective way improves the user satisfaction. Therefore many companies today are seeking ways to further develop these recommendation algorithms, in aspects of performance and reliability. In this study, three different recommendation systems were developed using MovieLens dataset and their performances were compared.

\*Sorumlu Yazar

\*caci@mersin.edu.tr ORCID ID 0000-0002-0028-9890  
(mbilalbozkurt@gmail.com)ORCID ID 0000-0003-1224-9535

e-ISSN: 2717-8579

Geliş Tarihi: 15/03/2021; Kabul Tarihi: 09/06/2021

Bilgisayar Bilimleri ve Teknolojileri Dergisi

## 1. GİRİŞ

Öneri sistemleri, bilgi elde etme çalışmalarıyla birlikte ortaya çıkmış bir kavram olup ancak 1990'ların ortasından itibaren ayrı bir araştırma ve çalışma alanı haline gelmiştir. Bu sistemler kullanıcının herhangi bir çabası olmadan onun kişisel tercihlerine (beğenme ve beğenmeme) veya özelliklerine (yaş, cinsiyet bölge vb.) göre uygun öğeler tavsiye eder. Öneri sistemlerini arama motorlarından ayıran bu temel durum kullanıcı memnuniyetini artırmaktadır. Çalışma ve kullanım alanı oldukça geniş olmakla birlikte müzik, film, kitap, alışveriş gibi birçok çeşitli alanda uygulaması mevcuttur. Ancak ne yazık ki farklı alanlardaki farklı sorunlar sebebiyle geniş kapsamlı bir öneri sistemi geliştirmek güçtür.

Amazon (URL-1) ve Netflix gibi şirketlerin de kullanıcıları ile etkileşime geçerken kullandıkları öneri sistemleri birçok alanda uygulanabilir durumdadır. Öneri sistemleri kullanıcı memnuniyetini artırdığı gibi uygulayıcıların kullanıcıları elde tutma oranını da (Tablo 1) artırmaktadır (Kumar, Yadav, Singh ve Gupta, 2015).

**Tablo 1.** Önerilerin şirkete katkıları

Netflix	İzlenen filmlerin %75'i önerilenler arasından seçiliyor.
Google News	Öneriler %38 daha fazla tıklanıyor.
Amazon	Satışların %35'i önerilenler arasından seçiliyor.

Öneri sistemleri, gerek kullanıcılar arasındaki benzerlikleri, gerek içerikler arasındaki benzerlikleri gerekse her ikisini bir arada kullanarak öneride bulunabilmektedir (Wang, Peng, Jin, Sha, ve Wang, 2016). Bu yöntemler sırasıyla işbirlikçi filtreleme, içerik tabanlı filtreleme ve hibrit filtreleme olarak isimlendirilmektedir.

Bu çalışmada MovieLens veri kümesini kullanarak üç farklı öneri sistemi geliştirilmiş ve performansları değerlendirilmiştir. Bu sayede yöntemler arasındaki hız farkı ve sonuçların kabul edilebilir olup olmadığı tartışılmıştır.

## 2. ÖNCEKİ ÇALIŞMALAR

Literatürde öneri sistemlerine yönelik birçok çalışma yapılmıştır. Var olan sistemleri geliştirmeyi amaçlayan çalışmalar olduğu gibi, kullanıcıların en çok tercih ettiği ve memnun kaldığı yöntemleri arayan çalışmalar da bulunmaktadır.

2011 yılında Bobadilla ve ark. optimal benzerlik fonksiyonunu bulabilmek için genetik bir

algoritma sundular. Çalışma sonucunda elde ettikleri benzerlik fonksiyonları daha iyi sonuç vermiştir. Fonksiyonları, korelasyondan %42 daha hızlı çalışmaktadır (Bobadilla, Ortega, Hernando ve Alcalá, 2011).

Ekstrand ve ark. tarafından 2014'te ürün-ürün İşbirlikçi Filtreleme (İF), kullanıcı-kullanıcı İF ve Tekil Değer Ayrışımı (TDA) yöntemleri ile öneri sistemleri geliştirilmiş ve sonuçlarını karşılaştırabilmek için 582 kişi ile anket çalışması yapılmıştır. Bu anketin sonucuna göre TDA ve ürün-ürün İF yaklaşımları kullanıcı-kullanıcı İF yaklaşımından daha çok tercih edilmiştir. Ürün-ürün ve kullanıcı-kullanıcı arasında yapılan karşılaştırmada 201 kişinin %71,6'sı ürün-ürünü; ürün-ürün ve TDA arasında yapılan karşılaştırmada 198 kişinin %51'i ürün-ürünü; TDA ve kullanıcı-kullanıcı arasında yapılan karşılaştırmada 183 kişinin %74,3'ü TDA'yi tercih etmiştir (Ekstrand, Harper, Willemsen ve Konstan, 2014).

MovieLens veri kümesini kullanarak kullanıcı ve öğe tabanlıdan farklı bir yöntem test etmek isteyen Zhang ve ark. etiket tabanlı bir öneri sistemi geliştirmişlerdir. Öncelikle etiket tabanında en yakın komşuyu bulup daha sonra İF kullanarak kişiselleştirilmiş önerilerini sunmuşlardır. Ancak aldıkları sonuç kullanıcı tabanlı ve öğe tabanlı yaklaşımların yanında başarılı olamamıştır (Zhang, Peng, Sun ve Liu, 2014).

2014 yılında Wang ve ark. kümeleme algoritması ve boyut indirgeme tekniğini birleştirerek hibrit model tabanlı işbirlikçi filtreleme yaklaşımı denemiştir. Bu yaklaşımda en yakın komşuyu bulmak için genetik algoritmalar da kullanılmıştır. Yaptıkları çalışma sonucunda var olan kümeleme tabanlı İF'lerden daha isabetli öneriler aldıklarını belirtmişlerdir (Wang, Yu, Feng ve Wang, 2014).

Ekstrand ve ark. tarafından MovieLens veri kümesi kullanılarak yapılan çalışmada ortalama reytinge göre, ürün-ürün İF'e göre ve TDA ile 3 farklı öneri sistemi geliştirilmiş olup kullanıcıların bu 3 algoritma arasında seçim şansı sunulmuştur. Toplam 3005 kullanıcı arasından 748 kullanıcı en az bir kez öneri sistemleri arasında geçiş yapmış olup bu kullanıcıların nihai tercihleri şu şekildedir: %45,5 TDA, %39 ürün-ürün (Ekstrand, Kluver, Harper, & Konstan, 2015).

Ahuja ve ark. MovieLens veri kümesinde K-Means Clustering ve K En Yakın Komşu algoritmalarını kullanarak geliştirdikleri sistemin var olan teknikten daha iyi sonuç verdiğini belirtmiştir (Ahuja, Solanki ve Nayyar, 2019).

Geçmişte yapılan bu çalışmaların birçoğunda İF ve hibrit yaklaşımın kullanıldığını görüyoruz. Yalnızca İF ya da yalnızca içerik tabanlı filtreleme kullanılmamasının sebebi bu iki yaklaşımın da kendi içinde ayrı ayrı problemleri olmasıdır.

### 3. ÖNERİ SİSTEMLERİ

Her geçen gün daha da büyüyen çevrimiçi ortamlarda kullanıcıların aradıkları ürünü bulmalarının zorlaşması sonucu ortaya çıkan öneri sistemleri, şirketlerin kârını artırdığı gibi kullanıcıların da memnuniyetini artırmaktadır. Örneğin, film izlemek isteyen bir kullanıcı dakikalarca izleyebileceği bir film aramakta, bulduğu filmleri ise yönetmen, oyuncu gibi çeşitli parametreler ile filtrelemekte ve belki de içerik olarak fazlasıyla beğenebileceği bir filmi göz ardı edebilmektedir. Öneri sistemleri kullanıcıya beğenebileceği ancak daha önce hiçbir oyuncusunun adını duymadığı filmler önerebilir.


#### 3.1. Öneri Sistemlerinde Öneri Yaklaşımları

Bir öneri sistemi geliştirebilmek için birçok farklı yaklaşım bulunmaktadır. Bu yaklaşımlar kullanıcılar arasındaki benzerlikleri, içerikler arasındaki benzerlikleri veya bu iki yöntemin hibrit hallerini kullanarak öneri sunar. Bu yöntemlere sırasıyla İF, içerik tabanlı filtreleme ve hibrit filtreleme denmektedir. Öneri sistemleri genel olarak bu üç yöntem üzerinden çalışılmaktadır.

##### 3.1.1. İşbirlikçi Filtreleme (İF)

İF, çok genel bir ifadeyle kullanıcının diğer kullanıcılarla olan benzerliklerini temel alarak önerilen bir algoritmadır. A ve B kullanıcılarının izlediği ve oyladığı filmler arasında bir ilişki kurulabilir ve bu kullanıcılardan birisine diğerinin izleyip beğendiği bir film önerilebilir.

Şekil-1'de iki bisikletçinin de pizza ve salata sevdiğini görüyoruz. Bunlara ek olarak sağdaki bisikletçi ayrıca kutu içecek de sevmektedir. Bu sebeple soldaki bisikletçinin de kutu içecek sevdiğini varsayıp ona kutu içecek önerebiliriz. Bu iki bisikletçi arasındaki ilişki ikisinin de pizza ve salata sevmesi yani ortak zevklere sahip olması dolayısıyla kurulmuştur.



Şekil 1. İF'nin görselleştirilmesi

İF, hafıza tabanlı, model tabanlı ve hibrit olmak üzere kendi içinde üçe ayrılır. Model tabanlı yaklaşımda istatistiksel yöntemlerle veya makine öğrenmesiyle boş reytingler tahmin edilir. Hafıza

tabanlı yöntemde ise kullanıcılar arasındaki benzerlikler bulunarak reyting tahmini yapılır.

##### 3.1.1.1. Hafıza tabanlı yaklaşım

Hafıza tabanlı yaklaşımda çözülmesi gereken problem benzerliğine başvurulacak en yakın komşunun nasıl bulunacağıdır. Bu konuda Kosinüs benzerliği sıklıkla kullanılmaktadır. Kosinüs benzerliği, iki kullanıcı vektörünün arasındaki açının kosinüsünü hesaplayarak (Denklem 1) bulunur (Xia, Zhang, ve Li, 2015).

$r_u$ : u kullanıcısının oyu,  
 $r_{u'}$ : u' kullanıcısının oyu olmak üzere;

$$\text{benzerlik}(u, u') = \frac{r_u \cdot r_{u'}}{|r_u| \cdot |r_{u'}|} = \sum_i \frac{r_{ui} r_{u'i}}{\sqrt{\sum_i r_{ui}^2} \sqrt{\sum_i r_{u'i}^2}} \quad (1)$$

u-kullanıcısının i-ögesi için vereceği oyu diğer tüm kullanıcıların i-ögesi için verdiği oyların ağırlıklı toplamı kullanılarak tahmin edilebilir. Formül hesaplanırken kullanılacak ağırlık ise diğer kullanıcılar ile u-kullanıcısı arasındaki benzerlik olacaktır (Denklem 2).

$r_{u'i}$ : u' kullanıcısının i filmi için oyu olmak üzere;

$$\hat{r}_{ui} = \sum_{u'} \text{benzerlik}(u, u') r_{u'i} \quad (2)$$

Son olarak, bulunan sonuç diğer tüm kullanıcıların reytinglerine bölünerek normalize edilir (Denklem 3).

$$\hat{r}_{ui} = \frac{\sum_{u'} \text{sim}(u, u') r_{u'i}}{\sum_{u'} |\text{sim}(u, u')|} \quad (3)$$

##### 3.1.1.2. Model tabanlı yaklaşım

Model tabanlı yaklaşımda kullanılan model, kullanıcının daha önce oylamadığı öğeler için makine öğrenmesi ile reyting tahmini yapar (Şekil 2).






## Şekil 2. Model tabanlı yaklaşımda yöntemler

Model tabanlı yaklaşım matris faktörizasyonunu kullanır. Matris faktörizasyonunun arkasındaki ana fikir kullanıcıların tutum ve tercihlerinin az sayıda gizli faktör ile belirlenmesidir. Şekil-3'teki matrisin ayrıştırılmasından sonra, satırlarda ifade edilen vektörlerin, sütunlarda ifade edilen kullanıcı vektörleriyle çarpımı, herhangi bir kullanıcının herhangi bir film için vereceği tahmini reytingi ifade edecektir (Şekil-4) (URL-2).

	Cennet Mahallesi	Arka Sokaklar	Yedi Numara
Bilal	4.5		5.0
Burak		4.5	4.0

Şekil 3. Film-Kullanıcı Matrisi



Şekil 4. Ayrıştırma sonrası durum

Şekil-3'e uygulanan ayrıştırmanın ardından Şekil-4 elde edilir.  $D(n\_factors)$  parametresi isteğe bağlı olarak değiştirilebilir. Örneğin,  $n\_factors=3$  olarak alındığında film özelliklerinde "Ne kadar bilim kurgu", "ne kadar yeni", "ne kadar animasyon içeriyor" gibi faktörleri temsil edebilir.

### 3.1.2. İçerik Tabanlı Filtreleme

İçerik tabanlı filtrelemede kullanıcının daha önce tercih ettiği öğelerin içerikleri incelenir ve bunlara uygun yeni bir içerik kullanıcıya sunulur. Bu yöntem öğelerin birçok özelliğinin (yönetmen, oyuncular, konu vs.) bilinmesini gerektirir.

### 3.1.3. Hibrit filtreleme

Hibrit filtreleme işbirlikçi ve içerik tabanlı filtrelemelerin dezavantajlarından kurtulabilmek için ikisinin bir arada kullanılmasıyla geliştirilen yöntemdir. Örneğin İF yönteminde sisteme yeni bir öğe eklendiğinde hiç oylanmamış olması ve dolayısıyla kimseye önerilemeyecek olması gibi bir dezavantajı varken içerik tabanlı filtrelemenin kullanıcıya asla kullanıcının zevkleri dışında bir içerik önerememe gibi bir dezavantajı vardır. Bunların üstesinden ikisinin bir arada kullanılmasıyla gelmektedir.

### 3.1.4. Popülarite Tabanlı Öneri Sistemleri

Popülarite tabanlı öneri sistemleri kullanıcıların oylamasından bağımsız olarak bir öğenin "erişme" sayısına göre öneriler sunan sistemler için kullanılan terimdir. Bu tür sistemlerde sunulan öneri her kullanıcı için aynıdır. Örneğin popülarite tabanlı film öneri sistemlerinde oylamaya göre değil kaç kullanıcının o filmi izlediğine göre sıralama yapılır. Bu sistemin sorunlarından birisi yeni eklenen filmlerin belirli bir süre zarfında önerilemeyecek olmasıdır.

### 3.2. Öneri Sistemlerinin Zorlukları

Bir kullanıcıya zevkine göre öneride bulunma fikri ilk bakışta kolay gözükebilir, ancak kullanıcının zevkine uygun doğru öğeleri bulabilmek sadece kullanıcı hakkında bilgi sahibi olmakla çözülememektedir. Buna ek olarak öğeler hakkında, genel bağlam hakkında da bilgi sahibi olmayı ve bunları kullanarak karmaşık hesaplamalara yapmayı gerektirmektedir.

Yapılan bir öneri kullanıcının zevklerine uygun olmasına rağmen kültürüne uygun olmayabilir. Kültürüne uygun olmasına rağmen kullanıcının görüşleri filmin yönetmeninin görüşleriyle zıt düşüyor olabilir. Devam eden paragraflarda öneri sistemlerinin zorlukları sunulmuştur:

#### 3.2.1. Soğuk Başlangıç (Cold Start) Problemi

Soğuk başlangıç ya da ilk oylayıcı sorunu İF'de sisteme yeni eklenen bir öğenin daha önce hiçbir kullanıcı tarafından oylanmamış olması ve bu sebeple hiç kimseye önerilemeyecek olmasından kaynaklanan bir problemdir (Elahi, Ricci ve Rubens, 2016). Aynı durum, sisteme yeni giren bir kullanıcı için de geçerlidir. Kullanıcı ilk geri bildirimini yapana kadar kendisine bir öneri sunulamayacaktır. İçerik tabanlı sistemde ise kullanıcıların oyları veya öğelerin puanları yerine öğenin özellikleri ile hesaplama yapıldığından böyle bir sorun oluşmamaktadır.

#### 3.2.2. Seyrek Veri (Sparsity) Problemi

İF'nin problemlerinden birisi olan seyrek veri problemi sistemde yeterince puanlama olmadığında meydana gelir. Bir matris halinde tutulan kullanıcı/puan yapısındaki boşluklar sistemin verimliliğini düşürür. Bu sorun genellikle sistemde çok öğe az kullanıcı olduğunda meydana gelir.

#### 3.2.3. Ölçeklenebilirlik Problemi

Öneri sistemleri, aynı anda birden çok kullanıcıya hizmet vermeyi hedefler. Aynı anda binlerce kullanıcıya hizmet vermesine ek olarak sistemde milyonları aşkın kullanıcı ve öğe

bulunabilir. Böyle bir sistemin verimli çalışabilmesi için sistemi bu yükü taşıyabilecek donanım ve yazılımla çalıştırılması gerekir. Ölçeklenebilirlik, tüm öneri sistemleri için zorlayıcıdır.

### 3.2.4. Gri Koyun Problemi

Yine işbirlikçi filtrelemenin sorunlarından birisi olan gri koyun sorunu sistemdeki bazı kullanıcıların hiçbir kullanıcı veya grupta ortak ilgi alanı olmadığında meydana gelir. Ancak sistemdeki kullanıcı ve oylama sayısı arttığında bu sorunla karşılaşma ihtimali azalmaktadır.

### 3.2.5. Komşu Geçişkenliği Problemi

Öneri sistemlerinin veritabanı çok seyrek olduğunda yani yeterli oylama olmadığında komşu geçişkenliği meydana gelebilir. Öyle ki aynı zevk ve beğeniye sahip iki kullanıcı, sistemde aynı öğeleri hiç oylamamış olabilirler. Bu durumda öneri sisteminin bu iki kullanıcı arasında ilişki kurması mümkün değildir.

## 3.3. Veri Kümeleri ve Büyük Veri

Öneri sistemlerinin en büyük ihtiyacı kullanıcılar ve onların oylamalarıdır. Bu büyük veriyi uzun emekler sonucu toplayabilir ya da hazır veri kümeleri kullanarak sistemi kısa sürede çalıştırabilir ve test edebiliriz. Piyasada gerçek veriler bulunduğu gibi algoritmik olarak oluşturulmuş veriler de bulunmaktadır.

### 3.3.1. Veri Kümesi

Bu çalışmada MovieLens veri kümesi kullanılmıştır. MovieLens, 2010 yılında piyasaya sürülmüş olan bir film öneri sistemi projesinin veri kümesidir. 100.000 ve 1 milyon satır boyutlu veri kümeleri kullanıcıların yaş, cinsiyet, meslek, bölge gibi temel verilerini de içermektedir. 10 milyonluk veri kümesi ise bu bilgileri içermeyip sadece oylama verisini içerir. Şekil 5'te MovieLens veri kümesinin ilk beş kaydı görülmektedir.

movieId	title	genres
0	1 Toy Story (1995)	Adventure Animation Children Comedy Fantasy
1	2 Jumanji (1995)	Adventure Children Fantasy
2	3 Grumpier Old Men (1995)	Comedy Romance
3	4 Waiting to Exhale (1995)	Comedy Drama Romance
4	5 Father of the Bride Part II (1995)	Comedy

userId	movieId	rating	timestamp
0	1	4.0	964982703
1	1	3	964981247
2	1	6	964982224
3	1	47	964983815
4	1	50	964982931

Toplam Film Sayısı: 5  
Toplam Kullanıcı Sayısı: 1

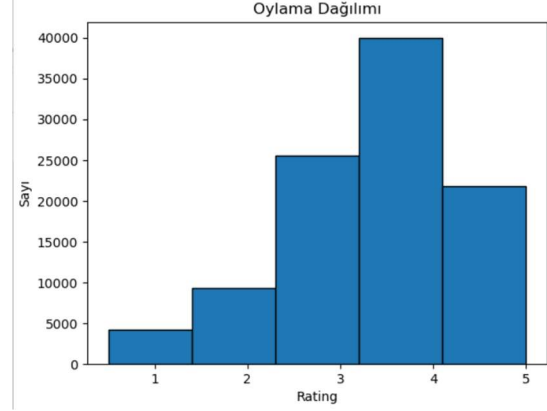
Şekil 5. MovieLens veri kümesi

## 3.4. Öneri Sistemlerinin Geliştirilmesi

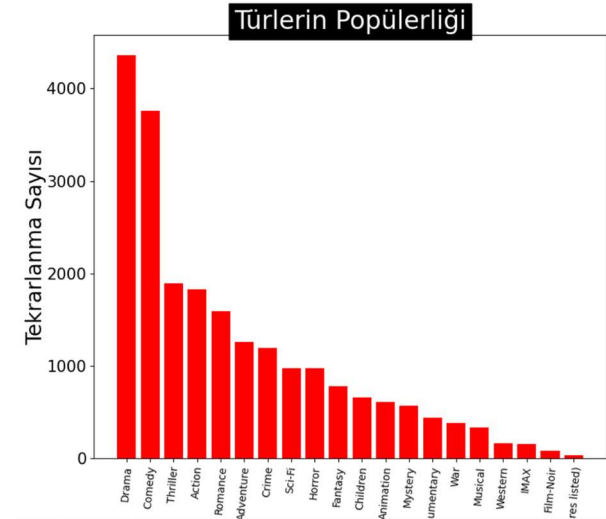
Bu çalışmada popülerite tabanlı, TDA ile işbirlikçi filtreleme ve ardından kosinüs benzerliği

yöntemleri kullanılarak üç farklı öneri sistemi geliştirilecektir.

Geliştirilecek sistemler için MovieLens tarafından ücretsiz olarak sunulan 600 kullanıcı, 9.000 film ve 100.000 oylamaya sahip olan en küçük veri kümesi kullanılmıştır(URL-3). Bahsedilen veri kümesi, film başlığını, türünü ve kullanıcıların verdiği oylamaları içermektedir. Oylama ve tür dağılımı Şekil-6 ve Şekil-7'de gösterilmiştir.



Şekil 6. Seçilen veri kümesinin oylama dağılımı.



Şekil 7. Seçilen veri kümesinin kategori dağılımı.

## 4. SONUÇLAR

Çalışmamızda popülerite tabanlı, TDA ile işbirlikçi filtreleme tabanlı ve kosinüs benzerliği tabanlı olmak üzere üç farklı öneri sistemi geliştirilmiş ve sonuçlar karşılaştırılmıştır. Geliştirme ortamının teknik detayları Tablo 2'de verilmiştir.

Tablo 2. Geliştirme ortamı

CPU	Intel i7 6700HQ
GPU	Nvidia GeForce 950m
Dil	Python 3

İşletim Sistemi	Windows 10
-----------------	------------

MovieLens veri kümesindeki filmler kullanıcılar tarafından oylanmıştır. Veri kümesine yeni eklenen 611. kullanıcının oyladığı filmler Şekil-8'de görülmektedir.


```

611. kullanıcı şu ana kadar toplam 18 filmi oyladı.
#1. A Quiet Place (2018) - 2.0
#2. I, Tonya (2017) - 4.0
#3. Arrival (2016) - 3.0
#4. Interstellar (2014) - 5.0
#5. Truman Show, The (1998) - 4.0
#6. Ray (2004) - 3.5
#7. The Martian (2015) - 4.5
#8. Léon: The Professional (a.k.a. The Professional) (Léon) (1994) - 5.0
#9. La La Land (2016) - 5.0
#10. Love Me If You Dare (Jeux d'enfants) (2003) - 4.0
#11. The Hateful Eight (2015) - 4.5
#12. Cast Away (2000) - 4.0
#13. Django Unchained (2012) - 4.5
#14. Fight Club (1999) - 5.0
#15. Lord of the Rings: The Two Towers, The (2002) - 5.0
#16. Lord of the Rings: The Return of the King, The (2003) - 5.0
#17. Lord of the Rings: The Fellowship of the Ring, The (2001) - 5.0
#18. Seven (a.k.a. Se7en) (1995) - 4.5

```

Şekil 8. Örnek bir kullanıcının oyları.

Geliştirilen sistemler örnek iki kullanıcı için (7. ve 611. kullanıcı) önerilerde bulunmuştur. Her bir algoritma her iki kullanıcı için de 30 adet öneri alınmıştır. Popülarite bazlı öneri sistemi beklendiği üzere her iki kullanıcı için de aynı sonucu vermiştir. Ortalama hesaplama süresi 0,0413 saniyedir. TDA İF sisteminin ortalama hesaplama süresi 1,37 saniye olarak hesaplanmıştır. Kosinüs benzerliği bazlı öneri sisteminin ortalama hesaplama süresi 2,73 saniye olarak hesaplanmıştır. Çalışma sürelerinin karşılaştırması Şekil-9'dan görülebilir.



Şekil 9. Sistemlerin çalışma süresi

611. Kullanıcıya bu öneriler hakkındaki düşünceleri sorulduğunda en iyi sonucu TDA yönteminin verdiğini, ardından sırasıyla kosinüs benzerliğini ve popülarite tabanlı yaklaşımı seçeceğini bildirmiştir. Çalışma sonucunda elde edilen sonuçlar (Şekil-10) İF'nin diğerlerine göre daha başarılı olduğunu göstermektedir.

	Popülarite Tabanlı	Matris Faktörizasyonu Tabanlı	Kosinüs Benzerliği Tabanlı
Kişisel Öneriler	HAYIR	EVET	EVET
Kullanıcı Özellikleri	HAYIR	EVET	EVET
Film Özellikleri	HAYIR	EVET	HAYIR
Yeni Filmleri Önerilebilir	HAYIR	HAYIR	HAYIR

Şekil 10. Sonuçlar

Özetle, TDA ile alınan sonuçlar ve çalışma hızı diğer yaklaşımlara göre daha iyi performans

göstermiştir. Hiç animasyon filmi oylamamış olan 611. kullanıcıya TDA ile 4 adet animasyon filmi önerilmiş olması filmlerin içeriklerinin de hesaplamaya dahil edildiğini göstermektedir. Kosinüs benzerliği ile bulunan en yakının komşu da önerilen bu filmleri izleyip yüksek bir puanla oylamıştır. Hibrit bir yaklaşım olarak TDA ile yapılan öneriler en yakın komşu ile karşılaştırılabilir ve en yakın komşu tarafından beğenilmeyen (düşük puan alan filmler) kullanıcıya önerilmez.

## KAYNAKÇA

Ahuja, R., Solanki, A., & Nayyar, A. (2019, January). Movie recommender system using K-Means clustering and K-Nearest Neighbor. In *2019 9th International Conference on Cloud Computing, Data Science & Engineering (Confluence)* (pp. 263-268). IEEE.

Bobadilla, J., Ortega, F., Hernando, A., & Alcalá, J. (2011). Improving collaborative filtering recommender system results and performance using genetic algorithms. *Knowledge-based systems*, 24(8), 1310-1316.

Ekstrand, M. D., Harper, F. M., Willemsen, M. C., & Konstan, J. A. (2014, October). User perception of differences in recommender algorithms. In *Proceedings of the 8th ACM Conference on Recommender systems* (pp. 161-168).

Ekstrand, M. D., Kluver, D., Harper, F. M., & Konstan, J. A. (2015, September). Letting users choose recommender algorithms: An experimental study. In *Proceedings of the 9th ACM Conference on Recommender Systems* (pp. 11-18).

Elahi, M., Ricci, F., & Rubens, N. (2016). A survey of active learning in collaborative filtering recommender systems. *Computer Science Review*, 20, 29-50.

Koren, Y. (2009). The bellkor solution to the netflix grand prize. *Netflix prize documentation*, 81(2009), 1-10.

Kumar, M., Yadav, D. K., Singh, A., & Gupta, V. K. (2015). A movie recommender system: Movrec. *International Journal of Computer Applications*, 124(3).

Wang, K., Peng, H., Jin, Y., Sha, C., & Wang, X. (2016). Local weighted matrix factorization for top-n recommendation with implicit feedback. *Data Science and Engineering*, 1(4), 252-264.

Wang, Z., Yu, X., Feng, N., & Wang, Z. (2014). An improved collaborative movie

recommendation system using computational intelligence. *Journal of Visual Languages & Computing*, 25(6), 667-675.

Xia, P., Zhang, L., & Li, F. (2015). Learning similarity with cosine similarity ensemble. *Information Sciences*, 307, 39-52.

Zhang, J., Peng, Q., Sun, S., & Liu, C. (2014). Collaborative filtering recommendation algorithm based on user preference derived from item domain features. *Physica A: Statistical Mechanics and its Applications*, 396, 66-76.

URL-1: <https://www.amazon.science/the-history-of-amazons-recommendation-algorithm>  
[Eriřim Tarihi: 12.03.2021]

URL-2: <https://developers.google.com/machine-learning/recommendation/collaborative/matrix>  
[Eriřim Tarihi: 12.03.2021]

URL-3: <https://grouplens.org/datasets/movielens/>  
[Eriřim Tarihi: 12.03.2021]



Araştırma Makalesi

## COVID-19 veri seti kullanarak ön-eğitilmiş modellerin sınıflandırma performanslarının karşılaştırılması

Melisa Uçkuner\*<sup>1</sup>, Hamza Erol<sup>2</sup>

<sup>1</sup>Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Mersin, Türkiye

<sup>2</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

### ÖZ

**Anahtar Kelimeler:**  
sınıflandırma  
covid-19  
makine öğrenmesi  
öğrenme aktarımı  
ön-eğitilmiş modeller

COVID-19, 2019 yılında Çin'in Wuhan kentinde ortaya çıkan ve SARS-CoV-2 virüsünün neden olduğu bir salgındır. Bu salgın, virüsün yüksek bulaşıcılığa sahip olmasından dolayı hızlı bir şekilde tüm dünyaya yayılmaktadır. SARS-CoV-2 virüsünün oluşturduğu semptomlar, diğer hastalıklarla benzerlik gösterebilmekte ve bu virüse maruz kalanların hastalıkları viral pnömoni ile karıştırılabilmektedir. Bundan dolayı hastalığın teşhisinde, doktorlara ve araştırmacılara yardımcı olmak için bilgisayar destekli teşhis sistemlerinden faydalanılmaktadır. Bu çalışmada, 3 sınıf içeren COVID-19 veri seti, öğrenme aktarımı yöntemi kullanılarak sınıflandırılmıştır. Veri setinin %80'i eğitim, %20'si test verisi olarak ayrılmıştır. Ön-eğitilmiş modeller kullanılarak oluşturulan sınıflandırıcılar eğitilmiş ve elde edilen modellerin test verisi için doğruluk oranları InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2, DenseNet201 tabanlı modeller için sırasıyla %98.6, %98.7, %99.3, %97.8, %98.7 ve %98.0 olarak hesaplanmıştır. Bu sonuçlar, ön-eğitilmiş modeller kullanılarak oluşturulan sınıflandırıcıların, COVID-19 salgınında teşhis aşamasında doktorlara yardımcı olabileceğini göstermektedir.

## Comparison of the classification performances of pre-trained models using the COVID-19 data set

**Keywords:**  
classification  
covid-19  
machine learning  
transfer learning  
pre-trained models

### ABSTRACT

COVID-19 is a pandemic that originated in Wuhan, China in 2019 and is caused by SARS-CoV-2 viruses. The pandemic quickly spread all over the world due to the high contagiousness of the virus. Symptoms exhibited by SARS-CoV-2 viruses can be similar to other diseases and diseases of those exposed to the virus can be confused with viral pneumonia. Therefore, computer-aided diagnosis (CAD) systems are used to assist doctors and researchers in the diagnosis of the disease. In this study, the COVID-19 data set, which includes 3 classes, was classified using the transfer learning method. 80% of the data set is separated as training and 20% as test data. Classifiers constructed using pre-trained models were trained and the accuracy rates for the test data were obtained as %98.6, %98.7, %99.3, %97.8, %98.7 and %98.0 for InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2, DenseNet201 models, respectively. These results show that the proposed classifiers based on pre-trained models can assist doctors in the diagnosis of the COVID-19 outbreak.

\*Sorumlu Yazar

\*[melisauckuner@gmail.com](mailto:melisauckuner@gmail.com)  
ORCID ID 0000-0003-2955-4456  
[herol@mersin.edu.tr](mailto:herol@mersin.edu.tr)  
ORCID ID 0000-0001-8983-4797

e-ISSN: 2717-8579  
Geliş Tarihi: 17/05/2021; Kabul Tarihi: 18/06/2021

## 1. GİRİŞ

İnsanoğlunun afetlerle mücadelesi, insanlığın varoluşunun başından itibaren günümüze kadar devam etmektedir. Bakterilerin ve virüslerin neden olduğu biyolojik afetler de doğal afetler arasında yer almaktadır. Son zamanlarda yaşanan en büyük biyolojik afetlerden birisi, 2019 yılında Çin'in Wuhan kentinde ortaya çıkan ve Dünya Sağlık Örgütü tarafından pandemi olarak kabul edilen COVID-19 salgınıdır. Viral bir salgın olan COVID-19, henüz aşı çalışmaları tam olarak sonlanmamış ve tedavisi olmayan bir hastalık olup, hızlı yayılma ve viral pnömoni (viral zatürre) ile karıştırılma gibi zorlayıcı özelliklere sahiptir. Son yıllarda teknolojinin gelişmesiyle birlikte bilgisayar destekli teşhis (BDT) yöntemlerinin yaygın kullanımı alanına erişmesi, COVID-19 hastalığının tespitinde de bilgisayar destekli sistemlerin kullanılabilirliğini göstermektedir. BDT sistemlerinin hızlı ve güvenilir sonuç vermesi, hızla yayılan COVID-19 viral salgınının tespitinde kullanılarak doktorlara yardımcı sistemlerin geliştirilmesine motivasyon oluşturmaktadır. BDT sistemlerinin gelişmesinde, son zamanlarda popüler bir noktaya ulaşan derin öğrenme yöntemi ve evrişimli sinirsel ağları (ESA) büyük rol oynamaktadır. Derin öğrenme modelleri, görüntülerin ve videoların sınıflandırılması başta olmak üzere birçok alanda yaygın bir şekilde kullanılmakta ve yeni fikirlerin geliştirilmesine kolaylıklar sağlayan bir kapı aralamaktadır. Literatürde, COVID-19 salgınının tespiti için makine öğrenmesi yöntemlerini kullanan çeşitli yöntemler bulunmaktadır (Rochmawati vd., 2020; Mishra vd., 2020; Tabik vd., 2020; Wang vd., 2020; Chowdhury vd., 2020). Rochmawati ve arkadaşları tarafından yapılan çalışmada (Rochmawati vd., 2020) bir klinik semptom veri seti kullanılarak COVID-19 semptomları, karar ağacı algoritması ile sınıflandırılmaktadır. Mishra ve arkadaşları (Mishra vd., 2020) ise COVID-19 hastalığının tespitinde, x-ray röntgen verilerinin sınıflandırması için CovAI-Net olarak adlandırdıkları iki aşamalı bir evrişimsel sinir ağı (ESA) modeli önermişlerdir. Veri seti sınıflandırması konusunda yapılan bir diğer çalışma, Tabik ve arkadaşları tarafından (Tabik vd., 2020) yapılmıştır. Önerilen çalışmada, homojen ve dengeli şekilde oluşturdukları veri seti, öğrenme aktarımı yöntemi kullanılarak sınıflandırılmış ve %97.72 oranında doğruluğa ulaşılmıştır (Tabik vd., 2020). Wang ve arkadaşları (Wang vd., 2020), bilgisayarlı tomografi ile elde edilen görüntüleri kullanarak, COVID-19 sınıflandırması yapan ve DeCoVNet olarak adlandırdıkları bir ESA modeli önermişlerdir. Önerdikleri model (Wang vd., 2020), %90.1'lik bir doğrulukla tahminlerini gerçekleştirmektedir. Bu konuda yapılan bir diğer çalışmada (Chowdhury vd., 2020) çeşitli kaynaklardan elde edilen 3487 adet x-ray röntgen görüntüleri, ön-eğitilmiş derin öğrenme modelleri

kullanılarak sınıflandırılmıştır. Yapılan çalışmada (Chowdhury vd., 2020), %98.3'lük doğruluğa erişilmiştir.

Bu çalışmada, COVID-19 salgını için oluşturulan 3 sınıflı x-ray röntgen görüntülerinin öğrenme aktarımı tabanlı sınıflandırıcı kullanılarak sınıflandırılması amaçlanmıştır. 6 farklı ön-eğitilmiş model kullanılarak oluşturulan sınıflandırıcının karşılaştırması yapılarak modellerin performansları yorumlanmıştır.

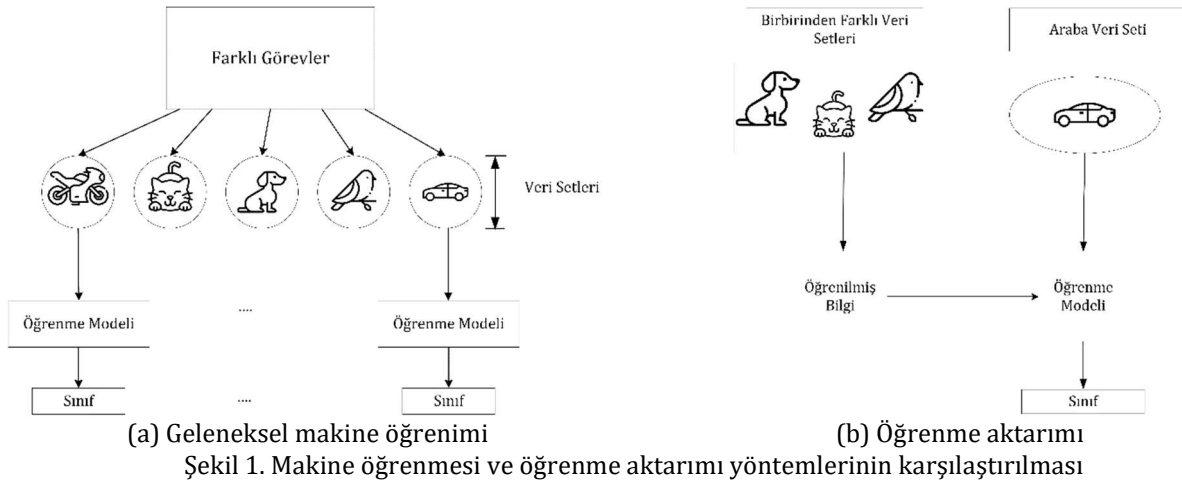
## 2. ÖĞRENME AKTARIMI YÖNTEMİ

Öğrenme aktarımı (transfer öğrenmesi), özel amaçlar için geliştirilen derin öğrenme modelleri ile elde edilen özelliklerin, diğer makine öğrenmesi yöntemlerinde giriş olarak kullanılması ile oluşturulan öğrenme yapısı olarak tanımlanmaktadır.

Öğrenme aktarımı, bir probleme çözüm arama veya bir durumdan elde edilen sonuçları bilgi olarak saklayıp, farklı ama ilişkili problemlere ya da durumlara bilginin aktarılmasıdır. Aktarılan bilginin, farklı durumda da çözüme olumlu yönde etkili olması için genel bilgiler içermesi gerekmektedir. Probleme özgü özelliklerin kullanılması, negatif yönde bilgi aktarımına sebep olabilmektedir. Bu sebeple, hem kaynak hem de uygulanacak problemlere uygun olan bilgiler aktarılmalıdır.

İnsanlar, günlük hayatta karşılaştıkları sorunlarda elde ettikleri bilgileri başka durumlarda kullanmaktadır. Elde edilen bilgi, yeni bilgiler elde edilmesi için ilk adım ya da başlangıç olarak düşünülmektedir. Başlangıçta mevcut olan bilgi sayesinde yeni bilgi öğrenimi, hızlı ve kolay bir şekilde gerçekleşmektedir.

Geleneksel makine öğrenmesi, farklı veri setlerinin öğrenimi için farklı modellerin kullanılmasına dayanmaktadır. Her veri setinin özelliği birbirinden farklı olduğundan, bu farklılığa uygun şekilde modeller geliştirilmesi önemlidir. Ayrıca geliştirilen modellerin eğitilmesinde, veri setine ait özellik çıkarımının daha önceden yapılması da modelin yüksek doğruluğa hızlı bir şekilde erişmesi için gereklidir. Öğrenme aktarımı yönteminde ise bu özellik çıkarımı, geleneksel makine öğrenmesi yöntemlerinin aksine model içerisinde yapılmaktadır. Böylece modelin eğitilmesi ve test edilmesi aşamasında ayrıca özellik çıkarımı yapmaya gerek olmamakta, işlenmemiş veri doğrudan modele uygulanabilmektedir. Ayrıca, öğrenme aktarımında kullanılan ön-eğitilmiş modeller, daha önceden çeşitli veri setleri ile eğitildiklerinden dolayı eğitilmiş ağırlıklara sahiptir. Böylece ön-eğitilmiş ağırlıklar kullanarak yüksek doğruluklara hızlı bir şekilde ulaşılabilir. Şekil 1(a)'da geleneksel makine öğrenimine ve Şekil 1(b)'de öğrenme aktarımına ilişkin görsel yer almaktadır.



Şekil 1’de görüldüğü gibi, geleneksel makine öğrenmesinde oluşturulan modeller, her bir veri seti için ayrı ayrı olacak şekilde sıfırdan eğitilmektedir. Öğrenme aktarımı sürecinde aktarılabilecek bilgi ile bu bilginin aktarılma zamanı ve aktarım yöntemi önemlidir. Aktarılabilecek bilginin belirlenmesi, ilk ve en önemli aşama olup, kullanılacak veriye göre değişmektedir. Kaynak veriden aktarılabilecek olan bilgi, ortak özellikler içermelidir. Aktarılabilecek bilginin sadece kaynağa özgü olması, kullanılacak veri seti için bir yarar sağlamamakta, hatta negatif bilgi aktarımına sebep olabilmektedir. Bundan dolayı, aktarılabilecek bilgi genel olmalıdır. Bilginin aktarılma zamanı, iki veri setinin birbirinden çok farklı olması veya ortak özelliklerinin olması durumlarında farklılıklar göstermektedir. Bu zaman, çok farklı veri setlerinde eğitimin başarısını düşürebildiği gibi, ortak özelliklerin kullanılmasında performansı yükseltmektedir. Aktarım yöntemi olarak var olan modeller direkt kullanılabilir gibi, modeller üzerinde katmanlar ya da parametreler değiştirilip yeni modeller elde edilerek bilgi aktarımı gerçekleştirilebilir.

Öğrenme aktarımı, bahsedildiği gibi eğitilmiş modellerin edindiği bilginin kullanılmasıyla gerçekleştirilmektedir. Literatürde birçok derin öğrenme modeli bulunmasına rağmen bu çalışmada InceptionV3, Xception, ResNet152V2, DenseNet201, InceptionResNetV2, ve VGG19 modelleri tercih edilmiştir.

Derin öğrenme modellerinde, ağların derinlikleri arttıkça hesaplama karmaşıklığı da meydana gelmektedir. Hesaplama esnekliği sağlamak ve karmaşıklığı azaltmak için kullanılan yollardan biri, matrislerin boyutlarını havuzlama katmanları ile azaltmaktır. Ancak bu durumda ilgili katmanın derinliği azalmamaktadır. Katman derinliğini azaltmak için Szegedy vd. tarafından önerilen çalışmada (Szegedy vd., 2016),  $1 \times 1$  boyutunda evrişim katmanı kullanılması önerilmiştir. Önerilen katmanın kullanılmasıyla, matris derinliği sınırlandırılabilir ve işlem karmaşıklığı azaltılabilir. Modüllerden oluşan InceptionV3 modelinde modüller, *Inception*

olarak adlandırılan farklı boyutlarda evrişim ve maksimum havuzlama katmanlarından oluşmaktadır.

Xception mimarisi (Chollet, 2017), *Inception* mimarisindeki standart *Inception* modüllerinin *derinlemesine ayrılabilir evrişim katmanları* ile değiştirilmesiyle oluşturulmuş bir uzantıdır. Xception modelinde çapraz-özellik haritası korelasyonları  $1 \times 1$  boyutundaki evrişim katmanı sayesinde elde edilmektedir. Ardından, her kanal için uzamsal korelasyonlar ise klasik  $3 \times 3$  veya  $5 \times 5$  boyutlarındaki evrişim katmanlarıyla hesaplanmaktadır. Burada uygulanan yöntem, derinlemesine ayrılabilir evrişimleri temsil etmektedir.

ESA’da katman sayısının artırılmasının, modelin doğruluğunu sürekli olarak artırmadığı ve doyuma ulaştırdığının görülmesi, ResNet mimarisinin önerilmesinde önemli rol oynamıştır. ResNet mimarisi (He vd., 2016), mevcut katmana daha önceki katmanlardan artık değerlerin (residual value) eklenmesine dayanmaktadır. Artık değerler, ResNet mimarisinde doğrusal ve ReLU (rectified linear unit) katmanları arasında iki katmanda bir eklenecek şekilde oluşturulmaktadır. Böylece daha derin ağlar oluşturulurken eğitim daha hızlı yapılmakta ve ağ başarısı artırılmaktadır.

Literatürde yer alan derin öğrenme modellerinden bir diğeri, DenseNet olarak adlandırılan, Huang ve arkadaşları tarafından önerilen yoğun bağlantılı evrişimsel ağlardır (Huang vd., 2017). DenseNet mimarisinde, ResNet mimarisinden farklı olarak daha önceki katmanlardan gelen bilgiler, daha sonraki katmanlarla toplanmak yerine birleştirilmektedir. Bu yöntem, özelliklerin yeniden kullanılması ve gradyan kaybolma sorununu azaltma gibi avantajlar sunmaktadır (Wang ve Zhang, 2020).


Inception-ResNet modeli, *Inception* mimarisinde yer alan *Inception* modülleri ile ResNet mimarisinin performansından esinlenilerek oluşturulan hibrid bir modeldir (Szegedy vd., 2017). Bu hibrid modelde *inception* modülleri, artık *inception* modüllerine dönüştürülmektedir.

VGG mimarisi, başlangıcından sonuna doğru yükseklik ve genişlik boyutlarının azaldığı ancak derinliğin arttığı basit bir ağ mimarisidir (Huang vd., 2018). Bu modelin diğer modellere göre ayırt edici özelliği, evrişim katmanlarının ikili veya üçlü gruplar olarak kullanılmasıdır. VGG19 modeli, 16 evrişim katmanı, 5 havuzlama katmanı ve 3 tam bağlı katmandan oluşmaktadır.

### 3. MATERYAL VE METHOD

Öğrenme aktarımında amaç, yeni veri setine ait özelliklerin, ön-egitilmiş modeller aracılığı ile çıkarımının sağlanması ve bu özelliklerin, farklı makine öğrenmesi yöntemlerinde kullanılarak

amaca uygun yeni modellerin eğitilmesidir. Bunun için veri setinin ve bu sete uygun olabilecek ön eğitimli modellerin seçimi önemlidir. Bu çalışmada, COVID-19 Radiography Database (URL-1) adlı veri seti kullanılmıştır. Katar Üniversitesi, Dhaka Üniversitesi ile Pakistan ve Malezya'dan katılımcıların oluşturduğu bir araştırmacı grubu, medikal doktorlarla iş birliği kurarak COVID-19 ve viral pnömoni hastalığına sahip insanlardan elde edilen göğüs röntgeni içeren veri seti oluşturmuşlardır. Oluşturulan veri setine sağlıklı hastaların röntgenlerini de ekleyen araştırmacılar, 3 sınıflı bir veri seti elde etmişlerdir. Bu sınıflara ait örnek röntgen görselleri Şekil 2'de verilmektedir.



Şekil 2. (a) Covid, (b) normal ve (c) viral pnömoni sınıflarına ait röntgen görsellerinden örnekler

Bu çalışma kapsamında COVID-19 Radiography Database veri setinin öğrenme aktarımı yöntemi kullanılarak sınıflandırılmasında, 6 farklı ön eğitimli model kullanılmıştır. Seçilen veri setine ait bilgiler Tablo 1'de verilmiştir.

Tablo 1. Veri setinin özellikleri

Parametre	Değer
Sınıf Adedi	3
Sınıflar	covid, normal, viral pnömoni
Görüntü Adedi	2905

Tablo 2'de ise veri setine ait her bir sınıfın içerdiği görüntü adedi verilmektedir.

Tablo 2. Sınıflardaki görüntü sayısı

Sınıf	Görüntü Adedi
covid	219
normal	1341
viral pnömoni	1345

Farklı ön eğitimli modeller kullanılarak oluşturulan yeni yapay sinir ağı (YSA) tabanlı sınıflandırıcı modelin yapısı, Şekil 3'te görselleştirilmiştir. Ele alınan modellerin çıkışlarına, Şekil 3'te görüldüğü gibi 4 yeni sinirsel katman eklenmiştir. Eklenen bu katmanların ağırlıkları ile ele alınan modellerin bazı katmanlarına ait ağırlıklar, COVID-19 veri setine göre yeniden eğitilmiştir. Bu çalışmada ele alınan

modeller, modellerin katman sayıları ve giriş görüntü boyutları Tablo 3'te verilmiştir.

Tablo 3. Kullanılan ön-egitilmiş modellere ilişkin bilgiler


Ön-egitilmiş Model	Toplam Katman Sayısı	Giriş Görüntü Boyutu
InceptionV3	316	299x299
ResNet152V2	52	224x224
Xception	171	299x299
InceptionResNetV2	825	299x299
DenseNet201	709	224x224
VGG19	47	224x224

Oluşturulan sınıflandırıcının eğitimi için veri setinin %80'ine karşılık gelen 2325 adet görüntü, testi için ise %20'sine karşılık gelen 580 adet görüntü kullanılmıştır. Eğitim sırasında, tüm eğitim verilerinin ağı gösterilme sayısı (epok) 100 ve alt örneklerin sayısı ise 32 olarak seçilmektedir. Derin öğrenme uygulamalarında öğrenme işlemi, aslında bir optimizasyon problemidir. Öğrenme aşamasında kullanılan algoritmalar arasında global çözüme yaklaşım anlamında başarı ve performans farklılıkları bulunmaktadır. Bu sınıflandırma çalışmasında, sınıflandırıcı modelin ağırlıklarının eğitiminde optimizasyon algoritması olarak Adam algoritması seçilmiştir.



Eğitim aşamasında kullanılan optimizasyon algoritmalarının en iyi çözüme yaklaşmasını sağlayan parametrelerden biri, öğrenme katsayısıdır. Öğrenme katsayısının değeri, optimizasyon işleminin hızını ters orantılı olarak

etkilerken, yerel minimum noktalara takılma durumunda da rol oynamaktadır. Bu çalışmada, Adam optimizasyon algoritması için öğrenme katsayısı 0.00146 olarak belirlenmektedir.



Şekil 3. Ön-ēğitilmiş model kullanılarak oluşturulan sınıflandırıcı modeli

Hata fonksiyonu, tahmin edilen değerin asıl değere yakınlığına ilişkin bir değer döndürmektedir. Tahmin edilen değer, gerçek değere ne kadar yakınsa, hata fonksiyonunun sonucu da o kadar küçük olmaktadır. Bu çalışmada hata fonksiyonu olarak, çok sınıf içeren sınıflandırma problemlerine uygun olduğu için kategorik çapraz entropi seçilmektedir. Önerilen öğrenme aktarımı modellerinin eğitiminde kullanılan parametreler ve bu parametrelerin aldığı değerler Tablo 4'te verilmiştir.

Tablo 4. Modeller tarafından kullanılan parametreler ve değerleri


Parametre	Değer
Eğitim Verisi Oranı	%80 (2325 adet)
Doğrulama Verisi Oranı	%20 (580 adet)
Epok Sayısı	100
Alt Örnek Sayısı (Batch Size)	32
Optimizasyon Algoritması	Adam
Öğrenme Katsayısı	0.00146
Hata Fonksiyonu	Kategorik çapraz entropi


Tablo 3 ve Tablo 4'te verilen bilgiler kullanılarak oluşturulan öğrenme aktarımı modellerinin eğitimi, veri boyutunun büyüklüğünden ve eğitilecek parametre sayısının fazlalığından dolayı CPU üzerinde uzun zaman almaktadır. Bu sorunu aşmak için bu çalışmada oluşturulan modeller, Tesla T4 GPU donanımı kullanılarak eğitilmiştir. Bu sayede eğitim süreleri, GPU kullanmadan ulaşılabilecek sürelerle kıyasla yaklaşık olarak 15 ile 30 kat arasında kısaltılmıştır.

#### 4. BULGULAR VE TARTIŞMA

GPU üzerinde yapılan eğitim sürecinden elde edilen hata ve doğruluk grafikleri her model için ayrı ayrı oluşturulmuştur. Eğitim süreci InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2 ve DenseNet201 öğrenme aktarımı modelleri için yaklaşık olarak, sırasıyla, 9000, 10200, 10500, 5300, 9600, 8800 saniye sürelerinde tamamlanmıştır.

Şekil 4'te, InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 kullanılan sınıflandırıcı modellerin eğitimi için, sırasıyla, epoka karşılık hata ve doğruluk grafikleri verilmiştir.

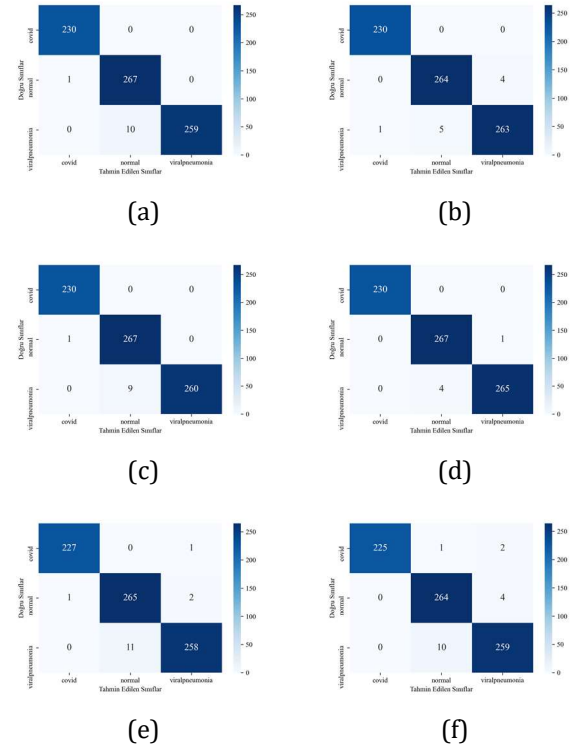




**Şekil 4.** InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 kullanılarak oluşturulan modeller için, sırasıyla, epoka karşılık (a, c, e, g, i, k) hata ve (b, d, f, h, j, l) doğruluk grafikleri

Şekil 4'te görüldüğü gibi, ilk epok için elde edilen en yüksek hata değeri VGG19'a dayalı model ile elde edilmişken, en düşük hata değeri ise DenseNet201'e dayalı model ile elde edilmiştir. ResNet152V2 kullanılan modelin hatayı minimize etme hızının, diğer modellere kıyasla daha düşük olduğu görülmektedir. Xception ve VGG19 kullanılan modeller ise yüksek doğruluk değerlerine en hızlı ulaşan modeller olmuşlardır. Şekil 4'te veriler grafikler kullanılarak, bu çalışmada kullanılan modellerin performansları, hata ve doğruluk açısından birbirleriyle ayrıca kıyaslanabilir. Şekil 5 (a) - (f)'de ise sırasıyla, InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 kullanılarak eğitilen öğrenme aktarımı modellerinin test verisi için elde edilen karışıklık matrisleri verilmiştir. Şekil 5 (a) - (f)'de görüldüğü gibi InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 modelleri kullanılarak eğitilen sınıflandırıcı modelleri, sırasıyla, 11, 10, 10, 5, 15 ve 17 adet veriyi yanlış sınıflandırmıştır. Bu doğrultuda en iyi sınıflandırma, InceptionResNetV2 kullanılarak oluşturulan model ile elde edilmiştir. Covid sınıfının doğru tahmini, diğer sınıflara göre daha önemlidir. Buna göre, InceptionResNetV2 ile oluşturulan sınıflandırıcı modeli, covid sınıfının tamamını doğru tahmin etmiştir. Yine covid sınıfının doğru sınıflandırılması açısından karşılaştırma yapıldığında, InceptionV3, Xception ve

ResNet152V2 ile oluşturulan modellerin DenseNet201 modelinden daha iyi sınıflandırdığı görülmektedir.



**Şekil 5.** (a) InceptionV3, (b) ResNet152V2, (c) Xception, (d) InceptionResNetV2, (e) DenseNet201 ve (f) VGG19 kullanılarak eğitilen öğrenme aktarımı modelinin doğrulama verisiyle elde edilen karışıklık matrisi

VGG19 ile oluşturulan model ise tüm modeller arasında covid sınıfını en çok yanlış sınıflandıran model olarak görülmektedir. Tablo 5'te görüldüğü gibi, eğitilen öğrenme aktarımı modellerinin test verisi için doğruluk oranları InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2, DenseNet201 tabanlı sınıflandırıcı modeller için sırasıyla %98.6, %98.7, %99.3, %97.8, %98.7 ve %98.0 olarak hesaplanmaktadır.

## 5. SONUÇLAR

Bu çalışmada, COVID-19 salgını sürecinde elde edilen göğüs röntgenlerinden oluşan 3 sınıflı veri setinin, öğrenme aktarımı yöntemi ile sınıflandırılması yapılmıştır. Bunun için öncelikle veri seti, kullanılacak öğrenme aktarımı modeline göre yeniden boyutlandırılarak ön işlemden geçirilmiştir. Daha sonra, ön-eğitilmiş modeller kullanılarak yeni sınıflandırıcı modeller oluşturulmuştur. Ön-eğitilmiş modellerde başlangıç ağırlıkları olarak ImageNet veri seti için elde edilmiş ağırlıklar kullanılmıştır. Ayrıca ele alınan modellerin bazı katmanları, yeniden eğitilebilir katman olarak belirlenerek eğitim performansı artırılmıştır. Oluşturulan sınıflandırıcı modelleri, Tesla T4 GPU donanımı kullanılarak eğitilmiştir.

Eğitim işlemi sonunda elde edilen modeller, test verileri kullanılarak test edilmiştir.

**Tablo 5.** Eğitilen öğrenme aktarımı modellerinin performanslarına ilişkin sayısal sonuçlar

Model	Doğruluk	Sınıflar	TN	TP	FN	FP
InceptionResNetV2 + YSA	0.993	Covid	537	230	0	0
		Normal	495	267	1	4
		Viral Pnömoni	497	265	4	1
Xception + YSA	0.987	Covid	536	230	0	1
		Normal	490	267	1	9
		Viral Pnömoni	498	260	9	0
ResNet152V2 + YSA	0.987	Covid	536	230	0	1
		Normal	494	264	4	5
		Viral Pnömoni	494	263	6	4
InceptionV3 + YSA	0.986	Covid	536	230	0	1
		Normal	489	267	1	10
		Viral Pnömoni	498	259	10	0
DenseNet201 + YSA	0.980	Covid	536	227	1	1
		Normal	486	265	3	11
		Viral Pnömoni	493	258	11	3
VGG19 + YSA	0.978	Covid	537	225	3	0
		Normal	486	264	4	11
		Viral Pnömoni	490	259	10	6

Önerilen 6 farklı modelden en yüksek doğruluğu veren sınıflandırıcı, %99.3 doğruluk oranıyla InceptionResNetV2 tabanlı model olmuştur.

Bu çalışma, öğrenme aktarımı yönteminin, hızlı bir şekilde yayılan COVID-19 salgınının tespitinde röntgen görüntüleri kullanarak, doktorlara ve araştırmacılara yardımcı olabileceğini göstermektedir. Bu sonuçlarla birlikte, hiper parametre optimizasyonu yapılarak ve daha farklı model yapıları kullanılarak veri setinin daha başarılı bir şekilde sınıflandırılmasının mümkün olabileceği değerlendirilmektedir.

#### KAYNAKÇA

- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Yustanti, W., Rakhmawati, L., Tjahyaningtijas H. P. A. ve Anistiyasari Y. (2020). Covid symptom severity using decision tree. *2020 Third International Conference on Vocational Education and Electrical Engineering (ICVEE)*, 1-5.
- Mishra, M., Parashar, V. ve Shimpi, R. (2020). Development and evaluation of an AI System for early detection of Covid-19 pneumonia using X-ray (Student Consortium). *2020 IEEE Sixth International Conference on Multimedia Big Data (BigMM)*, 292-296.
- Tabik S., Gómez-Ríos, A., Martín-Rodríguez, J. L., Sevillano-García, I., Rey-Area, M., Charde, D., Guirado, E., Suárez, J. L., Luengo, J., Valero-González, M. A., García-Villanova, P., Olmedo-Sánchez, E. & Herrera, F. (2020). COVIDGR dataset and COVID-SDNet methodology for predicting COVID-19 based on chest x-ray images. *in IEEE Journal of Biomedical and Health Informatics 2020*, 24(12), 3595-3605.
- Wang, X., Deng, X., Fu, Q., Zhou, Q., Feng J., Ma, H., Liu, W. & Zheng, C. (2020) A weakly-supervised framework for covid-19 classification and lesion localization from chest ct. *in IEEE Transactions on Medical Imaging 2020*, 39(8), 2615-2625.
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub Z. B., Islam, K. R., Khan, M. S., Iqbal, A., Emad, N. A., Reaz, M. B. I. & Islam M. T. (2020). Can AI help in screening viral and COVID-19 pneumonia?. *IEEE Access 2020*, 8, 32665-132676.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. & Wojna, Z. (2016) Rethinking the inception architecture for computer vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *2016*

*IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778.*

Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251-1258.

Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. *Thirty-First AAAI Conference on Artificial Intelligence*, 31(1).

Huang, G., Liu, Z., Maaten, L. v. d., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

Wang, S., ve Zhang Y. (2020). DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification. *ACM Transactions on Multimedia Computing Communications and Applications*, 16(2), 1-19.

Huang Z., Nasrullah, W. J., Song S., Mateen M. (2018). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, 11(1).

URL-1:

<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>

[Eriřim Tarihi: 15.11.2020]



Araştırma Makalesi

## HAVADA ve KARADA HAREKET EDEBİLEN 3 BOYUTLU TÜNEL HARİTALAMA ROBOTU

Eray SAKARYA\*, Ahmet ALKAN

Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik ve Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye

### Anahtar Kelimeler:

Tünel haritalama  
Görüntüleme  
Tespit

### ÖZ

Ultrasonik ses, frekansı 20.000Hz ile 1 GHz arasında olan ses dalgaları olup, işitilebilen seslere göre 100.000 kat daha fazla enerjiye sahiptir. Bu sebeple bu işaretler radar, sonar vb. cihazlarda kullanılabilir. Bununla birlikte ses dalgalarının yayılma hızı ortam yoğunluğuna ve sıcaklığına bağlıdır. Bu makalede askeri operasyonlarda güvenlik güçlerinden önce tünel ve benzeri dar ortamlara girerek, ortamın 3 boyutlu haritasını ultrasonik ses dalgaları kullanarak çıkartabilecek, üzerinde yön değiştirebilen kamera bulunan robotun çalışma prensipleri anlatılmıştır. Robot gerektiğinde karada paletle hareket edebilirken, gerekli görüldüğünde üzerinde mevcut kanatların açılmasıyla drone olarak havada seyredebilecektir. Kullanıcı tarafından kolaylıkla istenilen hedefe yönlendirilecek robotun elde ettiği bilgiler bilgisayarda tasarlanmış olan programa anlık olarak gönderilmektedir. Programda derlenen ve matematiksel işlemlerden geçirilen bilgiler, 3 boyutlu görsel tünel haritasına dönüştürülmek suretiyle operasyonu yürütenlerin kullanabileceği kullanışlı bir araç haline getirilmektedir. Kullanıcı kafasına taktığı kask yardımıyla kontrol ve keşif işlemlerini hızlı ve verimli bir şekilde yerine getirebilmektedir.

## 3-DIMENSIONAL TUNNEL MAPPING ROBOT MOVING IN AIR and ON LAND

### ABSTRACT

### Keywords:

Tunnel Mapping  
Visualization  
Detection

Frequency of ultrasonic sound varies between 20.000Hz and 1GHz and it has 100,000 times more energy than audible sounds. Therefore, these signals can be used on radar, sonar devices etc. However, the propagation speed of the sound waves depends on the ambient density and temperature. In this article, we explain that the operating principles of the robot, which can enter the tunnel and similar narrow areas before the security forces in the military operations, also it can produce the 3D map of the tunnel using ultrasonic sound waves. The robot will be able to navigate in the air as a drone with the opening of the existing wings, also it can move with pallets if there is no barrier on the way. The information obtained by the robot, which will be easily directed to the desired target by the user, and it is instantly sent to the program developed on the computer. Obtained information is passed through mathematical operations and it is converted into a 3D visual tunnel map, making it a useful tool for those performing the operation. The pilot can perform the control and detect processes quickly and efficiently with the help of a helmet on his head.

### \*Sorumlu Yazar

\* (eraysakarya118@hotmail.com) ORCID ID 0000-0003-1207-6881  
(aalkan@ksu.edu.tr) ORCID ID 0000-0003-0857-0764

e-ISSN: 2717-8579

Geliş Tarihi: 09/03/2021; Kabul Tarihi: 08/07/2021

Bilgisayar Bilimleri ve Teknolojileri Dergisi

## 1. GİRİŞ

Gelişen teknolojinin en önemli uygulama alanlarından birisi de askeri alandır. Devletler teknolojik gelişmişlik düzeylerini silahlı güçlerinin caydırıcılığını arttırmak için yoğun çaba sarf etmektedirler. Teknolojide önde olan ülkelerin, silahlı kuvvetlerinin de güçlü olması tesadüf olmayıp, bu teknolojik altyapıya dayanmaktadır. Dolayısıyla, günümüz savaşlarında birçok farklı teknolojik silah ve taktikler kullanılmaktadır.

Keşif robotları günümüzde askeri operasyonlar için çok önemlidir ve bir çeşitli versiyonları farklı ordular tarafından kullanılmaktadır. Bu robotların bazıları haritalama özelliklerine de sahiptir.

Dünya da ülkelerin savunma sanayii harcamaları coğrafi yapı, tehdit yoğunluğu ve ekonomik duruma göre farklılık göstermektedir [1]. Güçlendirilmiş beton kullanılarak yapılan sığınaklar veya yerin metrelerce altına kazılmış tünellerin düşük maliyetler ile keşfedilebilmesi, yüksek maliyetli beton delici mühimmatların kullanımını azaltabilecek olması sebebiyle oldukça önemlidir [2].

Ülkemizde savunma sanayii sektörü için Orta Vadeli Mali Plan kapsamında 2021 yılı bütçesi 138 milyar lira olarak öngörülmektedir. Bu kapsamda, ürünümüzün kullanılabilmesi için kurumlardan olan Millî Savunma Bakanlığına yaklaşık 61,5 milyar, Emniyet Genel Müdürlüğüne 44,6 milyar, Jandarma Genel Komutanlığına 27,7 milyar ve Cumhurbaşkanlığı Savunma Sanayii Başkanlığına 120,1 milyon TL kaynak tahsis edilmiştir.

Bu çalışmada görülmesi zor olan tünel, mağara vb. yerlere yapılacak operasyonlarda, operasyon yapan askerlerin can güvenliğini ve operasyonun etkisini arttıracak bir robot tasarlanmıştır. Bu tür hedefler tespit edildikten sonra ortam içerisindeki yolların keşfi, içeride herhangi bir düşmanın olup olmadığı, tünel içerisinde patlayıcı bir gaz olup olmadığı, tünel içerisinde daha önceden tuzaklanmış bir mayın olup olmadığı ve tünel duvarlarının kondisyonunun iyi olup olmadığı gibi durumların tespit edilmesi için askerlerden önce tünel girerek keşif yapacak bir robot projesi geliştirilmiştir.

Robotun en önemli görevi girdiği tünelin haritasını üzerindeki sensörlerden elde ettiği bilgileri yazılımsal olarak derleyerek en doğru 3 boyutlu haritayı, bilgisayarda hazırlanmış olan programa çizmesidir.

Canlı olarak görüntü aktarımı yapabilen, robot için özel olarak tasarladığımız, Görüntü Stabilizasyon Sistemi' ne entegre edilmiş kamera sayesinde, robot engebeli zeminde hareket ettiğinde, dahi pilot stabil görüntü alabilecektir. Bu sayede görüntüdeki bozulma minimum seviye indirilmiş olacak ve detaylar daha net bir şekilde görülebilecektir. Pilotun tünel içerisinde robotu hangi yöne ilerleteceğini anlayabilmesi için robot üzerindeki kamera modülünden gelen görüntüyü anlık olarak izleyebileceği bir FPV Gözlük

kullanılmıştır. FPV Gözlük için tasarlanan bir elektronik kart sayesinde pilotun hangi yöne baktığı belirlenip robotun üzerindeki kamera otomatik olarak pilotun baktığı yöne doğru dönmektedir.

Kumanda ile robot arasındaki sinyal herhangi bir sebepten ötürü kesilirse, robot tünel içerisinde sinyalin kesildiği ana kadar topladığı harita bilgisini ve üzerindeki sensörlerden gelen parametreleri hesaplayarak en kısa ve doğru şekilde başlangıç noktasına otonom olarak geri dönmektedir.

Çalışma süresince geliştirilen robot sayesinde can güvenliği artırılacak ve tünelin haritası çıkarılarak, güvenli olup olmadığının belirlenmesinin ardından içeriden imha edilebilecektir. Böylece operasyonlarda kullanılan yüksek maliyetli mühimmatların ekonomiye olan olumsuz etkisi azaltılabilecektir.

## 2. YÖNTEM

### 2.1. Karada Taşıma Sistemi

Sistemin karada taşınması için düşünülen Palet Sistemi aşağıdaki alt bölümlere ve belirtilen özelliklere sahip olacaktır. Sistemi oluşturan alt bölümler;

- Palet sistemi
- Enkoderli redüktörlü DC motorlar (palet sistemi için)
- DC motor sürücü kart
- Lityum-Polimer PİL

#### 2.1.1. Palet sistemi

Palet sistemi robotun ana taşıyıcı unsurudur. Paletli yürüyüş sistemi kullanılmakta olan asıl amacımız, diğer tekerlekli sistemlere göre yer ile arasındaki temas yüzeyinin daha fazla olmasıdır. Paletli yürüyüş sisteminin bir diğer avantajı ise herhangi bir aktarma organına (şaft, diferansiyel vb.) ihtiyaç duymadan çalışabilmesidir. Motorlar, Rim Dişlisi vasıtasıyla direkt olarak hareketi paletlere aktarır. Şekil 1.1' de görülen paletli tank şasisinin net ağırlığı 550 gramdır. Boyutları 30\*15\*7.6cm olan şasi üzerinde 300 gramlık faydalı yük taşıma kapasitesi mevcuttur. Bu sayede, farklı konfigürasyonlar ile askerlerin ihtiyaç duyabileceği önemli malzemeleri de taşıyabilecektir. Şase verileri Tablo 1.1' de verilmiştir.



Şekil 1.1. Paletli taşıyıcı sistem [3]

Tablo 1.1. Paletli şase verileri

Net Ağırlık:	550g
--------------	------

Palet Genişliği:	2.3cm
Boyutlar:	30cm*15cm*7.6cm

### 2.1.2. Redüktörlü DC motor

CHIAI MOTOR tarafından üretilen bu motor 6V DC gerilim ile çalışmaktadır. Motor üzerine entegre edilmiş redüktör sistemi vardır. Redüktör sistemi motor milinin dönüş hızını azaltır fakat motor gücünü artırır. Kullandığımız motor yüksüz halde 210 RPM ile çalışabilmektedir [4].

**Tablo 1.2.** DC motor özellikleri

Çalışma Gerilimi:	DC 6V
Yüksüz Hız:	210RPM 0.13A
Maksimum Verimlilik:	2.0kg.cm/170rpm/2.0W/0.60A
Maksimum Güç:	5.2kg.cm/110rpm/3.1W/1.10A
Durdurma Torku:	10kg.cm 3.2A
Redüksiyon Oranı:	1 :34

### 2.1.3. DC motor sürücü kart

TB6612FNG iki yönde de iki motoru birbirlerinden bağımsız olarak kontrol edebileceğiniz bir motor sürücü kartıdır. Bu sayede fırçasız motorun hız ve yön kontrolü yapılabilir [5]. 4.5 V- 13.5 V voltaj aralığında çalışan motor sürücü kanal başına sürekli olarak 1 A, zorlanma durumunda anlık olarak 3 A verebilir. Bu motor sürücü kart her bir palet (DC motor) için 1 er adet kullanılmıştır ve 2 kanallı olan kartın çıkışları paralel bağlanarak çıkış akım değerleri 2 katına çıkarılmıştır [6].

**Tablo 1.3.** DC motor sürücü verileri

Çalışma gerilimi:	4.5- 13.5 V
Çıkış akımı:	sürekli 1 A, anlık 3 A

### 2.1.4. Li-Po pil

Sisteme enerji vermek için Lityum-Polimer pil kullanılmıştır. Bu pil 14.8V, 1800mAh kapasiteye sahip olup, sürekli deşarj akımı ise 65C'dir. Bu sayede sürekli olarak 117A akım verebilmektedir [7]. Şarj edilebilir olan pil, robot üzerindeki modüler yapı sayesinde aynı özelliklere sahip başka bir pil ile de kolayca değiştirilebilmektedir.

**Tablo 1.4.** Li-Po pil verileri

Pil voltajı:	14.8V
Kapasite:	1800mAh
Boyutlar:	35*34*73mm
Sürekli Deşarj Oranı:	65C

Ağırlık:	177g
----------	------


## 2.2 Havada Taşıma Sistemi

Sistemin havada taşınması için düşünülen Drone Sistemi aşağıdaki özelliklere sahip olacaktır. Sistemi oluşturan alt bölümler;

- H şeklinde açılıp kapanabilen kanatlar
- Fırçasız motorlar (uçuş için)
- Pervaneler
- ESC (Fırçasız Motor Kontrolcüsü)
- Jiroskop, İvme ölçer, pusula, barometre sensörü.


### 2.2.1. H şeklinde açılıp kapanabilen kanatlar

Bu sistem tank palet sisteminin üzerine entegre edilmiştir. Palet sisteminin yetersiz kaldığı engelleri aşmak amacıyla tasarlanmış kanatların 4 köşesinde, üzerinde pervane bulunan fırçasız motorlar vardır. Pilot istediği anda palet sistemini kumanda üzerinden devre dışı bırakabilir.



**Şekil 2.1.** Kanatların teknik çizimi

Kanatların açılması için H şeklindeki formun orta noktasında dişliler kullanılmıştır. Bir DC motor yardımıyla bu dişliler hareket ettirilerek kanatlar açılır. Şekil 2.1' de görülen yapıda, sol üst ve sol alt kısımdaki daireler bir kol olarak birbirine bağlı olup, sağ üst ve sağ alt kısımdaki kareler kendi arasında birbirleriyle bağlantılıdır. (X şeklindeki yapının köşelerindeki kareler fırçasız motor yuvaları için çizilmiştir.)




**Şekil 2.2.** Kanat parçası

Şekil 2.1'deki konumda kanatlar kapalıdır. DC motor sayesinde H şeklindeki yapının orta noktasındaki dişliler doğru yönde hareket ettirildiğinde;

- 1- Sol kısımdaki kol, x yönünde,
- 2- Sağ kısımdaki kol, -x yönünde hareket edecektir.

Hareket tamamlandığında kanatlar düz bir çizgi şeklinde hizalanacaklardır. (Şekil 2.2'deki ölçüler ile motor yuvalarındaki ölçüler uyumludur.)

Bu sistemin yapılmasındaki asıl amaç, olası bir tünel haritalama senaryosunda kanatları kapatarak genişliği azaltıp, robotun tünel içerisinde daha rahat manevra yapabildiğini sağlamaktır.



Şekil 2.3. Kanatların açık hali

### 2.2.2. Fırçasız motorlar

Hava taşıma sisteminin en önemli kısmı olan fırçasız motorlar için Eachine markasının BR2205 modeli seçilmiştir. 5045 pervaneler ve 4s Li-Po pil ile 950 gram kaldırma kuvveti oluşturmaktadır ve tam güçte 27.6A akım çekmektedir [8].

### 2.2.3. Pervaneler

Tablo 2.2'deki 5045 değerindeki, 50: motor çapı, 4.5: hatve değeridir [9] Hatve değeri, pervanenin boşlukta bir tur attığında (bir kanat tekrar aynı noktaya geldiğinde) oluşan spiral şeklinin uzunluğudur. Hatve değeri pervanenin hücum açısı ile doğrudan orantılıdır. Hücum açısı veya hatve değeri arttıkça motor daha çok zorlanacağı için çektiği akım artar.

Tablo 2.1. Pervane verileri

Çap:	5 inç (~12cm)
Hatve:	4,5 inç
Malzeme:	Polikarbonat
Kütle:	5.3g
Göbek çapı:	5.02mm
Göbek kalınlığı:	7.95mm

### 2.2.4. ESC (fırçasız motor kontrolcüsü)

ESC fırçasız motorların hız kontrolü için kullanılır [10]. EMAX firmasının 30A'lık ESC'sinin seçilme sebebi, fırçasız motorların 5045 pervane ve 4S Li-Po pil konfigürasyonunda 27.6A'ya kadar akım çekebilmesidir. Bu hız kontrolcüsü üzerinden sürekli olarak 30A, anlık olarak ise 40A akım geçirebilmektedir [11]. Üzerinde dahili olarak bir voltaj regülatörü bulunan kontrolcüden 5V çıkış alınabilir.

### 2.2.5. Jiroskop, ivme ölçer, pusula, barometre sensörü

Bu sensör kartı üzerinde robotun otonom şekilde uçabilmesi için kontrol etmesi gereken parametreleri robota verir [12]. Üzerinde bulunan; LSM303D sensörü sayesinde x, y ve z eksenlerindeki eğim, ivme, ölçülebilir.

L3GD20 manyetik alan sensörü bir çeşit pusuladır ve Dünya'nın elektro manyetik alanını kullanarak, robotun Dünya üzerinde hangi yöne baktığını ölçebilir.

BMP180 ise atmosferik basınç sensörüdür. Ortamdaki hava basıncını ölçerek deniz seviyesinden yüksekliği ölçülebilir.


Tablo 2.2. IMU sensör verileri

LSM303D	
Gyro ölçüm aralığı:	250/500/2000 °/s
Açısal ivme ölçer ölçüm aralığı:	±2/±4/±6/±8/±16 g
L3GD20	
Ölçüm aralığı:	±2/±4/±8/±12 Gauss
BMP180	
Ölçüm aralığı:	300-1100 hPa (500-9000 metre)
Hassasiyet:	0.03 hPa (±25cm)
Besleme gerilimi:	3-5V

### 2.3. Görüntü Alma ve İletim Sistemi

Robotun görüntü aktarması için düşünülen Gimbal Sistemi aşağıdaki özelliklere sahip olacaktır. Sistemi oluşturan alt bölümler;

- FPV Kamera
- Görüntü Vericisi



Şekil 2.4. Gimbal sistemi

#### 2.3.1. FPV kamera



Sistemin stabil bir şekilde görüntü aktarması için Gimbal Sistemi tasarlanmıştır. Robotun asıl amacı olan harita çıkarmanın dışında, tünel içerisinde bulunması muhtemel olan hedef unsurların görüntüsünü de aktarması gerekmektedir. Stabil bir şekilde görüntü aktarabilmek için Gimbal Sistemine entegre edilmiştir. FPV Kamera F1.2 diyafram değerine sahip olup düşük ışıkta daha yüksek çözünürlük elde edilmesi amacıyla seçilmiştir [13].

**Tablo 3.1.** FPV kamera verileri

Giriş Voltajı:	5-20V
Güç Tüketimi:	27mA-105mA
Lux;	0.08Lux/ F1.2
Çalışma Sıcaklığı:	0- 40°C
Kamera Boyutları.	28 * 24.5 * 17.5mm
Lens Boyutu:	17 *14mm
Net Kütle:	10.4g
Format:	NTSC/PAL
Sensör:	1/3 "CCD

### 2.3.3. Görüntü vericisi

Eachine markasına ait DTX03 görüntü aktarıcı modülü sayesinde kameradan alınan görüntü, pilotun gözündeki gözlüğe veya elindeki ekrana iletilir. Tablo 3.3' de özellikleri belirtilen modülün çalışması istenilen güç ayarlanabilir. Mikro SD Kart takılabilen görüntü vericisi 200mW maksimum güce sahiptir [14].

**Tablo 3.2.** Görüntü vericisi verileri

Ürün Modeli:	Eachine DTX03
Frekans:	5.8GHz 9 bant 72 kanal, 5325-5945 MHZ
Micro SD Kart:	Maksimum 32GB (Class 10)
Video Format:	NTSC/PAL
Verici Gücü:	25/50/200mW
Çalışma Akımı:	7V-550mA / 12V-300mA / 24V-160mA
Video Bant Genişliği:	18MHz
Çalışma Voltajı:	DC7-24V
Çalışma sıcaklığı:	-10- 60 derece
Kütle:	6.97g
Boyutlar:	28 * 18.04mm

## 2.4. Haritalama Sistemi

Sistemin harita çıkarabilmesi için düşünülen "Haritalama Sistemi" aşağıdaki özelliklere sahip olacaktır. Sistemi oluşturan alt bölümler;

- GPS Modülü

- Analog Ultrasonik Mesafe Sensörü

### 2.4.1. GPS modülü


GPS modülü açık alanda pozisyon belirlemede yardımcı olması için kullanılmıştır. Açık alanda 5 metrelik bir hassasiyete sahip olan sensör, sıcak başlangıç özelliği sayesinde robot çalışmaya başladığında 30 saniye içerisinde hazır olmaktadır. Herhangi bir tünel haritalama görevinde GPS modülünün hassasiyeti tünel içerisinde azalacağından, tünel içerisindeyken pilot kontrollü olarak modülün gücü kesilebilmektedir. GPS modülü açık alanda pozisyon belirlemede yardımcı olması için kullanılmıştır. [15].

**Tablo 4.1.** GPS modülü verileri

Ürün Adı:	SAM-M8Q GPS Modülü
Boyutlar:	26 x 16 x 7.5 mm
Çalışma voltajı:	4~6V
Kütle:	7g

### 2.4.2. Analog ultrasonik mesafe sensörü

Şekil 4.2' de görülen sensör, bir çeşit hoparlör ve mikrofona sahiptir. Hoparlör ile ultrasonik ses dalgası yayar ve mikrofon ile ses dalgalarını dinler. Ses dalgasının bir cisme çarpıp dönmesi boyunca geçen süreyi kullanarak cismin ne kadar uzakta olduğunu algılar.



**Şekil 2.5.** Üç boyutlu harita çıkaracak sistem

450cm' ye kadar ölçüm yapabilen sensör robotun arka kısmında yere dik olacak şekilde konumlandırılmıştır [16]. Sensör bir servo motora entegre edilmiştir bu sayede, 180 derecelik bir açıyla tünelin içerisini tarayabilmektedir. Yazılımda ayarlanmış olan değere göre (örneğin robot her 10cm ilerlediğinde) tünelin içi tekrar taranmaktadır. Elde edilen tüm bu bilgiler bir bilgisayara gönderilerek hazırlanmış olan programda bir araya getirilir ve birleştirilir. Bu sayede tünelin 3 boyutlu haritası elde edilmiş olur.


**Tablo 4.2.** Ultrasonik mesafe sensörü verileri

Çalışma Voltajı:	5V(DC)
Ölçüm Mesafesi:	2cm-450cm
Ölçüm Açısı:	<15 derece

### 3. BULGULAR

Herhangi bir tünel haritalama görevinde, tünelin genişliği, yüksekliği, uzunluğu gibi parametreler haritanın çıkarılmasında gereklidir. Robotun arka kısmında dik bir şekilde yerleştirilmiş ultrasonik mesafe sensörü 180 derecelik açıyla, robot her 10 cm ilerlediğinde tüneli taramaktadır. Bu tarama bilgileri daha önceden yapılmış olan bilgisayar programına gönderilir.

Robotun ne kadar ileriye gittiğinin bilinmesi, taranan değerlerin programda hangi noktalara konulması gerektiğinin bilinmesi için önemlidir. Bu noktada robotun üzerindeki ivme sensörü ve saat modülü kullanılır.



Şekil 3. Parametrelerin hesaplaması

İlk ölçümün A noktasında yapıldığını varsayalım. b ve a uzunluklarının bulunması robotun bir sonraki analiz verisini bilgisayar programında hangi koordinatlara koyması gerektiğini bulabilmesi için gereklidir.

$$b = \frac{1}{2} \times a \times t^2 \quad (1)$$

b uzunluğunu bulmak için yukarıdaki denklemde görülen (1) formülünden yararlandık (a ivme, t süre). Süre değerini saat modülünden (zaman bilgisi modülün üzerinde bulunan dahili pil sayesinde enerji kesildiğinde dahi kaybolmaz), ivme değeri ise robot üzerindeki ivme sensöründen alınmaktadır.

a uzunluğunu bulmak için yükseklikteki değişimi bilmek yeterlidir. Bu değeri robot üzerindeki barometre sensöründen almaktayız. Yeni yükseklik bilgisinden önceki yükseklik bilgisi çıkarılarak yükseklikteki değişim pozitif veya negatif yönde hesaplanmış olur. Bu değer pozitif veya negatif olmasının bir farkı yoktur. Eğer değer negatif çıkarsa üçgen ters bir şekilde duracaktır yani robot tünel içerisinde aşağıya iniyor.

Son olarak c uzunluğu bulunarak bir sonraki tarama verisinin tam olarak nereye koyulacağı hesaplanmış olur (Bu değer çözünürlük değeridir ve yazılımsal olarak 10cm olarak ayarlanmıştır).

$$a^2 + b^2 = c^2 \quad (2)$$

Yukarıda görülen formülünden (2) hipotenüs hesaplanarak Şekil 3' te görülen B noktasının koordinatları hesaplanmış olur.

İvmenin bu hesaplamalarda kullanılması çok önemlidir çünkü eğer robot herhangi bir çamur vb. zemine saplanmışsa motorların dönmesi halinde bile ivmede bir değişim olmayacaktır. Bu yüzden 10cm yol alamadığında robot bulunduğu yerde tekrar bir ölçüm yapmayacaktır.

Ölçülen tünel analiz değerleri bilgisayarda hazırlanmış olan programa gönderilir ve tünelin 3 boyutlu çıktısı elde edilmiş olur.

Haritalama için geliştirilmiş benzer çalışmalar bulunmaktadır [17], [18], [19]. Yatay olarak yerleştirilmiş LİDAR sensörü kullanılan tasarımlarda 3 boyutlu haritanın çıkarılabilmesi için robotun uçarak düşey ekseninde de tarama yapması gerekmektedir. Yaptığımız çalışmada haritalam için kullanılan sensörün konumu sayesinde uçmasına gerek yoktur fakat sadece robotun geçtiği noktanın haritası çıkarılabilmektedir. Bu sebeple ortam haritasının çıkarılabilmesi için robotun tünel içerisinde ilerlemesi gerekmektedir.

İlerleyen çalışmalarda robot üzerinde bulunan ultrasonik mesafe sensörü LİDAR ile değiştirilerek 25 metre yapı çapındaki tünellerin haritalandırılması sağlanacaktır.

### 4. SONUÇLAR

Bu çalışmada insanların girmesinin tehlikeli olabileceği tünel vb. yapıların 3 boyutlu haritasını ultrasonik ses dalgaları kullanarak çıkarabilecek robot yapılmıştır. Robotun topladığı veriler, bilgisayardaki programa gönderilerek tünelin 3 boyutlu haritası çıkarılmış olur. Harita tamamlandıktan sonra harita içerisinde hareket edilebilmektedir. Bu çalışma 3 boyutlu tünel haritalama sisteminin başlangıcı niteliğinde olup, ileride yapılması planlanan çalışmalarda görüntü işleme teknolojisi kullanılarak tünelin duvar rengi vb. ayrıntılarında elde edilmesi hedeflenmektedir.



Şekil 4. Uygulama sonucu

### BİLGİLENDİRME/TEŞEKKÜR

Bu çalışmanın ilk hâli TÜBİTAK tarafından düzenlenen 2242 Üniversite Öğrencileri Araştırma Proje Yarışmalarında, Ankara Bölge ve Final Birinciliği derecesini elde ederek TEKNOFEST 2020' de sergilenmiştir. FPV Gözlük ilave edilmiş hâli ise TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı (2020-2) kapsamında desteklenmeye hak kazanmıştır.

#### KAYNAKÇA

[1]: <https://www.sipri.org/databases/milex>

[2]: Baran, T . (2018). TÜRKİYE'DE SAVUNMA SANAYİ SEKTÖRÜNÜN İNCELENMESİ VE SAVUNMA HARCAMALARININ EKONOMİ ÜZERİNDEKİ ETKİLERİNİN DEĞERLENDİRİLMESİ . Uluslararası İktisadi ve İdari Bilimler Dergisi , 4 (2) , 58-81 . DOI: 10.29131/uiibd.429369

[3]: [https://www.banggood.com/3V-9V-DIY-Shock-Absorbed-Smart-Robot-Tank-Chassis-Crawler-Car-Kit-With-260-Motor-For-Arduino-SCM-p-1184648.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/3V-9V-DIY-Shock-Absorbed-Smart-Robot-Tank-Chassis-Crawler-Car-Kit-With-260-Motor-For-Arduino-SCM-p-1184648.html?rmmids=search&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[4]:[https://www.banggood.com/6V-100210300RPM-Encoder-Motor-DC-Gear-Motor-p-1016183.html?rmmids=search&ID=519629&cur\\_warehouse=CN](https://www.banggood.com/6V-100210300RPM-Encoder-Motor-DC-Gear-Motor-p-1016183.html?rmmids=search&ID=519629&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[5]:<http://makina.deu.edu.tr/wp-content/uploads/10DCMotor>

[6]:[https://www.robotistan.com/tb6612fng-cift-motor-surucu-karti-yeni-versiyon-tb6612fng-dual-motor-dr?sgm\\_campaign=scn\\_6186b7935a026000&sgm\\_source=639&sgm\\_action=click](https://www.robotistan.com/tb6612fng-cift-motor-surucu-karti-yeni-versiyon-tb6612fng-dual-motor-dr?sgm_campaign=scn_6186b7935a026000&sgm_source=639&sgm_action=click)

[Erişim Tarihi: 08.03.2021]

[7]: [https://www.banggood.com/ZOP-Power-14-8V-1800mAh-65C-4S-Lipo-Battery-XT60-Plug-p-1089557.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/ZOP-Power-14-8V-1800mAh-65C-4S-Lipo-Battery-XT60-Plug-p-1089557.html?rmmids=search&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[8]: [https://www.banggood.com/4X-Racerstar-Racing-Edition-2205-BR2205-2300KV-2-4S-Brushless-Motor-For-QAV250-ZMR250-RC-Drone-FPV-Racing-p-1066837.html?rmmids=search&cur\\_warehouse=GWTR](https://www.banggood.com/4X-Racerstar-Racing-Edition-2205-BR2205-2300KV-2-4S-Brushless-Motor-For-QAV250-ZMR250-RC-Drone-FPV-Racing-p-1066837.html?rmmids=search&cur_warehouse=GWTR)

[Erişim Tarihi: 08.03.2021]

[9]: [https://www.banggood.com/7-Pairs-KingKong-5045-5-Inch-3-blade-Rainbow-Colorful-Propellers-CW-CCW-for-FPV-Racer-p-1067564.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/7-Pairs-KingKong-5045-5-Inch-3-blade-Rainbow-Colorful-Propellers-CW-CCW-for-FPV-Racer-p-1067564.html?rmmids=search&cur_warehouse=CN)

[1067564.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/7-Pairs-KingKong-5045-5-Inch-3-blade-Rainbow-Colorful-Propellers-CW-CCW-for-FPV-Racer-p-1067564.html?rmmids=search&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[10]:<http://abakus.inonu.edu.tr/xmlui/handle/11616/6190>

[11]: [https://www.banggood.com/EMAX-BLHeli-Series-6A-12A-20A-30A-ESC-p-963634.html?rmmids=search&ID=511756&cur\\_warehouse=CN](https://www.banggood.com/EMAX-BLHeli-Series-6A-12A-20A-30A-ESC-p-963634.html?rmmids=search&ID=511756&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[12]: <https://www.robotistan.com/lsm303dl3gd20bmp180-10dof-sensor-karti>

[Erişim Tarihi: 08.03.2021]

[13]: [https://www.banggood.com/Eachine-1000TVL-13-CCD-110-Degree-2-8mm-Lens-Mini-FPV-Camera-NTSC-PAL-Switchable-p-1053340.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/Eachine-1000TVL-13-CCD-110-Degree-2-8mm-Lens-Mini-FPV-Camera-NTSC-PAL-Switchable-p-1053340.html?rmmids=search&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[14]: [https://www.banggood.com/Eachine-TX5258-5-8G-72CH-25200500800mW-Switchable-FPV-Transmitter-Support-OSD-Configuring-p-1248768.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/Eachine-TX5258-5-8G-72CH-25200500800mW-Switchable-FPV-Transmitter-Support-OSD-Configuring-p-1248768.html?rmmids=search&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[15]: [https://www.banggood.com/Matek-Systems-M8Q-5883-SAM-M8Q-GPS-QMC5883L-Compass-Module-for-RC-Drone-FPV-Racing-p-1337288.html?rmmids=search&cur\\_warehouse=CN](https://www.banggood.com/Matek-Systems-M8Q-5883-SAM-M8Q-GPS-QMC5883L-Compass-Module-for-RC-Drone-FPV-Racing-p-1337288.html?rmmids=search&cur_warehouse=CN)

[Erişim Tarihi: 08.03.2021]

[16]: <https://www.robotistan.com/hc-sr04-ultrasonik-mesafe-sensoru>

[Erişim Tarihi: 08.03.2021]

[17]: Akyol, S , Uçar, A . (2019). Rp-Lidar ve Mobil Robot Kullanılarak Eş Zamanlı Konum Belirleme ve Haritalama . Fırat Üniversitesi Mühendislik Bilimleri Dergisi , 31 (1) , 137-143 . Retrieved from <https://dergipark.org.tr/tr/pub/fumbd/issue/43638/534772>

[18]: Rizzo, C., Tardioli, D., Sicignano, D., Riazuelo, L., Villarroel, J. L., & Montano, L. (2013). Signal-based deployment planning for robot teams in tunnel-like fading environments. The International Journal of Robotics Research, 32(12), 1381-1397.

[19]: White, C., Hiranandani, D., Olstad, C. S., Buhagiar, K., Gambin, T., & Clark, C. M. (2010). The Malta cistern mapping project: Underwater robot mapping and localization within ancient tunnel systems. Journal of Field Robotics, 27(4), 399-411.



Araştırma Makalesi

## Makine Öğrenmesine Dayalı Mobil İngilizce Öğrenme Uygulaması

Esracan Güngör<sup>1</sup>, Sinem Ak<sup>1</sup>, Zeynep Orman<sup>\*1</sup>

<sup>1</sup> İstanbul Üniversitesi - Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

### Anahtar Kelimeler:

Makine öğrenmesi  
Yapay sinir ağı  
İngilizce öğrenme  
Mobil uygulama

### ÖZ

Günümüzde yabancı dil bilmek, artık bir tercihten çok zorunluluk haline gelmiştir. Yurt dışında okumak, internet üzerinden çevrim içi derslere katılmak, staj ve gönüllü projelerde yer almak isteyenler için yabancı dil bilgisi gerekli bir koşul haline almıştır. Bugün işverenler arasında en çok aranan becerilerden biri olan yabancı dil bilgisi denilince akıllara ilk gelen İngilizce olmaktadır. Eğitim amaçlı mobil uygulamalar, bir dil kursuna gitmeden veya yurt dışında eğitim görmeden yeni bir dil öğrenmenin en iyi yollarından biridir. Günümüzde yabancı dil öğrenmek giderek kolaylaşmaktadır. Buna en büyük katkı, kuşkusuz mobil uygulama ve akıllı telefon kullanımının artmasından kaynaklanmaktadır. Bu makale çalışması ile ana dili İngilizce olmayan kişiler için İngilizce öğrenimini kolaylaştırmak ve her an ulaşılabilirliğini arttırmak amacıyla makine öğrenmesine dayalı bir mobil İngilizce öğrenme uygulaması geliştirilmiştir. Bu çalışmanın özgün değeri, uygulama başında kullanıcıya uygun gruptaki seviye sınavının yapay sinir ağı yöntemi ile seçilip sunulması ve uygulama içinde yer alan kelime-anlam eşleştirme alıştırmasında İngilizce kelimelerin kullanım sıklıklarına göre zorluk seviye gruplarının Mini Batch K-Means yöntemi ile belirlenmesidir.

## Mobile English Learning Application Based on Machine Learning

### Keywords:

Machine learning  
Artificial neural network  
English learning  
Mobile application

### ABSTRACT

Being proficient in a foreign language has become an obligation rather than a preference. It is of utmost importance to be proficient in a foreign language for those who want to study abroad, participate in online classes, get internships, and take part in voluntary projects. English is the first language to come to mind when asked about foreign language skills, which is one of the most sought-after skills by employers. The best method to learn a foreign language without signing up for a language course or study abroad is through educational mobile applications. Nowadays it is getting easier to learn new languages. This is due to the contributions of mobile applications and the rising rate of smartphone usage. In this study, a mobile English learning application based on machine learning has been developed with the aim of making learning English easier and more accessible to those whose first language is not English. The genuine value of this study is that it picks and presents the corresponding fluency level exam according to the user via artificial neural network at the beginning of the application and sorts the vocabulary of the word-meaning matchup exercise into difficulty levels depending on their frequency of use by Mini Batch K-Means method.

### \*Sorumlu Yazar

<sup>\*</sup>(esracangungor@gmail.com) ORCID ID 0000-0003-2611-8122  
(sinem\_ak98@outlook.com) ORCID ID 0000-0002-3978-1866  
(ormanz@iuc.edu.tr) ORCID ID 0000-0002-0205-4198

## 1. GİRİŞ

Mobil teknoloji sadece yaşam tarzımızı değil, aynı zamanda öğrenme şeklimizi de değiştirmiştir. Bu açıdan mobil öğrenme, mobil teknolojinin tek başına veya diğer bilgi ve iletişim teknolojileriyle birlikte kullanılması anlamına gelir, böylece öğrenme her yerde ve her zaman gerçekleştirilebilir. Günümüzde mobil öğrenme, esnek öğrenme fırsatları ve gelişen mobil teknolojilerle etkili bir öğrenme modeli haline gelmiştir (Bozkurt, 2015).

Son elli yılda yapılan incelemelerin gösterdiği gibi, eğitim, toplumun diğer alanlarına ve insan faaliyetlerine benzer şekilde, teknolojik gelişmelerden önemli ölçüde etkilenmiştir. Bu türden kapsamlı bir ilerleme alanı, eğitimde yapay zekâ uygulamaları olmuştur. Bu alan son 25 yılda daha fazla büyümüş olup bilgisayar bilimleri ve eğitim alanında edinilen yeni bilgileri içermektedir. Eğitim değerlendirmesinde, bu yeni metodolojiler, yüksek hızlı veri ağları ve geleneksel testlere ihtiyaç duymadan değerlendirmeler için geniş bir veri yelpazesinin yönetimini sunarak süreçlerinin tüm yönlerini iyileştirmiştir (Rodríguez-Hernández vd., 2021).

Adriana Teodorescu tarafından yapılan çalışmada, mobil öğrenmenin etkinliğini ve iş İngilizcesi öğrenimi üzerindeki etkisini değerlendirmektedir. Öğrencilerin, sadece çevrim içi sosyalleşmekle kalmayıp aynı zamanda mobil öğrenme araçlarını hem profesyonel hem de özel hayatlarında kullanarak sürekli eğitim ile iş İngilizcesi bilgilerini de geliştirdikleri doğrulanmıştır. Sonuç olarak, mobil öğrenmenin öğrenme etkinliğini, bilginin transferini ve paylaşımını, öğrencilerin güvenini ve benzer şekilde ilgisini arttırdığına inanılmaktadır (Teodorescu, 2014).

V.O. Oladokun, A.T. Adebajo, B.Sc., ve O.E. Charles-Owaba tarafından yapılan çalışmada, üniversiteye kabul edilmek üzere düşünülen bir adayın olası performansını tahmin etmek için bir yapay sinir ağı modeli geliştirilmiş, test edilmiş ve bir öğrencinin performansını etkileyebilecek çeşitli faktörler belirlenmiştir. Test verileri değerlendirmesinde, yapay sinir ağı modelinin aday öğrencilerin %70'inden fazlasının performansını doğru bir şekilde tahmin edebildiğini gösterilmektedir. Yapılan bu çalışmayla, yapay sinir ağının bir üniversiteye kabul sisteminin etkinliğini artırma potansiyeli gösterilmiştir (Oladokun vd., 2008).

Mariel F. Musso, Eva Kyndt, Eduardo C. Cascallar ve Filip Dochy tarafından yapılan çalışmada, yapay sinir ağları kullanarak öğrenci performansının öngörücü modellerini tasarlamak için arka plan bilgileriyle birlikte öğrencilerin bilişsel ve bilişsel olmayan ölçümleri kullanılmıştır. Sonuçlar, yapay sinir ağının diskriminant analizleri gibi geleneksel yöntemlerle karşılaştırıldığında

daha yüksek doğruluğunu göstermektedir (Musso vd., 2013).

İzzettin Aydoğan ve Gürol Zırhlıoğlu tarafından yapılan çalışmada, yapay sinir ağının kestirim (tahmin) alanındaki yeteneğini akademik başarı ile buluşturup yapay sinir ağı kullanılarak öğrenci başarılarını erken kestirebilen bir model geliştirilmesi hedeflenmiştir. Modelin geliştirilmesinde öğrenci verileri kullanılmış ve öğrencilerin başarı ölçüleri kestirilmiştir (Aydoğan ve Zırhlıoğlu, 2018).

Carlos Felipe Rodríguez-Hernández, Mariel Musso, Eva Kyndt ve Eduardo Cascallar tarafından yapılan çalışmada ilgili araştırma hedefi, öğrencilerin performansının ve deneyiminin değerlendirilmesidir. Çalışmada geliştirilen model test aşamasında, yüksek performans grubu için öğrencilerin %82'sini ve düşük performans grubu için öğrencilerin %71'ini doğru bir şekilde sınıflandırmıştır. Yaptıkları çalışmada, yüksek öğretimde akademik performansın tahmini öğretmenlere, öğrencilere, politika yapıcılara ve kurumlara çeşitli faydalar sağladığı savunulmaktadır (Rodríguez-Hernández vd., 2021).

Noor Mohd Ariff Brahin, Haslinah Mohd Nasir, Aiman Zakwan Jidin, Mohd Faizal Zulkifli ve Tole Sutikno tarafından yapılan çalışmada 4 yaşından büyük çocukların İngilizce ve Arapça öğrenmelerine yardımcı olmak için mobil uygulama geliştirmiştir. Uygulama, çıktı sonucunu tahmin etmek için Android Studio ve makine öğrenimi tekniği olan TensorFlow nesne algılama uygulama programlama arayüzü kullanılarak geliştirilmiştir. Geliştirilen sistem, "LearnWithIman" adlı çocuk dil öğrenme uygulaması ile çekilen görüntünün tahminini yüksek doğrulukla gerçekleştirebilmektedir (Brahin vd, 2020).

Bu makale çalışmalarının dışında makine öğrenmesini kullanan çeşitli mobil uygulamalar bulunmaktadır. Duolingo uygulamasında dil öğrenmeyi eğlenceli ve ilgi çekici hale getirmek için yapay zekâ, makine öğrenimi ve oyunlaştırma kullanılmaktadır. Uygulama, performansın yanı sıra kullanımı da izler ve kullanıcıya hangi zorlukların verileceğini bulmak için aralıklı tekrarlama yöntemi kullanılmaktadır ve öğrenilen bir şeyin ne zaman unutulacağını da tahmin edebilir. Uygulama, bir şeyi doğru veya yanlış anlama olasılığını hesaplayabilen "kuş beyin" olarak bilinen bir makine öğrenme işlevi kullanılmaktadır. Sistem doğru bir yanıt alacağını düşünürse, başarı şansının yalnızca yaklaşık %70 olduğunu tahmin ettiği için kullanıcıya bir meydan okuma verecektir. (URL-4)

Lingvist, yapay zekâ ve makine öğrenimi tarafından desteklenen bir mobil uygulamadır. Uygulamanın ücretsiz sürümü, kullanıcıya istenilen dilin en yaygın 3.000'e kadar kelimesini öğretmektedir. Dersler, daha önce yapılan hatalara dayalı olarak ilerledikçe gelişmektedir. Lingvist aralıklı tekrar yöntemini kullanılmaktadır. Sık sık yanlış yapılan kelimeleri yeniden kullanır ve zaten öğrenilen kelimeleri hızla geçer. (URL-4) Lingvist'in

yöntemi, kelimeye dayalı bir ezber bölümü içerir. Şirketin yazılımı, belirli bir dildeki kelimelerin sıklığını belirlemek için altyazılar veya makaleler gibi çeşitli metin kaynaklarını analiz eder. Lingvist, en alakalı kelimelerden başlayarak kullanıcılara hızlı bir şekilde öğretmeye çalışır. Meraklılar için dilbilgisi referansları olsa da Lingvist dilbilgisini öğretmekle ilgili değil, dili doğal olarak kullanıldığı gibi öğretmekle ilgilidir. (URL-5)

Blue Canoe mobil uygulaması, öğrencilere telaffuzları hakkında kişiselleştirilmiş geri bildirim sağlamak için makine öğrenimi destekli konuşma tanıma özelliğini kullanmaktadır. Uygulama ayrıca, kullanıcıların hangi ses ve sözcüklerde zorlandıklarını belirler ve çalışanların öğrenmelerini takip edebilmeleri için işverenlere bir puan vermektedir. Kullanıcılar, üç ay boyunca üzerinde çalışmak istedikleri üç beceriyi seçerler ve uygulama, ilerledikçe performanslarına göre üç ila on dakikalık etkinlikler önermek için makine öğrenimini kullanılmaktadır. Bir öğrenci birden fazla aktiviteyi tamamladıysa ve hala bir beceri ile mücadele ediyorsa, o zaman bir antrenöre erişebilmektedir. (URL-6)

ELSA Speak, dil öğrenenlerin kullandıkları kelimeler, cümleler, konuşmalarındaki yanlışlıkları ve telaffuz hatalarını anında tespit eden ve nasıl düzeltilecekleri konusunda anlık olarak geri bildirim sağlayan yapay zekâ teknolojisine sahip İngilizce telaffuz koçudur. (URL-7) ELSA, bireysel ses seviyeleri, tonlama, ritim ve perdedeki kesin hataları belirleyebilir ve bu hataların nasıl düzeltileceği konusunda anında geri bildirim ve öneriler sağlamaktadır. Tüm geri bildirimler, derin öğrenme algoritmalarına dayalı tescilli konuşma tanıma teknolojisi kullanılarak tamamen otomatikleştirilmektedir. ELSA, doğal dil işleme çerçevesi ile dışarıdan herhangi bir yardım almadan kullanıcılara yüzde 95 doğrulukla rehberlik etmektedir. Ayrıca, daha fazla netlik için resimleme öğelerinin yanı sıra düzgün cümle oluşturmayı sağlayan bir sözlüğe de sahiptir. (URL-8)

Uzaktan eğitimin önem kazandığı bu dönemde, yapılan bu makale çalışması ile literatürdeki diğer çalışmalara benzer bir şekilde bir yapay sinir ağı geliştirilerek kullanıcının İngilizce seviyesi, yapay sinir ağı ile tahmin edilmiştir. İngilizce kelime bilgisinin geliştirilmesinde verimliliğin artması için İngilizce kelimeler Mini Batch K-Means kullanılarak kullanım sıklıklarına göre gruplandırılmıştır.

Makalenin ilerleyen bölümlerinde işleyiş şu şekilde düzenlenmiştir. İkinci bölümde kullanılan yöntemlerden yapay sinir ağı, Mini Batch K-Means ve veri setlerinden, üçüncü bölümde önerilen sistemin nasıl gerçekleştirildiğinden detaylı bir şekilde bahsedilmiştir. Dördüncü bölümde ise yapay sinir ağı modelinin performansına ve tahmin sonuçlarına, Mini Batch K-Means ile gruplandırma sonucuna yer verilmiştir. Çalışmanın sonuçlarının tartışıldığı sonuç adımına ise beşinci bölümde değinilmiştir.

## 2. YÖNTEM

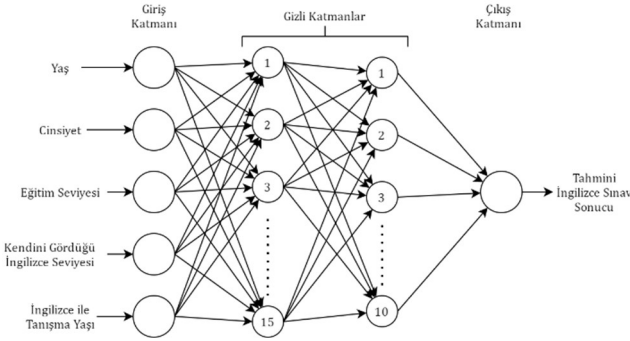
Makine öğrenmesi algoritmalarından yapay sinir ağı, kullanıcıların İngilizce seviyelerini tahmin etmede ve kümeleme algoritmalarından olan Mini Batch K-Means algoritması kelimelerin zorluk seviyesine göre gruplandırılmasında kullanılmıştır.

### a. Yapay Sinir Ağı

Makine öğrenme algoritmalarından biri olan yapay sinir ağı öğrenme algoritması, bir formda verilen veriyi anlamak ve genellikle başka bir formda istenen çıktıya dönüştürmek için bir ağ kullanan hesaplamalı bir öğrenme sistemidir. Yapay sinir ağları, öğrenme sürecinin matematiksel olarak modellenmesi sonucu ortaya çıkmıştır ve insan beynindeki biyolojik sinir ağlarının yapısını, öğrenme, hatırlama ve genelleme kabiliyetlerini taklit etmektedir. Yapay sinir ağları; teşhis, sınıflandırma, tahmin, kontrol, veri ilişkilendirme, veri filtreleme ve yorumlama gibi alanlarda kullanılmaktadır (URL-1).

Katmanlar şeklinde kurulmuş bir yapı olan sinir ağlarının ilk katmanı giriş katmanı, son katmanı çıkış katmanı olarak adlandırılır. Giriş katmanı ile çıkış katmanı arasında bulunan katmanlar ise gizli katmanlar olarak adlandırılmaktadır. Bir yapay sinir ağı içerisinde sadece giriş katmanı ve çıkış katmanı yer alıyorsa bu sinir ağına tek katmanlı sinir ağı, içerisinde gizli katmanlar içeriyor ise bu sinir ağına çok katmanlı sinir ağı denmektedir. Sinir ağına bulunan her katmanda belirli sayıda düğüm (node) bulunmaktadır. Yapay sinir ağı modeline BEST veri setinde bulunan yaş (age in years), cinsiyet (gender), eğitim seviyesi (maximum education level), kişinin kendini tahmin ettiği İngilizce seviyesi (self-perceived English level), kişinin İngilizce diliyle tanışma yaşı (age of acquisition) değişkenleri girdi olarak; İngilizce test (Lextale test) sonucu ise istenilen çıktı sonucu olarak verilmiştir. Bu veriler ile denetimli öğrenme gerçekleştirilerek bir yapay sinir ağı modeli oluşturulmuş ve eğitilmiştir. Yapılan mobil uygulamada kullanıcıdan alınan bilgiler bu modele verilerek kullanıcının test sonucu tahmin edilmektedir. Oluşturulan yapay sinir ağının modeli Şekil 1'de verilmiştir. Model bir giriş katmanı, iki gizli katman ve bir çıkış katmanından oluşmaktadır. Giriş katmanında beş düğüm, çıkış katmanında ise bir düğüm bulunmaktadır. İlk gizli katmanda on beş düğüm, ikinci gizli katmanda ise on düğüm yer almaktadır. Giriş katmanındaki düğüm sayısı sistem içerisindeki girdilerin sayısına eşittir. Aynı şekilde, çıkış katmanındaki düğüm sayısı da istenilen çıktı sayısı ile belirlenebilmektedir. Uygulama için geliştirilen yapay sinir ağı modelinde gizli katmanlarda yer alacak nöron sayısını belirlemek sorundur. Geleneksel matris algoritması, matris boyutlarının ya giriş sayısına ya da çıkış sayısına eşit olması gerektiğini belirtmektedir. Ancak, gizli

katmanda en verimli şekilde kaç tane düğümün bulunacağı konusunda herhangi bir matematiksel yöntem bulunmamaktadır. Gizli katmandaki nöron sayısının belirlenmesinde genellikle deneme ve yanılma yöntemi kullanılmaktadır (URL-9). Bundan dolayı çalışmada gizli katmanlardaki düğüm sayıları deneme yanılma yöntemi ile belirlenmiştir. İkinci gizli katmanda yer alan düğümler, çıkış katmanında yer alan bir düğüme bağlanmaktadır. Çıkış katmanında yer alan düğüm, kullanılan veri setindeki İngilizce test sonucunun tahmini sonucunu vermektedir.



Şekil 1. Yapay sinir ağı modeli

## b. Mini Batch K-Means

Mini Batch K-Means, bir veri setinde benzer özellikler gösteren verilerin gruplara ayrılmasında kullanılır. K-Means, zaman olarak iyi performansı nedeniyle en popüler kümeleme algoritmalarından biridir. Analiz edilen veri kümelerinin artan boyutuyla birlikte, ana bellekteki tüm veri kümesine ihtiyaç duyması K-Means algoritmasının hesaplama süresini artırır. Bu nedenle, algoritmanın zamansal ve hafıza maliyetlerini azaltmak için çeşitli yöntemler önerilmiştir. Mini Batch K-Means algoritması bunlardan biridir (URL-2).

Mini Batch K-Means, algoritmasının ana fikri, hafızada saklanabilmeyi kolaylaştırabilmek için sabit boyutta küçük rastgele veri yığınları kullanarak büyük boyuttaki veri kümesini hafızada saklanabilecek hale getirmek anlamına gelir. Her bir iterasyonda, veri setinden yeni bir rastgele örnek alınır, bu örnek kümeleri güncellemek için kullanılır ve bu işlem yakınsama sağlanana kadar tekrarlanır.

SUBTLEX-UK veri seti içerisinde bulunan LogFreq (Zipf) ve CDcount değerleri kullanarak kelimeler, kullanım sıklığına göre Mini Batch K-Means yöntemi ile İngilizce yetkinlik seviyelerinden A1, A2, B1, B2 ve C1 seviyelerini belirtmek amacıyla beş gruba ayrılmıştır. İyi bir eğitim almış olan ve ana dili İngilizce olan bir kişi, teknik olarak C2 seviyesinde olduğundan dolayı kişinin İngilizce öğrenme uygulamasına ihtiyaç duymayacağı düşünülmüş bu nedenle C2 seviyesi çıkarılarak kelimelerin beş gruba ayrılmasına karar verilmiştir.

Zipf yasası veya dilde tutumluluk yasası, matematiksel istatistik biliminden türetilen deneysel bir yasa olarak ifade edilmektedir. Dil bilim kanununa göre, yazılı metindeki kelimeler

azalan sıklığa göre (yani en çok kullanılan kelimedenden en az kullanılan kelimeye) sıralanırsa, sonuç listesindeki tek bir kelimenin sayısı ve sayısı kelimenin geçtiği yerlerin oranı her zaman sabit bir sayı olacaktır. (URL-3).

Walter J. B. van Heuven, Pawel Mandera, Emmanuel Keuleers ve Marc Brysbaert tarafından yapılmış olan SUBTLEX-UK çalışmasında Zipf değerleri aşağıda 1'de verilen denklem ile hesaplanmıştır:

$$\text{Zipf} = \log_{10} \left( \frac{\text{frequency\_count}}{201.336 + .159} \right) + 3.0 \quad (1)$$

LogFreq (Zipf), tüm altyazılar içinde kelimenin frekans değerini gösteriyorken, CDCount tüm altyazılarda kelimeyi içeren yayın sayısını göstermektedir. LogFreq, ve CDCount değerlerinin Logaritma 10 tabanında almamızın sebebi değer aralıklarını küçülterek daha doğru sonuçlar çıkmasını sağlamaktır.

## c. Veri Setleri

Bu makale çalışmasında iki veri setinden yararlanılmıştır.

### i. The best dataset of language proficiency (BEST)

Angela de Bruin, Manuel Carreiras ve Jon Andoni Duñabeitia tarafından hazırlanan bu çalışma, Bask Ülkesinden çok sayıda İspanyolca-Bask-İngilizce çok dilli kişilerin geçmişlerinin ve dil becerilerinin bir fonksiyon olarak kullanılması ile katılımcı seçimi ve sınıflandırmayı kolaylaştıracak bir norm veri seti sunmaktadır. BEST veri seti adını Basque, English, and Spanish Tests'den almaktadır. Bu veri seti üç dil bloğuna bölünmüş dört farklı alt testten bilgi içermektedir. 435'i kadın olan 650 katılımcıdan oluşan bir grup çeşitli dil yeterlilik ölçümlerinden geçmiştir. Katılımcıların yaşları 18 ile 50 arasında değişmektedir. Testin gerçekleştiği zamana ait maksimum eğitim düzeyi lise ile üniversite arasında değişmesine rağmen katılımcıların çoğunluğu (%80) daha yüksek bir eğitim düzeyine, mesleki eğitim, üniversite veya yüksek lisans derecesine sahiptir. Veriler, Ocak 2015'ten başlayıp Haziran 2016'da sona eren 18 aylık bir dönem boyunca toplanmıştır. Tablo 1'de katılımcı numarası (participant number), yaş (age), cinsiyet (gender), eğitim seviyesi (maximum educational level), kişinin kendini tahmin ettiği İngilizce seviyesi (self-perceived English level), İngilizce ile tanışma yaşı (age of acquisition) İngilizce test sonucu (lextale test) gibi veri setinden alınmış bazı örnek veriler gösterilmiştir (de Bruin vd., 2017).

Veri setinde eksik, bozuk veya gürültülü değer olmadığından dolayı veri setine sadece kategorik değerlerin nümerik değerlere çevrilme işlemi uygulanmıştır. Veri setinde yer alan cinsiyet ve

eğitim seviyesi sütunlarının kategorik değerler içermesinden dolayı bu değerler sayısal değerlere

çevrilmiştir.

**Tablo 1.** The Best Dataset Of Language Proficiency veri seti

PARTICIPANT NUMBER	AGE	GENDER	MAXIMUM EDUCATIONAL LEVEL	SELF PERCEIVED LEVEL	AGE OF ACQUISITION	LEXTALE TEST ENGLISH
1	22	Female	High School	5	5	58,75
2	21	Female	University	7	5	72,5
3	39	Female	Professional Training	7	12	60
4	20	Male	University	2	6	61,25
5	23	Male	University	7	6	66,25

## ii. SUBTLEX-UK: A new and improved word frequency database for British English

Walter J. B. van Heuven, Pawel Mandera, Emmanuel Keuleers ve Marc Brysbaert tarafından yapılmış olan SUBTLEX-UK, İngiliz televizyon programlarının altyazılarında geçen kelimelere göre kelime frekanslarını sunmaktadır. İngiltere düzenlemelerine uygun olarak, 2008'den beri British Broadcasting Corporation (BBC), işitme engellilere yardımcı olmak için programlanmış tüm programları kendi ana kanallarında altyazı koymaktadırlar. Mümkün olan en geniş dil girdisi aralığına sahip olmak için, üç yıllık bir süre (Ocak 2010 - Aralık 2012) boyunca yayınlanan dokuz kanaldan (BBC1 - BBC4, BBC News, BBC Parliament, BBC HD, CBeebies ve CBBC) altyazılarından kelime ve kelime çiftleri toplanmıştır. Bu veri seti içerisinde kullanılan sütunlar ve içerisinde bulunan bazı veriler Tablo 2'de verilmiştir (van Heuven vd., 2014).

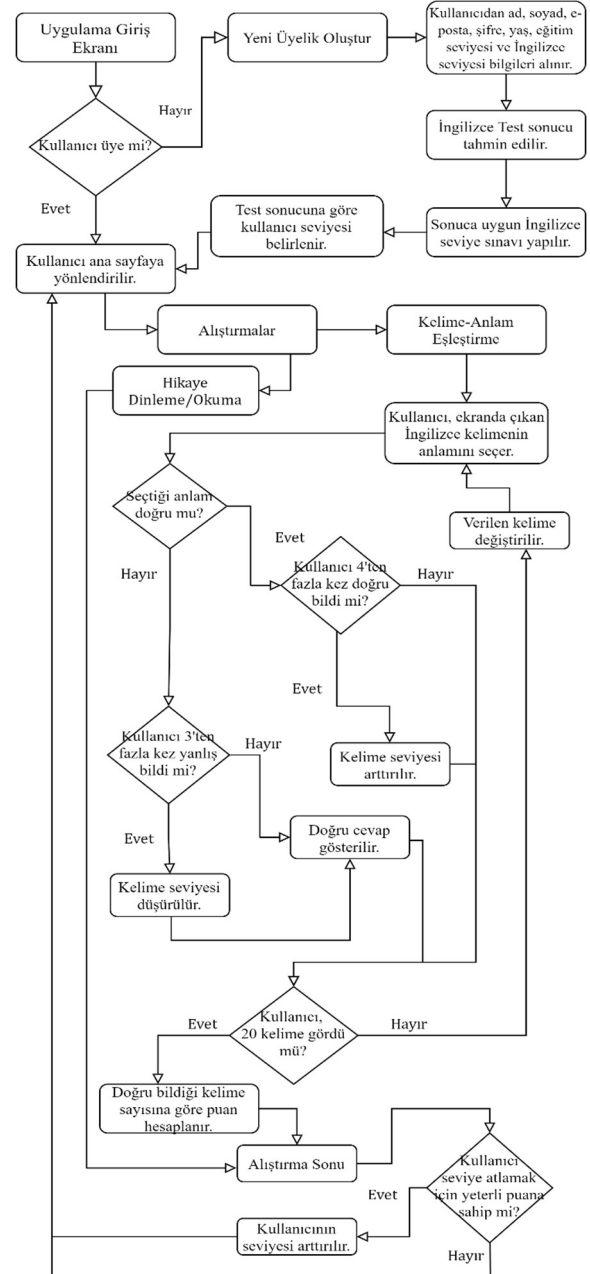
**Tablo 2.** SUBTLEX-UK veri seti

Spelling	LogFreq (Zipf)	CDcount
labour	5,35	8196
programme	5,2	15482
favourite	5,13	13805
colour	5,05	10120
realise	4,89	11118
honourable	4,84	1513

## 3. ÖNERİLEN SİSTEM

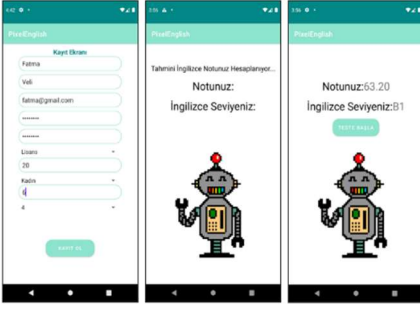
Şekil 2'de verilen Flow-Chart diyagramına göre uygulama açıldığında kullanıcının üye olup olmadığı kontrol edilir. Kullanıcı üye ise kullanıcı girişi yapılır ve kullanıcı ana sayfaya yönlendirilir. Kullanıcı kayıtlı değil ise, yeni üyelik oluşturmak için kayıt sayfasına yönlendirilir. Şekil 3'te gösterildiği üzere kullanıcıdan ad, soyad, e-posta, şifre, yaş, eğitim seviyesi ve İngilizce seviyesi bilgileri alınır. Bu bilgilere dayalı olarak İngilizce test sonucu tahmin edilir. Tahmin edilen

İngilizce test sonucuna uygun olan İngilizce seviye sınavı, kullanıcıya yapılır. Sınav sonucu kullanıcının seviyesi olarak belirlenir.



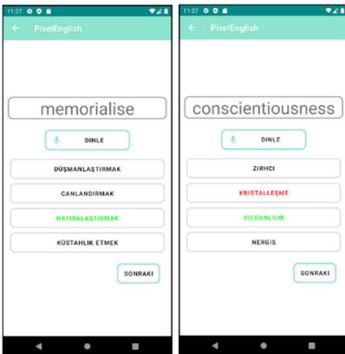
**Şekil 2.** Sistemin işleyini gösteren akış diyagramı





Şekil 3. Mobil uygulama üzerinde tahmin sayfalarının arayüzü

Alıştırmalar sayfasına giren bir kullanıcı; hikâye dinleme/okuma ve kelime-anlam eşleştirme alıştırmalarına geçiş yapabilir. Bu makale çalışmasında hikâye alıştırmalarıyla ilgili ayrıntılara değinilmemiştir. Şekil 4'te verilen kelime-anlam eşleştirme alıştırmalarına giren bir kullanıcının karşısına İngilizce bir kelime çıkar. Kullanıcı çıkan ekranda verilen kelimeye uygun olan anlamı seçer. Seçilen anlamın, verilen İngilizce kelimenin gerçek anlamı olup olmadığına bakılır. Eğer kullanıcının seçtiği anlam doğru ise kullanıcının üçten fazla kez yanlış cevap verip vermediği kontrol edilir. Kullanıcı beş kez doğru cevap vermiş ise kelimelerin zorluk seviyesi artırılır, vermemiş ise kelimelerin zorluk seviyesi değiştirilmez. Kullanıcının seçtiği anlam yanlış ise kullanıcının üç veya üçten fazla kez yanlış bilip bilmediğine bakılır. Kullanıcı, üç veya üçten fazla kez yanlış bildiyse kelime zorluk seviyesi düşürülür ve kullanıcıya doğru cevap gösterilir. Kullanıcı üç veya dört kez doğru cevap vermişse ise kelime zorluk seviyesi değiştirilmez ve kullanıcıya doğru cevap gösterilir. Bu işlemler yapıldıktan sonra kullanıcının yirmi kelime için kelime-anlam eşleştirilmesi yapıp yapmadığı kontrol edilir. Eğer kullanıcı yirmiden az sayıda kelime eşleştirmiş ise kullanıcıya gösterilen kelime değiştirilir. Kullanıcı yirmi sayıda kelime eşleştirmişse alıştırma bitirilir, kullanıcının doğru bildiği kelime sayısına göre puan hesaplanır ve alıştırma sonu sayfasına yönlendirilir.



Şekil 4. Kelime-anlam eşleştirme alıştırmalarının arayüzü

Alıştırma sonu sayfasından sonra kullanıcının seviye atlamak için yeterli puana sahip olup olmadığı kontrol edilir; yeterli puana sahip ise kullanıcı seviyesi artırılır, değilse kullanıcının

seviyesi değişmez. Kullanıcı ana sayfaya geri yönlendirilir.

#### 4. BULGULAR

Model eğitiminde eğitim-test bölümü (train-test split) yaklaşımında modelde kullanılacak olan veri seti eğitim ve test olarak ikiye ayrılır. Eğitim seti ile model kurulur ve test seti üzerinden modelin performansı değerlendirilir. Bu yöntemle farklı eğitim-test bölümleri sonucunda farklı doğruluk oranı değerleri elde edilmektedir. Model performansı en yüksek doğruluk oranı veren bölünmeye göre değerlendirilir ve model bu bölünmeye göre değerlendirildiği için farklı bölünme oranları deneme yanılma yöntemi ile denenmektedir (Anita Rác vd., 2021; Xu ve Goodacre, 2018). Bu durumdan kaçınabilmek için en temel Çapraz Geçerlilik (Cross-Validation) yöntemlerinden olan K-Fold çapraz doğrulama yöntemi kullanılmıştır. Daha iyi sonuç alınması için veri seti üzerinde 3 Fold ve 5 Fold denenip karşılaştırılmıştır. Tablo 3'te veri setinde yer alan bazı verilerin yaş (age), cinsiyet (gender), eğitim seviyesi (maximum educational level), kişinin kendini tahmin ettiği İngilizce seviyesi (self-perceived English level), İngilizce ile tanışma yaşı (age of acquisition) İngilizce test sonucu (lextale test) ile yapay sinir ağı fold=3 ve fold=5 elde edilen tahminler yer almaktadır. K-Fold çapraz doğrulamasında 3 Fold olduğunda RMSE (Root Mean Square Error, Ortalama Karekök Sapması) sonucu yaklaşık olarak 9,14 ve 5 Fold olduğunda RMSE sonucu 8,85 olmaktadır. RMSE değeri, gerçek parametre ile kestirilen parametreler arasındaki farkların ortalamasının karekökünü ifade etmektedir (Soysal ve Kelecioğlu, 2018). RMSE değeri sıfırdan sonsuza kadar değişebilmektedir ve değer sıfıra ne kadar yakınsa model o kadar başarılıdır. 5 Fold değerinin sonucu, 3 Fold değerinden daha düşük olduğu için 5 Fold daha başarılıdır.

Tablo 3. BEST veri setindeki sonuçlar ile yapay sinir ağının yaptığı tahminlerin karşılaştırılması

AGE	21	20	24	28
GENDER	Female	Female	Male	Male
MAXIMUM EDUCATIONAL LEVEL	University	University	University	Postgraduate
SELF-PERCEIVED ENGLISH LEVEL	7	4	8	7
AGE OF ACQUISITION	7	6	7	9
LEXTALE TEST	68,75	65	73,75	85
NEURAL NETWORK PREDICTION (FOLD=3)	87,34	67,92	98,58	96,35

NEURAL NETWORK PREDICTION (FOLD=5)	71,02	63,2	81,39	83,04
------------------------------------	-------	------	-------	-------

Geliştirilen yapay sinir ağı modelinin performansını ölçmek için kullanılan doğruluk (accuracy) hesabı aşağıda 2’de verilen formülle hesaplanmaktadır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN} \quad (2)$$


DP: Doğru Pozitif

DN: Doğru Negatif

YN: Yanlış Negatif

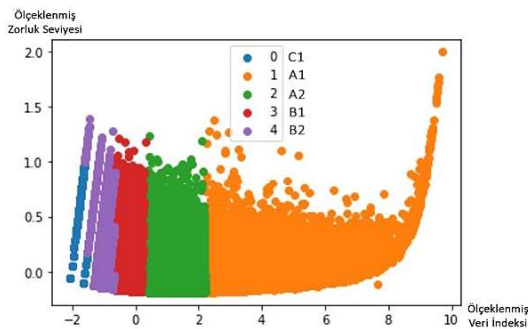
YP: Yanlış Pozitif

Doğruluk hesabı yapıldığında yapay sinir ağı modeli, %76,23 oranında başarılı sonuç elde etmektedir. Şekil 5’te BEST veri setindeki veriler ile tahmin edilen sonuçların karşılaştırılması verilmiştir. Verilen şekilde kırmızı çizgiler gerçek sonuçları, mavi çizgiler ise tahmin edilen sonuçları vermektedir. Grafikte X eksen 0’dan 650’ye olan veri sayısını, Y eksen ise 40 ile 100 arasında değişen test sonuçlarını temsil etmektedir.



Şekil 5. Yapay sinir ağı modelinin tahmin ettiği sonuçlarla gerçek sonuçlarının karşılaştırılması

Şekil 6’da Mini Batch K-Means ile yapılan kümeleme işleminin grafik üzerinden gösterimi verilmiştir. Verilen grafikte mavi renk ile gösterilen 0 değeri C1 seviyesini, turuncu renk ile gösterilen 1 değeri A1 seviyesini, yeşil renk ile gösterilen 2 değeri A2 seviyesini, kırmızı renk ile gösterilen 3 değeri B1 seviyesini, mor renk ile gösterilen 4 değeri B2 seviyesini temsil etmektedir. Grafikte Python’ın scatter metodunun kendi ölçeklediği değerler Y ekseninde zorluk seviyesi, X ekseninde veri indeksi olarak verilmiştir.



Şekil 6. İngilizce kelimelerin Mini Batch K-Means ile kümelemesi

Mini Batch K-Means kümeleme işlemi sonucunda elde edilen her zorluk seviyesinden 2’şer örnek seçilmiş ve bu örnekler için kelimenin yazılışı (spelling), tüm altyazılar içinde kelimenin frekansı (LogFreq(Zipf)) tüm altyazılarda kelimeyi içeren yayın sayısı (CDCcount) , Batch K-Means kümeleme işlemi sonucunda elde edilen zorluk seviyesi (level) Tablo 4’te gösterilmiştir.

Tablo 4. Seviyelerine göre kümelemiş kelimelerden örnekler

Spelling	LogFreq (Zipf)	CDcount	Level
labour	5,35462437	8196	1
programme	5,200220181	15482	1
vaporiser	3,149054066	40	2
stabiliser	2,883256447	82	2
draughtsmen	2,654777119	13	3
armours	2,339188403	6	3
doubler	1,951008231	4	4
factorise	1,871826985	4	4
fruiterers	1,926184648	2	0
ormers	1,598825713	2	0

## 5. SONUÇ

Günümüzde yaşanan olağanüstü pandemi durumunda özellikle uzaktan eğitimin önemi artmıştır. Uzaktan eğitimin bir parçası olan mobil öğrenme günümüz koşullarında sıklıkla kullanılmaktadır. Mobil cihazların taşınabilirliği, iletişim becerileri bu cihazların daha esnek ve daha etkili öğrenme araçları olmaları mobil eğitimi öne çıkaran özelliklerdendir. Ek olarak, mobil cihazlar öğrenciler arasındaki etkileşimi, kaynaklara erişimi ve bu kaynakların transferini önemli ölçüde etkilemektedir. Mobil öğrenme uygulamalarının mevcut uygulamalar arasında yetersizliği göz önünde bulundurularak geleneksel işleyişin aksine her kullanıcıya aynı seviye belirleme testinin yapılması yerine kullanıcıdan alınan kriterlerle kullanıcının İngilizce seviyesi yapay sinir ağı ile tahmin edilerek uygun görülen seviye belirleme testi sunan bir mobil uygulama geliştirilmiştir. Kullanıcıların seviyelerinin tahmin edilmesi için K-Fold çapraz doğrulaması kullanılarak yapay sinir ağı modeli oluşturulmuş ve eğitilmiştir. K-Fold çapraz doğrulamasında kullanılan fold=5 değeri ile elde edilen RMSE sonucu 8,85’tir. Yapay sinir ağı modelinin performansı, doğruluk hesabı kullanılarak ölçülmüştür ve sonucu %76,23 olarak bulunmuştur. Yapılan mobil uygulamada kelime-anlam eşleştirme alıştırmalarında kullanılan veri setinde İngiliz televizyon programlarında geçen kelimeler, geçtiği sayı ve frekansları kullanılmıştır. Bu kelimeler zorluk seviyesine göre Mini Batch K-

Means yöntemi ile gruplandırılmıştır. Kullanıcının belirli bir sayıda yaptığı doğru veya yanlışlara göre seviyesi artan veya azalan kelimeler kullanıcıya sunulmuştur. Bu yöntemle kullanıcıların tek bir seviyeye bağlı kalmadan kelime dağarcığının geliştirilmesi hedeflenmiştir. Geliştirilen mobil uygulamanın daha ilgi çekici hale getirmek için hikâye okuma ve dinleme, kelime oyunu gibi alıştırmalar da eklenmiştir.

#### KAYNAKÇA

Bozkurt, D. (2015). Mobil Öğrenme: Her zaman, Her Yerde Kesintisiz Öğrenme Deneyimi, *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 1 (2), 65-81.

Rodríguez-Hernández, C.F., Musso, M.F., Kyndt, E. & Cascallar, E.C. (2021), Artificial Neural Networks in Academic Performance Prediction: Systematic Implementation And Predictor Evaluation, *Computers & Education: Artificial Intelligence*, (2).

Teodorescu, A. (2014), Mobile Learning And Its Impact On Business English Learning, *Procedia - Social and Behavioral Sciences*, 180, 1535-1540.

Oladokun, V.O., Adebajo, A.T., B.Sc., & Charles-Owaba, O.E. (2008), Predicting Students' Academic Performance using Artificial Neural Network: A Case Study of an Engineering Course, *The Pacific Journal of Science and Technology*, 9 (1), 72-79.

Musso, M.F., Kyndt, E., Cascallar, E.C. & Filip Dochy (2013), Predicting General Academic Performance And Identifying The Differential Contribution Of Participating Variables Using Artificial Neural Networks, *Frontline Learning Research*, 1(1), 42-71.

Aydoğan, İ. & Zırhloğlu, G. (2018), Öğrenci Başarılarının Yapay Sinir Ağları ile Kestirilmesi, *YYÜ Eğitim Fakültesi Dergisi*, 15(1), 577-610.

de Bruin, A., Carreiras, M. & Duñabeitia, J.A. (2017), The BEST Dataset of Language Proficiency, *Front Psychol.*, 8, 522.

van Heuven, W.J.B., Mandera, P., Keuleers, E. & Brysbaert, M. (2014), SUBTLEX-UK: A new and improved word frequency database for British English, *The Quarterly Journal of Experimental Psychology*, 67 (6), 1176-1190.

Soysal, S. & Kelecioğlu, H. (2018), Toplam Test ve Alt Test Puanlarının Kestiriminin Hiyerarşik Madde Tepki Kuramı Modelleri ile Karşılaştırılması, *Eğitimde ve Psikolojide Ölçme ve Değerlendirme Dergisi*, 9 (2), 178-201.

Brahin, N. M. A., Nasir, H. M., Jidin, A. Z., Zulkifli, M. F. & Sutikno, T. (2020), Development Of Vocabulary Learning Application By Using Machine Learning Technique, *Bulletin of Electrical Engineering and Informatics*, 9(1), 362-369.

Xu, Y., & Goodacre, R. (2018), On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning, *Journal of Analysis and Testing* 2, 249-262.

Rác, A., Bajusz, D., & Héberger, K. (2021), Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification, *Molecules* 2021, 26(4),1111.

URL-1: <https://deepai.org/machine-learning-glossary-and-terms/neural-network>  
[Erişim Tarihi: 05.05.2021]

URL-2: <https://medium.com/@ekrem.hatipoglu/machine-learning-clustering-k%C3%BCmeleme-k-means-algorithm-part-13-be33aeef4fc8>  
[Erişim Tarihi: 21.04.2021]

URL-3: [https://tr.wikipedia.org/wiki/Zipf\\_yasas%C4%B1](https://tr.wikipedia.org/wiki/Zipf_yasas%C4%B1)  
[Erişim Tarihi: 03.05.2021]

URL-4: <https://innovationatwork.ieee.org/improve-your-english-with-artificial-intelligence-powered-apps/>  
[Erişim Tarihi: 17.07.2021]

URL-5: <https://en.wikipedia.org/wiki/Lingvist>  
[Erişim Tarihi: 17.07.2021]

URL-6: <https://trainingindustry.com/articles/learning-technologies/theres-an-app-for-that-machine-learning-based-apps-for-english-language-training/>  
[Erişim Tarihi: 17.07.2021]

URL-7: <https://www.hotenglish.com.tr/ingilizce-konusma.aspx>  
[Erişim Tarihi: 17.07.2021]

URL-8: <https://www.expresscomputer.in/industries/education/how-ai-speech-recognition-tech-are-helping-non-native-english-speakers/64053/>  
[Erişim Tarihi: 17.07.2021]

URL-9: <https://dergipark.org.tr/tr/download/article-file/165799>  
[Erişim Tarihi: 17.07.2021].



Derleme Makalesi

## Büyük veri analitiği için yüksek performans hesaplama: çözüm ortamları ve kodlama

Hamza Erol\*<sup>1</sup>

<sup>1</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

### Anahtar Kelimeler:

Küresel ekonomi  
Ekonominin akıllı yönetimi  
Akan büyük veri  
Çok katmanlı büyük veri  
Büyük verinin hacmi  
Büyük verinin karmaşıklığı  
Anaconda  
NetworkX  
PySpark  
PyCuda  
Google Colabratory

### ÖZ

Bu çalışmada akan veya katmanlı büyük veri, hacmi ve karmaşıklığı tanımlanmıştır. Büyük veri analitiğinde kullanılan; Tek işlemci- tek çekirdek yapısı: standart hesaplama mimarisi; Tek işlemci- çok çekirdek yapısı: paralel hesaplama mimarisi ve Çok işlemci- çok çekirdek yapısı: dağıtık hesaplama mimarisi biçimindeki yüksek performans hesaplama sistemleri açıklanmıştır. Bu sistemlerde kullanılan hesaplama ortamları incelenmiştir. Donanım hesaplama ya da donanım hızlandırılmış hesaplama ve Yazılım hesaplama ya da yazılım optimize edilmiş hesaplama konuları vurgulanmıştır. Büyük veri analitiğinde uygulanan öğrenme yöntemleri: istatistiksel öğrenme, makine öğrenme ve derin öğrenme ifade edilmiştir. Bu öğrenme yöntemlerinin sonuç veya ürün odaklı uygulamaları olarak yapay zekâ açıklanmıştır. Akan veya katmanlı büyük veri analitiğinde web tabanlı çözüm ortamı olarak Google Colabratory ve bu ortamda kod geliştirmede Python uygulamaları verilmiştir.

## High performance computing for big data analytics: solution environments and coding

### Keywords:

Global economies,  
Intelligent management of  
the economy  
Stream big data  
Multilayer big data  
Size of big data  
Complexity of big data  
Anaconda  
NetworkX  
PySpark  
PyCuda  
Google Colabratory

### ABSTRACT

Stream or multilayered big data, size and complexity is defined in this study. High performance computing systems used in big data analytics; Single processor - single core structure: standard computing architecture; Single processor - multi core structure: parallel computing architecture and Multi processor - multi core structure: distributed computing architecture are explained. Computing environments used in these systems have been examined. Hardware computing or hardware acceralated computing and software computing or software optimized computing are emphasized. Learning methods applied in big data analytics: statistical learning, machine learning and deep learning were expressed. Artificial intelligence has been explained as the result or product-oriented applications of these learning methods. Google Colabratory as a web-based solution environment in stream or multilayered big data analytics and Python applications for code development in this environment have been given.

\*Sorumlu Yazar

(herol@mersin.edu.tr) ORCID ID 0000 - 0001 - 8983 - 4797

## 1. GİRİŞ

Dünya ekonomilerinde tüketim için yeterli miktarda hızlı ve fazla sayıda endüstriyel üretim amacıyla Endüstri 4.0 aşamasına geçmiştir. Endüstri 4.0 endüstriyel üretim için robot teknolojilerini, uydu teknolojilerini ve sensör teknolojilerini kullanır. Büyük veri endüstriyel veridir (Gökalp vd., 2016). Endüstri 4.0 ile büyük veri kavramı küresel dijital ekonominin akıllı yönetiminde kullanılmaya başlanmıştır. Günümüzde ekonominin akıllı yönetimi büyük anlam ve önem kazanmıştır. Büyük verinin ekonomik değeri hesaplanabilir. Büyük veri sensörler, robotlar, uydu teknolojileri ve akıllı teknolojiler kullanılarak toplanır. Analog olarak alınan veriler datalogger kullanılarak sayısallaştırılır. Büyük veri katmanlardan oluşur. Büyük veri katmanlı veri olarak tanımlanır.

Büyük verinin özellikleri: (i) Genişliğine büyük veri: veride değişken sayısının fazla olması durumudur. (ii) Derinliğine büyük veri: veride gözlem sayısının fazla olması durumudur. (iii) Hem genişliğine hem de derinliğine büyük veri. (iv) Akan büyük veri: sürekli derinliğine gözlem değeri alınması durumudur. (v) Katmanlı büyük veri: değişken özellik gruplarının birleşiminden oluşan veridir. Büyük verinin katmanlı olması, hacminin büyüklüğü ve karmaşıklığı önemlidir. Büyük veri analitiğinde karmaşıklık: (i) Veri karmaşıklığı (ii) Hesaplama karmaşıklığı ve (iii) Bilgi karmaşıklığı olmak üzere incelenir (Erol ve Erol, 2018). Büyük veri analitiği; veri analizini ve veri modellemeyi kapsar. Büyük veri analitiği: (1) Verinin analitik için hazırlanması, (2) Verideki değişkenlerin ilişkilendirilmesi, (3) Verinin şekillendirilmesi, (4) Veriye anlam kazandırılması ve (5) Verinin bilgiye dönüştürülmesi aşamalarından oluşur (Erol ve Korkmaz, 2020).

Büyük veri analitiği, küresel ekonomilerde şirketlerin daha iyi kararlar alması için önemli ilişkisel yapıları, modelleri, eğilimleri ve tercihleri keşfetmek amacıyla büyük veri kümelerinde gelişmiş bilişim teknolojilerinin kullanılmasıdır. Endüstri 4.0'da büyük veri analitiği, bakım ve onarım işlemlerine ne zaman ihtiyaç duyulacağını tahmin etmek için üretim makinelerinden gelen sensör verilerinin analiz edildiği akıllı fabrikalar dahil birçok alanda rol oynar (Vassakis vd., 2018). Küresel ekonomilerinde üreticiler, bulut bilişim ve nesnelerin interneti platformları aracılığıyla sensörlerden topladıkları büyük miktardaki veriyi tedarik zinciri yönetiminin verimliliğini arttıracak yapısal kalıpları ortaya çıkarmak için büyük veri analitiğini kullanır (Thelin, 2020).

Büyük verinin önemini ve değerini Yuval Noah Harari yaşamın geleceği olarak ifade etmiştir. Bunu: "Geçtiğimiz yüzyıllarda dünyanın geçer akçesi toprak ve araziydi; fakat artık büyük veri ve verinin geleceği sadece insanın geleceğini değil, yaşamın geleceğini belirleyecek" şeklinde ifade etmiştir (İnternet Kaynağı 1, 2018).

## 2. YÖNTEM

### 2.1. Büyük Verinin Analitiğinin Küresel Ekonomilerde Kullanımı

Küresel ekonomilerde ekonominin akıllı yönetimini büyük veri analitiği kullanarak gerçekleştirenlerden biri de Avrupa Birliği ülkeleridir. Avrupa komisyonunun belirlediği ekonominin sektörlerinde 27 sektör bulunmaktadır. Tüm sektörlerde büyük veri analitiği kullanılmaktadır (İnternet Kaynağı 2, 2020). Avrupa komisyonunun hazırladığı ekonominin sektörleri listesinde 1 ile 11 maddelerinin belirlenmesinde paydaşlar; 12'den 27'ye kadar olan sektörlerin belirlenmesinde paydaşların danışmanları katkı sağlamıştır.

### 2.2. Büyük Verinin Toplanması

Küresel ekonomilerinde ekonominin akıllı yönetiminde veri toplama önemli kavramdır. Büyük veri sensörler, robotlar, uydu teknolojileri ve akıllı teknolojiler kullanılarak toplanır. Analog olarak sensörler vasıtasıyla alınan veriler dataloggerlar kullanılarak sayısallaştırılır ve fiziksel disk üzerine aktarılır. Tarım sektöründe akıllı tarım uygulamaları çerçevesinde toplanan çok bantlı uydu görüntü verileri Erol vd. (2018) tarafından çalışılmıştır. Bu uydu görüntüsü yer istasyonunda bulunan görüntüleme sistemi kullanılarak alınmış ve daha sonra sayısallaştırılmıştır. Sayısallaştırılan uydu verisi akan büyük veridir. Büyük verinin analitiği yapılarak tarımsal bölgede tarımsal ürünlerin rekolte tahminleri yapılmıştır. Tarım sektöründe akıllı tarım uygulamaları çerçevesinde yine toplanan çok bantlı SpectroRadiometer sensör verileri Erol vd. (2017) tarafından çalışılmıştır. SpectroRadiometer sensör verisi bağlı olduğu bilgisayardaki yazılımla sayısallaştırılmıştır. Sayısallaştırılan SpectroRadiometer sensör verisi akan büyük veridir. Büyük verinin analitiği yapılarak tarımsal bölge yetiştirilen farklı mısır çeşitlerinde nişasta, yağ gibi farklı ürünlerin verimliliklerinin performans karşılaştırmaları yapılmış ve bu ürünlerin rekolte tahminleri gerçekleştirilmiştir.

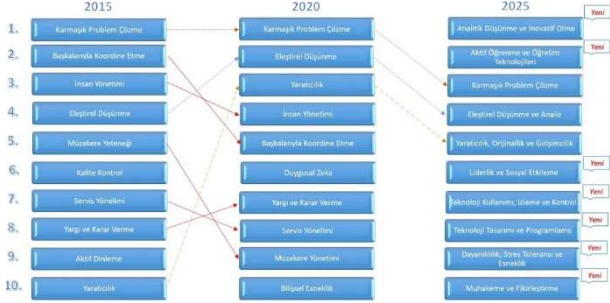
### 2.3. Büyük Verinin Analitiğinin Yapılmasında Mesleklerin Önemi

2019 yılında gerçekleştirilen 49. Dünya Ekonomik Formunda 2022 yılı için belirlenen en iyi 10 meslek Tablo 1'de verilmiştir (İnternet Kaynağı 3, 2019), (İnternet Kaynağı 4, 2018). Tablo 1'den de görüleceği gibi veri analitikçi ve büyük veri uzmanı meslekleri önem kazanan ve en iyi meslekler arasında yer almaktadır.

**Tablo 1.** 2019 yılında gerçekleştirilen 49. Dünya Ekonomik Formunda 2022 yılı için belirlenen en iyi 10 meslek.

Sıra No.	Meslek
1	Veri analitikçi / Veri bilimci
2	Yapay zekâ Makine öğrenme / Derin öğrenme uzmanı
3	Genel ve operasyonel yönetici
4	Yazılım ve uygulama geliştirici ve analizci
5	Satış ve pazarlama uzmanı
6	Büyük veri uzmanı
7	Dijital dönüşüm uzmanı
8	Yeni / yenilikçi teknoloji uzmanı
9	Organizasyonel gelişim uzmanı
10	Bilgi teknoloji servisleri uzmanı


Veri analitikçi ve büyük veri uzmanı meslekleri büyük veri analitiği çerçevesinde küresel dünya ekonomilerinde ekonominin akıllı yönetimi için önemlidir. İş hayatında en etkin 10 yetenek Şekil 1'de gösterilmiştir (Internet Kaynağı 5, 2020)



**Şekil 1.** İş hayatında en etkin 10 yetenek.

## 2.4. Büyük Verinin Analitiğinde Kullanılan Yüksek Performans Hesaplama Sistemleri

Büyük veri analitiğinde kullanılan yüksek performans hesaplama sistemleri Şekil 2'de gösterilmiştir. Büyük verinin katman sayısı, hacminin büyüklüğü ve karmaşıklığı büyük veri analitiğinde önemlidir. Bunlar dikkate alınarak büyük veri analitiğinde 3 farklı mimaride yüksek performans hesaplama sistemi kullanılır. Bu sistemler: (i) Tek işlemci - tek çekirdek yapısı: standart hesaplama mimarisi; (ii) Tek işlemci- çok çekirdek yapısı: paralel hesaplama mimarisi ve (iii) Çok işlemci- çok çekirdek yapısı: dağıtık hesaplama mimarisi şeklindedir. Bu sistemlerde (i) Donanım hesaplama ya da donanım hızlandırılmış hesaplama ve (ii) Yazılım hesaplama ya da yazılım optimize edilmiş hesaplama kullanılır.



**Şekil 2.** Büyük veri analitiğinde kullanılan yüksek performans hesaplama sistemleri.

## 2.5. Yüksek Performans Hesaplama Sistemlerinde Kullanılan Yazılım Araçları ve Kod Geliştirme Ortamları

Büyük veri analitiğinde çalışan meslek grupları: (1) Veri bilimi, (2) Veri Mühendisliği, (3) Bilgisayar Mühendisliği, (4) Yazılım Mühendisliği, (5) Makine Öğrenme Mühendisliği, (6) Derin Öğrenme Mühendisliği, (7) Yapay Zekâ Mühendisliği, (8) Yapay Beyin Mühendisliği. Büyük veri analitiğinde kullanılan ücretsiz ve açık kaynak kodlu; Linux ve Windows tabanlı bazı yazılım araçları Tablo 2'de verilmiştir. Büyük veri analitiğinde kullanılan bu ücretsiz yazılım araçları veriden bilgi üretmek amacıyla kullanılır.

**Tablo 2.** Büyük veri analitiğinde kullanılan ücretsiz ve açık kaynak kodlu; Linux ve Windows tabanlı bazı yazılım araçları.

Linux Tabanlı		Windows Tabanlı	
Sıra No	Ücretsiz Yazılım Aracı	Sıra No	Ücretsiz Yazılım Aracı
1	R	1	R
2	RapidMiner	2	RapidMiner
3	MOA	3	Orange
4	Orange	4	Tanagra
5	ROOT	5	NeoNeuro Data Mining
6	Rattle	6	khcoder
7	ELKI	7	Weka
8	DataMelt		
9	KNIME		
10	Weka		
11	KEEL		

Büyük veri analitiğinde kullanılan ticari yazılım araçları Tablo 3'te verilmiştir. Büyük veri analitiğinde kullanılan bu ticari yazılım araçları veriden bilgi üretmek amacıyla kullanılır.

**Tablo 3.** Büyük veri analitiğinde kullanılan ticari bazı yazılım araçları.

Sıra No	Ticari Yazılım Aracı
1	Oracle Big Data Analytics
2	IBM Big Data Analytics
3	SAP Big Data Analytics
4	Alteryx Analytics
5	MicroStrategy Enterprise Big Data Analytics
6	SAS High-Performance Big Data Analytics
7	BIRT Analytics
8	Tableau Big Data Analysis
9	Qlik Big Data
10	TIBCO Spotfire

Büyük veri analitiğinde kullanılan bazı kod geliştirme ortamları Tablo 4'de verilmiştir. Büyük veri analitiğinde kullanılan bu kod geliştirme ortamları veriden bilgi üretmek amacıyla kullanılır.

**Tablo 4.** Büyük veri analitiğinde kullanılan bazı kod geliştirme ortamları.

Sıra No	Kod Geliştirme Alanı	Kod Geliştirme Ortamı	Kod Geliştirme Dili
1	Veri Analitiği Tek işlemci- çok çekirdek yapısı (Paralel hesaplama mimarisi)	Anaconda Jupyter Notebook	Python
2	Web Analitiği Tek işlemci- çok çekirdek yapısı (Paralel hesaplama mimarisi)	NetworkX	Python
3	Sosyal Medya Analitiği Tek işlemci- çok çekirdek yapısı (Paralel hesaplama mimarisi)	NetworkX	Python
4	Büyük Veri Analitiği Tek işlemci- çok çekirdek yapısı (Paralel hesaplama mimarisi)	PySpark	Python
5	Büyük Veri Analitiği Çok işlemci- çok çekirdek yapısı (Dağıtık hesaplama mimarisi)	PyCuda	Python
5	Büyük Veri Analitiği Çok işlemci- çok çekirdek yapısı (Dağıtık hesaplama mimarisi)	Google Colabratory	Python

### 3. BÜYÜK VERİ ANALİTİĞİ YÖNTEMLERİ VE UYGULAMALARI

Büyük veri analitiğinde yapılan her proje için (i) Strateji oluşturulur, (ii) Yol haritası belirlenir, (iii) Planlama yapılır ve (iv) Modelleme gerçekleştirilir. Büyük veri analitiğinde yapılacak işlemler: (1) Büyük verinin kümelenmesi, (2) Büyük verinin sınıflandırılması, (3) Büyük veride ilişkisel yapı modellerinin oluşturulması ve (4) Büyük verinin görselleştirilmesi.

Büyük veri analitiğinde bir proje gerçekleştirilirken takip edilmesi gereken adımlar: (1) Büyük verinin hazırlanması, (2) Büyük verinin katmanlı yapısına, hacmine ve karmaşıklığına göre 3 farklı hesaplama sisteminden hangisinin kullanılacağına ve 2 farklı programlamadan hangisinin uygulanacağına karar verilir, (3) Büyük veri analitiğinde hangi yazılımın kullanılacağına karar verilir, (4) Büyük veriye uygulanacak işleme göre 2 farklı öğrenme yönteminden: Makine Öğrenme / Derin öğrenme seçeneklerinden hangisinin uygulanacağına karar verilir, (5) Büyük veriye 4 farklı işlemten biri ya da birkaçı uygulandıktan sonra Yapay Zeka uygulaması geliştirilip geliştirilmeyeceğine karar verilir. (6) Büyük veri için bilgi oluşturulur. Bu adımlarla (i)

Büyük veri analitik için hazırlanır, (2) Verideki değişkenler ilişkilendirilir, (3) Büyük veri şekillendirilir, (4) Şekillendirilmiş büyük veriye anlam kazandırılır, (5) Büyük veri bilgiye dönüştürülür.

Yüksek performans sistemleri kullanılarak büyük veri analitiği uygulamaları: (1) Büyük verinin kümelenmesi, (2) Büyük verinin sınıflandırılması (Korkmaz ve Erol, 2020), (Gülgün ve Erol, 2020(a)), (Gülgün ve Erol 2020(a)), (3) Büyük veride ilişkisel yapı modellerinin oluşturulması (Erol ve Erol, 2020) ve (4) Büyük verinin görselleştirilmesi (Erol ve Erol, 2016) aşağıda alt başlıklar altında açıklanmıştır.

#### 3.1. Google Colabratory Ortamında Büyük Verinin Kümelenmesi

Bu alt bölümde yüksek performans hesaplama sistemi kullanılarak Google Colabratory ortamında büyük verinin kümelenmesi incelenecektir (İnternet Kaynağı 6, 2021). Bu çalışmada eğitimsiz makine öğrenimi modellerinin bir kategorisi açıklanmıştır: boyut indirgeme. Burada, eğitimsiz makine öğrenim modellerinin başka bir sınıfı ele alınmıştır: kümeleme algoritmaları. Kümeleme algoritmaları, verilerin özelliklerinden içerdiği gruplarının optimal bir şekilde bölünmesini veya ayrı ayrı etiketlenmesini öğrenmeye çalışır. Birçok kümeleme algoritması mevcuttur, ancak belki de anlaşılması en basit olanı k-ortalama kümeleme olarak bilinen bir algoritmadır. Bu çalışmada Google Colabratory ortamında büyük verinin kümelenmesi uygulaması yapılmıştır.

#### 3.2. Google Colabratory Ortamında Büyük Verinin Sınıflandırılması

Bu alt bölümde yüksek performans hesaplama sistemi kullanılarak Google Colabratory ortamında büyük verinin sınıflandırılması amaçlı iki çalışma incelenecektir.

Birinci çalışmada tıbbi görüntülerin sınıflandırılmasını içermektedir (İnternet Kaynağı 7, 2021). Birinci sınıflandırma uygulamasında tıbbi görüntüleme için derin öğrenme kullanılmıştır. Akciğer X-ışın görüntülerinin sınıflandırılması yapılmıştır. Bu, tıbbi görüntü sınıflandırması için makine öğrenimine üst düzey bir giriş niteliğindedir. Sınıflandırmada derin öğrenme yöntemi uygulanmıştır. Tıbbi görüntüler görüntülenmiş ve görüntü düzeyinde açıklamalar oluşturulmuştur. Sınıflandırma modelini eğitmek için veri kümeleri oluşturulmuştur. Bu çalışmada Google Colabratory ortamında büyük verinin sınıflandırılması uygulaması yapılmıştır.

İkinci çalışma hazır görüntülerin (İnternet Kaynağı 8, 2009) sınıflandırılmasını içermektedir (İnternet Kaynağı 9, 2019). Sınıflandırmada evrişimli sinir ağı (CNN) kullanılmıştır. Görüntülerin evrişimli sinir ağı (CNN) kullanılarak sınıflandırılmasında hem model oluşturulmuş hem

de model eğitilmiştir. Bu çalışmada kullanılan veri seti, her sınıfta 6.000 resim olmak üzere 10 sınıfta 60.000 renkli görüntü içerir. Veri kümesi 50.000 eğitim görüntüsüne ve 10.000 test görüntüsüne bölünmüştür. Sınıflar birbirini dışlar ve aralarında hiçbir örtüşme yoktur. Bu çalışmada da Google Colabratory ortamında büyük verinin sınıflandırılması uygulaması yapılmıştır.

### 3.3. Google Colabratory Ortamında Büyük Veride İlişkisel Yapı Modellerinin Oluşturulması

Bu alt bölümde yüksek performans hesaplama sistemi kullanılarak Google Colabratory ortamında büyük veride ilişkisel yapı modellerinin oluşturulması incelenecektir (İnternet Kaynağı 10, 2019). Bu çalışmada ele alınan örnek uygulama TensorFlow kullanarak zaman serisi tahminine giriş niteliindedir. Bu çalışmada evrişimli sinir ağları (CNN) ve tekrarlayan sinir ağları (RNN) dahil olmak üzere birkaç farklı model stili oluşturulmuştur. Bu çalışma iki ana bölümde ele alınmıştır. (1) Tek bir zaman adımı için tahmin: (i) Tek bir özellik, (ii) Tüm özellikler. (2) Birden çok adım için tahmin: (i) Tek seferlik: Tahminleri tek seferde yapılır. (ii) Otopregresif: Her seferinde bir tahmin yapılır ve çıktı modeli geri beslemek için kullanılır.

### 3.4. Google Colabratory Ortamında Büyük Verinin Görselleştirilmesi

Bu alt bölümde yüksek performans hesaplama sistemi kullanılarak Google Colabratory ortamında büyük verinin hem kümelenmesi hem sınıflandırılması hem de ilişkisel görselleştirilmesi incelenecektir (İnternet Kaynağı 11, 2016). Bu çalışmada ele alınan konu güzel uygulama örneğidir.

Derin öğrenme, büyük miktarda veriyi analiz etmek için güçlü bir araçtır (İnternet Kaynağı 12, 2015). Uzaktan algılamada derin öğrenme özellikle anormallik tespitinde kullanılmaktadır (İnternet Kaynağı 13, 2017). Denetimsiz öğrenim kullanılarak çok zamanlı uzaktan algılama görüntülerinde birden fazla değişiklik türü belirlenebilmektedir (İnternet Kaynağı 14, 2018). Bu araştırma içinde görüntü sınıflandırmasına (İnternet Kaynağı 15, 2016) ek olarak biyofiziksel değişken regresyon modelleme de yapılmıştır (İnternet Kaynağı 16, 2019). Burada yapılan çalışma Landsat 8'i, eğitim verileri olarak Ulusal Arazi Örtüsü Veri Kümesini ve basit bir evrişimli sinir ağını kullanarak arazi örtüsü sınıflandırmasının temel bir örneğidir. Bu çalışmada Google Colabratory ortamında evrişimli sinir ağları kullanılarak arazi örtüsü haritalanmış ve sınıflandırması yapılmıştır. Çalışılan bölgenin arazi örtüsü büyük verinin kümelenmesi çerçevesinde farklı kümelere etiketlenmiş ve daha sonra evrişimli sinir ağları kullanılarak sınıflandırılmıştır. Sınıflandırma işlemiyle birlikte büyük verideki

değişkenler için yapısal modeller oluşturulmuş ve büyük verinin görselleştirilmesi yapılmıştır.

## 4. SONUÇLAR VE ÖNERİLER

Akan veya katmanlı büyük veri analitiği söz konusu olduğunda büyük verinin hacmi ve karmaşıklığı dikkate alınmalıdır. Büyük veri analitiğinde kullanılan hesaplama sistemleri de önemlidir. Büyük veri olması durumunda analitiği Anaconda ortamında standart tek işlemci- tek çekirdek mimarisi kullanılarak Python kodlama ile yapılabilir. Büyük verinin hacminin büyük olması durumunda analitiği Anaconda ortamında tek işlemci- çok çekirdek mimarisi ile paralel hesaplama mimarisi kullanılarak Python kodlama ile yapılabilir. Büyük verinin hacminin büyük ve karmaşıklığının olması durumunda analitiği Google Colabratory ortamında çok işlemci- çok çekirdek mimarisi ile dağıtık hesaplama mimarisi kullanılarak Python kodlama ile yapılabilir.

Yüksek performans hesaplama sistemlerinde büyük veri analitiğinde donanım hesaplama ya da donanım hızlandırılmış hesaplama yapılabilir. Alternatif olarak büyük veri analitiğinde yazılım gerçekleştirilebilir.

Büyük verinin hacminin büyük olması durumunda analitiğinde makine öğrenme yöntemleri uygulanabilir. Büyük verinin hacminin büyük ve karmaşıklığının fazla olması durumunda derin öğrenme yöntemleri uygulanabilir.

## KAYNAKÇA

- Gökalp MO, Kayabay K, Akyol MA, Eren PE and Koçyigit A. (2016). Big Data For Industry 4.0: A Conceptual Framework. 2016 International Conference on Computational Science and Computational Intelligence. 978-1-5090-5510-4/16 10.1109/CSCI.2016.87.
- Hamza Erol ve Recep Erol (2018). Determining Big Data Complexity Using Hierarchical Structure of Groups and Clusters in Decision Tree. 2018 3rd International Conference on Computer Science and Engineering (UBMK).
- Hamza EROL ve Timuçin KORKMAZ (2020). Büyük Veri Analitiği İçin Yüksek Performans Hesaplama Sistemi Gibi Davranan Bir Dağıtık Bilgisayar Sistemi Mimarisi. Bilgisayar Bilimleri ve Teknolojileri Dergisi - DergiPark. Yıl 2020, Cilt 1, Sayı 2, Sayfalar: 74-81.
- Vassakis K, Petrakis E and Kopanakis I (2018). Big Data Analytics: Applications, Prospects and Challenges. Mobile Big Data, Lecture Notes on Data Engineering and Communications Technologies 10, Springer International Publishing AG, [https://doi.org/10.1007/978-3-319-67925-9\\_1](https://doi.org/10.1007/978-3-319-67925-9_1).



- Thelin R (2020). What is Big Data? Characteristics, Types, and Technologies. <https://www.educative.io/blog/what-is-big-data>.
- İnternet Kaynağı 1 (2018). Yuval Noah HARARI 48. Dünya Ekonomik Formu. <https://www.weforum.org/events/world-economic-forum-annual-meeting-2018/sessions/will-the-future-be-human>.
- İnternet Kaynağı 2 (2020). [https://ec.europa.eu/esco/portal/escopedia/List\\_of\\_sectors\\_of\\_economic\\_activities\\_for\\_the\\_development\\_of\\_ESCO\\_v1](https://ec.europa.eu/esco/portal/escopedia/List_of_sectors_of_economic_activities_for_the_development_of_ESCO_v1).
- Hamza Erol, Bala Mikat Tyoden, Recep Erol (2018). Classification Performances Of Data Mining Clustering Algorithms For Remotely Sensed Multispectral Image Data. 2018 Innovations in Intelligent Systems and Applications (INISTA).
- Hamza Erol, Celaledin Barutçular, Ayman El Sabagh, Recep Erol (2017). Data Mining Models for Selection of the Best Spectral Reflectance Indices in Estimation of Crop Yields and Classification of Maize Hybrid Types Using SpectroRadiometer Data. 2017 European Conference on Electrical Engineering and Computer Science (EECS).
- İnternet Kaynağı 3 (2019). <https://www.weforum.org/events/world-economic-forum-annual-meeting-2019>.
- İnternet Kaynağı 4 (2018). <https://eab.com/insights/daily-briefing/workplace/the-top-10-emerging-jobs-for-2022/>
- İnternet Kaynağı 5 (2020). <https://www.weforum.org/reports/the-future-of-jobs-report-2020>.
- Timuçin Korkmaz, Hamza Erol (2020). Classification Of Human Facial Expressions For Emotion Recognition Using A Distributed Computer System. 2020 5th International Conference on Computer Science and Engineering (UBMK).
- Osman Doğuş GÜLGÜN and Hamza EROL (2020) (a). Classification Performance Comparisons Of Deep Learning Models In Pneumonia Diagnosis Using Chest X-Ray Images. Yayın Bilgisi: 2020, Turkish Journal of Engineering. DOI: 10.31127/tuje.652358.
- Osman Doğuş GÜLGÜN and Hamza EROL (2020) (b). Medical image classification with hybrid convolutional neural network models. Bilgisayar Bilimleri ve Teknolojileri Dergisi - DergiPark. Yıl 2020, Cilt 1, Sayı 1, Sayfalar: 28-41.
- Hamza EROL, Recep EROL (2020). Reliability And Chaotic Risk Modeling For Real Time Data Driven Smart Systems. 2020 IEEE 14th International Conference on Application of Information and Communication Technologies (AICT).
- Hamza Erol and Recep Erol (2016). Logical circuit design using orientations of clusters in multivariate data for decision making predictions: A data mining and artificial intelligence algorithm approach. 2016 International Symposium on INnovations in Intelligent SysTems and Applications (INISTA).
- İnternet Kaynağı 6 (2021). <https://colab.research.google.com/github/jak-evdp/PythonDataScienceHandbook/blob/master/notebooks/05.11-K-Means.ipynb#scrollTo=0XcQWHWPCZpc>.
- İnternet Kaynağı 7 (2021). <https://colab.research.google.com/github/mdai/ml-lessons/blob/master/lesson1-xray-images-classification.ipynb#scrollTo=Hk7H4FqrGCTM>.
- İnternet Kaynağı 8 (2009). Learning Multiple Layers of Features from Tiny Images, Alex Krizhevsky, <https://www.cs.toronto.edu/~kriz/cifar.html>.
- İnternet Kaynağı 9 (2019). <https://colab.research.google.com/github/tensorflow/docs/blob/master/site/en/tutorials/images/cnn.ipynb#scrollTo=DSPCOM-KmApV>.
- İnternet Kaynağı 10. [https://colab.research.google.com/github/tensorflow/docs/blob/master/site/en/tutorials/structured\\_data/time\\_series.ipynb#scrollTo=GU8C5qm\\_4vZb](https://colab.research.google.com/github/tensorflow/docs/blob/master/site/en/tutorials/structured_data/time_series.ipynb#scrollTo=GU8C5qm_4vZb).
- İnternet Kaynağı 11 (2016). [http://patrickgray.me/open-geo-tutorial/chapter\\_6\\_neural\\_networks.html](http://patrickgray.me/open-geo-tutorial/chapter_6_neural_networks.html).
- İnternet Kaynağı 12 (2015). <https://doi.org/10.1038/nature14539>.
- İnternet Kaynağı 13 (2017). <https://doi.org/10.1109/MGRS.2017.2762307>
- İnternet Kaynağı 14 (2018). <https://doi.org/10.1109/TGRS.2018.2872509>.
- İnternet Kaynağı 15 (2016). <https://doi.org/10.1109/TGRS.2016.2612821>.
- İnternet Kaynağı 16 (2019). <https://doi.org/10.3390/rs11070768>.