



*Journal Of Investigation
On Engineering & Technology*

VOLUME/ CİLT: 4 (2021)

ISSUE: 2

ISSN: 2687-3052



KTÜ
1955 KARADENİZ
TEKNİK ÜNİVERSİTESİ



Journal of Investigation on Engineering & Technology

<http://dergipark.gov.tr/jiet>



PUBLISHER:

Yayıncı

Karadeniz Technical University, Faculty of Technology
Karadeniz Teknik Üniversitesi, Of Teknoloji Fakültesi

PRIVILEGE OWNER (Dean):

İmtiyaz Sahibi (Dekan)

Dr. İrfan ACAR

EDITOR IN CHIEF:

Baş Editör

Dr. Canan AKSOY

JOURNAL EDITORS:

Dergi Editörleri

Dr. Canan AKSOY
Dr. Emin TUĞCU
Dr. Erol İSKENDER
Dr. Hamdi Tolga KAHRAMAN
Dr. Hasan Tahsin ÖZTÜRK

TECHNICAL EDITOR

Dergi Teknik Editörü

Dr. Hasan Tahsin ÖZTÜRK

FIELD EDITORS

Alan Editörleri

Dr. Cemalettin ŞİMŞEK (Karamanoğlu Mehmetbey
University)
Dr. Tufan ÇAKIR (Gümüşhane University)

LANGUAGE EDITOR:

Dil Editörü

Dr. Nilgün MÜFTÜOĞLU

STATISTICS EDITOR:

İstatistik Editörü

Dr. Hanefi CALP

LAYOUT EDITOR:

Mizanpaj Editörü

Sefa ARAS

ISSUE EDITORS

Sayı Editörleri

Dr. Canan AKSOY
Dr. Cemalettin ŞİMŞEK

SECRETARY:

Sekreter

Bora ÇAVDAR

EDITORIAL BOARD:*Yayın Kurulu*

Dr. Adem DOĞANGÜN (Bursa Uludağ University)
Dr. Zeki KARACA (Ondokuz Mayıs University)
Dr. Tayfun DEDE (Karadeniz Technical University)
Dr. Egemen ARAS (Bursa Technical University)
Dr. Erdem TÜRKELİ (Ordu University)
Dr. Erdoğan DOĞDU (Çankaya University)
Dr. Şeref SAĞIROĞLU (Gazi University)
Dr. Güngör BAL (Gazi University)
Dr. M. Ali AKCAYOL (Gazi University)
Dr. Recep DEMİRCİ (Gazi University)
Dr. Tuncay YİĞİT (Süleyman Demirel University)
Dr. Ercan Nurcan YILMAZ (Gazi University)
Dr. Cemal YILMAZ (Gazi University)
Dr. Uğur GÜVENÇ (Düzce University)
Dr. Yusuf SÖNMEZ (Gazi University)
Dr. Mehmet ŞİMŞEK (Düzce University)
Dr. İbrahim Alper DOĞRU (Gazi University)
Dr. Atakan AKSOY (Karadeniz Technical University)
Dr. Tuncay BAYRAM (Karadeniz Technical University)
Dr. Bakiye ÇAKIR (Artvin Çoruh University)
Dr. Ezgi Taylan KOPARAN (Bülent Ecevit University)
Dr. Numan DOĞAN (North Carolina State University)
Dr. Tayebeh MOUSAVİ (University of Oxford)
Dr. Germán F. de la FUENTE (University of Zaragoza)
Dr. Luis A ANGUREL (University of Zaragoza)
Dr. Bilge Han TOZLU (Hitit University)

INDEXING:*İndeksler*

ASOS
indeks

Product Information

Ürün Bilgisi

Volume 4 **Issue** 2 **December/2021**
Cilt *Sayı* *Aralık/2021*

Publisher Karadeniz Technical University, Faculty of Technology
Yayıncı *Karadeniz Teknik Üniversitesi Of Teknoloji Fakültesi*

Web Page <http://dergipark.gov.tr/jiet>
Web Sayfası

Date of Publication December /2021
Basım Tarihi *Aralık/2021*

Language English/Turkish
Yayın Dili *İngilizce/Türkçe*

Frequency Published twice in a year
Yayın Aralığı *Yılda iki kez yayınlanır*

Type of Publication Periodical
Yayın Türü *Sürekli yayın*

ISSN Number 2687-3052
ISSN Numarası

Yazışma Adresi

Karadeniz Teknik Üniversitesi
Teknoloji Fakültesi
Çamlı M. Hacı Mehmet Baheddin Ulusoy
Cad. No:144 61830 Of/ TRABZON
Telefon: +90 462 377 83 01
E-posta: jiet@ktu.edu.tr

Makale gönderimi dergipark üzerinden yapılmaktadır. Tüm yayınlanan makalelere <http://dergipark.gov.tr/jiet> adresinden ulaşılabilir.

Correspondence Address

Karadeniz Technical University
Faculty of Technology
Çamlı M. Hacı Mehmet Baheddin Ulusoy
St. No:144 61830 Of/ TRABZON
Phone: +90 462 377 83 01
E-mail: jiet@ktu.edu.tr

Paper submission is done via dergipark. All published papers are available at <http://dergipark.gov.tr/jiet>.



CONTENTS

İçindekiler



Research Papers

(Araştırma Makaleleri)

Pages

Sayfalar

Classification of Short Texts According to the Language They Are Written in and Application of Different Attribute Selection Methods 36-46

Kısa Metinleri Yazıldıkları Dile Göre Sınıflandırma ve Farklı Öznitelik Seçim Yöntemlerinin Uygulanması

Murat ASLANYÜREK, Altan MESUT

Classification of Epileptic Seizure Dataset Using Different Machine Learning Algorithms and PCA Feature Reduction Technique 47-60

Shamriz NAHZAT, Mete YAĞANOĞLU

The Effect of Over-Aging on Some Mechanical Properties for AZ31 Magnesium Alloy 61-68

AZ31 Magnezyum Alaşımı İçin Aşırı Yaşlandırmanın Bazı Mekanik Özelliklere Etkisi

Mehmet ŞAHBAZ

Review Papers

(Derleme Makaleleri)

Health 4.0: Blockchain Applications in Healthcare 69-76

İbrahim KAYA, Sercan DEMİR



Kısa Metinleri Yazıldıkları Dile Göre Sınıflandırma ve Farklı Öznitelik Seçim Yöntemlerinin Uygulanması

Murat ASLANYÜREK¹, Altan MESUT²

(Alınış / Received: 27.09.2021, Kabul / Accepted: 23.12.2021, Online Yayınlanma / Published Online: 31.12.2021)

Anahtar Kelimeler

Dil tanıma
Fasttext
Langdetect
Makine öğrenmesi

Öz: Özet: Bu çalışmada Wikipedia makale özetlerinden oluşan farklı boyutlardaki iki veri seti üzerinde dil tanıma yönelik sınıflandırma işlemi yapılmıştır. A veri seti grubu 204 bayt ve daha kısa makale özetlerinden oluşurken, B veri seti grubu 204 ile 512 bayt arasındaki özetlerden oluşmaktadır. Çalışmadaki birinci hedef kısa metinlerin boyutlarına göre uygun makine öğrenmesi ve öznitelik seçme yönteminin belirlenmesidir. İkinci hedef ise en hızlı ve yüksek doğrulukla sınıflandırma yapan yöntemin tespit edilmesidir. Yapılan testler sonucunda öznitelik seçiminde SelectFromModel-Lojistik Regresyon kullanılması ile en yüksek doğruluk değerine ulaşıırken, makine öğrenmesi yöntemi olarak Naive Bayes Multinomial ve Naive Bayes Bernoulli farklı uzunluktaki veri setlerine göre birbirlerine üstünlük sağlamaktadır. Ayrıca çalışmada kullanılan tüm sınıflandırma yöntemleri ile yapılan testler sonucunda, her iki veri setinde diğer sınıflandırma yöntemlerine göre fasttext'in doğruluk bakımından, Kelime Tabanlı İstatistiksel Yöntem (KTİY)'nin ise hız bakımından üstünlük sağladığı anlaşılmıştır.

Classification of Short Texts According to the Language They Are Written in and Application of Different Attribute Selection Methods

Keywords

Language recognition
Fasttext
Langdetect
Machine learning

Abstract: In this study, a classification process for language recognition has been performed on two data sets of different sizes consisting of Wikipedia article abstracts. Dataset group A consists of article abstracts of 204 bytes and less, while dataset group B consists of abstracts of between 204 and 512 bytes. The first goal of the study is to determine the appropriate machine learning and attribute selection method according to the sizes of the short texts. The second goal is to determine the fastest and most accurate classification method. As a result of the tests performed; the highest accuracy value has been achieved by using SelectFromModel-Logistic Regression in feature selection, while as a machine learning method, Naive Bayes Multinomial and Naive Bayes Bernoulli have been superior to each other according to data sets of different lengths. In addition, as a result of the tests performed with all classification methods used in the study, it has been understood that fasttext is superior in terms of accuracy and Word-Based Statistical Method WBSM in terms of speed in both data sets compared to other classification methods.

¹ Kırklareli Üniversitesi, Pınarhisar MYO, Bilgisayar Programcılığı Programı, Kırklareli, Türkiye, m.aslanyurek@klu.edu.tr

² Trakya Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Edirne, Türkiye, altanmesut@trakya.edu.tr

1. Giriş

Doğal dil işlemenin alt konularından olan Dil Tanıma (DT) problemi ile ilgili geçmişten günümüze birçok çalışma yapılmıştır. Bir belgenin yazıldığı dilinin bilinmesi ya da bir belge üzerindeki farklı dillere ait metinlerin dillerine göre gruplanması bir sınıflandırma problemidir. Metinlerin dillerine göre gruplanması onlar üzerinde yapılacak ön işlem adımlarını kolaylaştırmakla beraber, arama, sıkıştırma gibi işlemleri de kolaylaştıracaktır. Dil tanıma ya da metin sınıflandırma işlemleri denetimli ve denetimsiz öğrenme yöntemleri ile yapıldığı gibi, istatistiksel farklı yaklaşımlarla da yapılabilir. Dil tanıma problemlerinde ki en temel unsur, ayırt edici özelliklerin belirlenmesidir. Bu anlamda istatistiksel yöntemler ile yapılan DT problemleri için o dile ait sık geçen kelimelerin belirlenmesi önemlidir. DT işlemlerinde makine öğrenmesi yöntemleri kullanıldığında öznitelik seçimin etkili yapılması hem işlem süresini hem kısaltması hem de sınıflandırma başarısını arttırmayı beklenmektedir. Öznitelik seçimi, bir veri kümesindeki özniteliklerin, sınıflandırma başarısına en çok katkı sağlayacak olanların seçilmesi olarak tanımlanabilir. Böylelikle veri kümesini en iyi ifade edecek alt küme oluşturulması hedeflenir. Bu anlamda öznitelik seçimiyle alakalı literatürde birçok farklı yaklaşım ve teknik uygulanmaktadır. Gülşen ve ark., Türk kullanıcıların web günlük verilerine dayalı olarak cinsiyet tahmini yaptıkları sınıflandırma çalışmalarında öznitelik çıkarma tekniği olarak Bilgi kazanımı ve Ki-Kare tabanlı öznitelik seçim teknikleri kullanarak, Lojistik Regresyon (LR) sınıflandırıcısı ile yüksek başarımlı bir sınıflandırma yapmışlardır [1]. Yengi ve Omuca LR sınıflandırıcısının performansını arttırmak için öznitelik seçimi ve öznitelik azaltma yöntemlerini (wrapper, filter vb.) kullanmışlardır. Bu sayede LR sınıflandırıcısının performansını DVM (Destek Vektör Makineleri) gibi güçlü bir sınıflandırıcının performansına eşdeğer hale getirmeyi başarmışlardır [2]. Parlar ve ark., Twitter verilerini kullanarak oluşturdukları bir veri kümesinde duygu analizi sınıflandırması için bir çalışma yapmışlardır. Bu çalışmada sınıflandırma başarısını arttırmak için farklı öznitelik seçim yöntemlerini kullanmışlardır. Kullandıkları Bilgi Kazanımı, Ki-Kare modeli, Karınca Kolonisi Optimizasyonu ve Sorgu Genişletme yöntemlerinden, en iyi sonucu veren yöntemlerin Karınca Kolonisi Optimizasyonu ve Sorgu Genişletme yöntemleri olduğunu tespit etmişlerdir [3]. Sel ve ark., yaptıkları çalışmada öznitelik seçim tekniği kullanmadan oluşan 600 öznitelik ve Karşılıklı Bilgi öznitelik seçim yöntemini kullanarak 20, 50, 100 ve 200 öznitelik kullanarak sınıflandırma yapmışlardır. 50 öznitelik kullanıldığı durumda en yüksek sınıflandırma doğruluğuna ulaştıkları çalışma sonucunda anlaşılmıştır [4]. Erdem ve Özgür, sınıflandırma başarısını arttırmak ve sınıflandırma süresini azaltmak için Genetik Algoritma kullanan bir öznitelik seçim yöntemi önermişlerdir. Önerdikleri yöntemi birçok sınıflandırıcı ile kullanarak yöntemin başarısını daha önce yapılan çalışmalar ile karşılaştırmışlardır. Karşılaştırmalar sonucunda önerdikleri yöntemin yüksek doğruluk ve düşük çalışma zamanı elde ederek doğrulamışlardır [5]. Akyol meme kanseri tanısı için yaptığı sınıflandırma çalışmasında öz yinelenmeli öznitelik seçim yöntemi kullanarak, elde ettiği öznitelik kümesini Rastgele Orman ve Lojistik Regresyon sınıflandırıcısında kullanmıştır. Sınıflandırma güvenilirliğini test etmek için kullandığı 5 kat çapraz doğrulama tekniği ile Rastgele Orman sınıflandırıcının doğruluğunu %98 olarak ölçmüştür [6]. Ataş ve ark., Alzheimer hastalığını erken teşhisi için yaptıkları çalışmada öznitelik seçimi olarak Değişken Komşuluk Arama yöntemini ve sınıflandırıcı olarak DVM kullanmışlardır. Alzheimer teşhisinde bu iki model kullanıldığında, benzer çalışmalara göre daha iyi sonuç verdiği testler sonucu anlaşılmıştır [7]. Kaya ve ark., dil tanıma üzerinde yaptıkları bir çalışmada UTF-8 değerlerini karşılaştırarak ikili örüntüler elde etmeye dayanan ve bunları kullanarak dili tanıyan yeni bir öznitelik seçme yöntemi önermişlerdir. Önerilen bu yöntem Almanca, Fransızca, İngilizce ve Türkçe dillerinde Yapay Sinir Ağları (YSA) kullanarak sınıflandırma başarısı test edilmiştir. Testler sonucunda %99 ve %89 doğruluk ile sınıflandırma yapmayı başarmışlardır [8].

Bu çalışmada 6 farklı dile ait farklı boyutlardaki veri setleri üzerinde istatistiksel yöntem, makine öğrenmesi, langdetect ve fasttext yöntemleri kullanılarak kısa metinler dillerine göre sınıflandırılmıştır. Makine öğrenmesi yöntemleri kullanılarak yapılan sınıflandırmalarda farklı öznitelik seçme yöntemleri uygulanmıştır.

2. Yöntemler

2.1. Sınıflandırma Yöntemleri

2.1.1. Naive Bayes Sınıflandırıcı

Daha önceden sınıf etiketleri bilinen veri seti kullanılarak öğrenme modeli oluşturma temeline dayanan bu model Bayes teoriminden esinlenerek geliştirilmiştir [9]. Bu yaklaşımda farklı hesaplama dağılımları kullanılabilir. Genellikle belge sınıflandırmasında kullanılan ve multinom dağılımına dayanan model Multinomial Naive Bayes (M-NB) olarak bilinir. M-NB gibi çalışan ancak Bernoulli dağılımına dayanan model ise Bernoulli Naive Bayes (B-NB) olarak bilinir. Bu iki yöntem arasındaki diğer bir fark B-NB ikili terim özniteliklerinden faydalanırken, M-NB terim frekanslarını kullanmaktadır. Her bir sınıfla ilişkili olan sürekli değerlerin Gauss dağılımına göre dağıtılmasına dayanan model ise Gaussian Naive Bayes (G-NB) olarak bilinir.

2.1.2. Karar Ağaçları

Sınıflandırma ve regresyon çalışmalarında kullanılan ağaç tabanlı bir algoritmadır. Denetimli bir öğrenme metoduna dayanan bu yöntemde amaç, veri özelliklerinden çıkarılan basit karar kurallarını öğrenerek bir hedef değişkenin değerini tahmin eden bir model oluşturmaktır. Tahmin kuralının oluşturulması “böl ve yönet” yaklaşımı yinelemeli bir şekilde bölümlere ayırarak gerçekleşir [10].

2.1.3. K-En Yakın Komşu

Fix tarafından 1951’de geliştirilen [11] ve Cover ve Hart tarafından iyileştirilen bu modelde sınıf tahmini yapmak için bağımsız değişkenlerden oluşan vektöre en yakın olan komşuların uzaklık derecesine bakılır [12]. Hem sınıflandırma hem de regresyon için kullanılabilir [13].

2.1.4. Destek Vektör Makinesi

İlk fikir olarak 1960’lı yıllarda temeli atılan ve 1970’ li yıllara kadar geliştirilerek devam eden Destek Vektör Makineleri (DVM) asıl başarısına 1990’lı yıllarda ulaşmıştır. Cortes ve Vapnik’ in çalışmaları ile popüler hale gelen bu model sınıflandırma ve regresyon analizi için verileri analiz eden denetimli bir modeldir [14]. Eğitim ve sınıf verisi çok olduğu durumlarda genellikle model oluşturma süresi fazladır [15].

2.1.5. Langdetect

Python açık kaynak kitaplığı langdetect [16], başlangıçta dil tanımlaması için açık kaynak kodlu bir Java kitaplığı olarak geliştirilmiştir. Karakter n-gram özelliklerine sahip saf bir Bayes algoritması kullanır.

2.1.6. Fasttext

Hızlı ve etkili sınıflandırma yöntemi olan fasttext, Facebook çalışma grubu tarafından geliştirilmiştir. Word2Vec yöntemine dayanan bu model de kelimeler n-gramlar şeklinde ifade edilir. Word2Vec gibi yöntemlerde her kelime bir vektöre dönüştürülürken, fasttext ile n-gramlar vektöre dönüştürülür. Yapısında çok fazla kelime barındıran ve seyrek kelimelerin çok olduğu dillerde n-gramlar ile çalışmayan yöntemler başarısız olmaktadır. Fasttext ile bu problem giderilmiştir [17].

2.1.7. Kelime Tabanlı İstatistiksel Yöntem

Paulsen ve Martino’ nun yaptıkları patent çalışmasına göre bu yöntemde her dil için bir kelime tablosu tutulur. Kelime tablolarında ilgili dile ilgili en sık geçen etkisiz kelimeler (stopwords) kullanılır. Bir metnin ait olduğu dil belirlenirken metindeki her kelime tüm kelime tablolarında aranır ve hangi dilin kelime tablosunda bulunursa o kelime tablosuna ait sayaç değişkeninin değeri artırılır. Böylece hangi dilin kelime tablosuna ait sayaç değeri daha yüksek ise metin o dile ait olacaktır [18].

Bu çalışmada dillere ait her bir kelime tablosu 256 kelimedenden oluşmaktadır. 256 kelime olmasının sebebi daha sonraki yapılacak olan metin sıkıştırma çalışmasında dillere ait tabloların sıkıştırma için kullanılacak olmasıdır.

2.2. Kullanılan Öznitelik Seçme Yöntemleri

2.2.1. TF-IDF

TF-IDF (Terim Frekansı – Ters Doküman Frekansı), bir terimin/kelimenin dokümanlar içerisindeki önemini gösteren istatistiksel yöntemler ile hesaplanan bir ağırlık faktörüdür. TF ile metin dokümanları içerisindeki bir kelimenin tüm dokümanlarda geçme sıklığını verirken, IDF ise bir kelimenin hangi dokümanlarda geçtiği bilgisini verir [19]. Bu yöntem ile terim ağırlıklandırma işlemleri yapılarak önemli öznitelikler belirlenir. TF-IDF’ ye ait matematiksel formül aşağıdaki gibidir.

$$W_{TF-IDF} = TF(t_i, d_k) * \log \left(\frac{D}{d(t_i)} \right) \quad (1)$$

D: Toplam doküman sayısı

d(t_i): t_i terimin geçtiği toplam doküman sayısı

2.2.2. Ki-Kare

Bu yöntem ile Ki-Kare istatistiksel kriteri kullanılarak hedef değişkenle en belirgin ilişkisi olan özniteliklerin belirlenmesi sağlanır. Ki-Kare yöntemine ait formüller aşağıdaki gibidir [20].

$$Chi2(t, C) = \sum_{t \in \{0,1\}} \sum_{C \in \{0,1\}} \frac{(N_{t,C} - E_{t,C})^2}{E_{t,C}} \quad (2)$$

$$Chi2(t) = \sum_{i=1}^M P(C_i) * Chi2(t, C) \quad (3)$$

$P(C_i)$: Sınıf olasılığı.

N : t teriminin C sınıfı için gözlenen frekansı.

E : t teriminin C sınıfı için beklenen frekansı.

2.2.3. SelectFromModel-Lojistik Regresyon Yöntemi

Python paketi olan SelectFromModel [21], belirli bir eşik fonksiyonu (threshold) parametresi ile karşılaştırılan parametrelerin her biri için değerler sağlayan bir girdi modeli değerlendiricisidir. Eşik değerinin altında belirlenen öznitelikler kaldırılarak öznitelik seçimi gerçekleştirilir [22]. Bu model ile Lojistik Regresyon (LR) gibi modellerden üretilen tahminler parametre olarak kullanılarak önemli öznitelikler belirlenebilir. Özellikler arasındaki ilişki açıklamak için kullanılan LR, sınıf etiketleri 0 ve 1 şeklinde verilen ve ikili sınıflandırma problemlerinde kullanılan istatistiksel bir modeldir [23]. LR analizinde amaç, bağımlı ve bağımsız değişkenler arasındaki ilişki veya ilişkileri, en az değişken ile en iyi uyuma sahip olacak şekilde tanımlamaktır [24].

2.3. Yöntemlerin Uygulanması

Yapılan tüm sınıflandırma ve öznitelik seçme yöntemleri python programlama dili kullanılarak uygulanmıştır. Kelime Tabanlı İstatistiksel Yöntem (KTİY) Paulsen ve Martino' nun patent çalışmasından esinlenerek python programlama dili ile kodlanmıştır. langdetect için langdetect paketi ile "detect()" metodu ve fasttext için fasttext paketi ile "fasttext.load_model()" ve "predict()" metotları kullanılmıştır. Öznitelik çıkarma, seçme ve makine öğrenmesi yöntemleri sklearn paketindeki aşağıdaki metotlar kullanılarak yapılmıştır.

Öznitelik çıkarma ve vektöre dönüştürme → CountVectorizer(), TfidfVectorizer()

Öznitelik seçme → TfidfVectorizer(max_features), SelectKBest(chi2, max_features), SelectFromModel(estimator=LogisticRegression, max_features)

Makine öğrenmesi ile sınıflandırma → GaussianNB(), BernoulliNB(), MultinomialNB(), DecisionTreeClassifier(), RandomForestClassifier(), SVC().

Makine öğrenmesi ile sınıflandırma yöntemlerinin tamamı varsayılan parametreleri ile kullanılmıştır.

2.4. Veri Setleri

Wikipedia makale özetlerinden oluşan 6 farklı dile ait 2 farklı boyuttaki kısa metinlerden oluşan veri setleri hem test verisi hem de öğrenme verisi olarak kullanılmıştır. A veri seti grubunda kullanılan kısa metinlerin (makale özeti) boyutu 0,2 KB'tan küçük değişik uzunluktaki karakter sayısından oluşmaktadır. A veri seti grubu içerdiği özetler bakımından tamamen farklı A1 ve A2 veri setinden oluşmaktadır. Öğrenme (model kurma) için kullanılan A1 veri seti 6.000 kısa metinden ve toplam 765 KB dosya boyutundan oluşmaktadır. Kısa metinlerin dillerinin belirlenmesi (test) için kullanılan A2 veri seti ise 24.000 kısa metinden ve toplam 3 MB dosya boyutundan oluşmaktadır.

B veri seti grubunda kullanılan özetlerin boyutu ise 0,2 KB ile 0,5 KB arasında değişik uzunluktaki karakter sayısından oluşmaktadır. B veri seti grubu içerdiği özetler bakımından tamamen farklı B1 ve B2 veri setinden oluşmaktadır. Öğrenme için kullanılan B1 veri seti 6.000 kısa metinden ve toplam 1,98 MB dosya boyutundan oluşmaktadır. Kısa metinlerin dillerinin belirlenmesi için kullanılan B2 veri seti ise 24.000 kısa metinden ve toplam 7,92 MB dosya boyutundan oluşmaktadır.

2.5. Veri Önışlem Aşamaları

Metinler üzerinde makine öğrenmesi yöntemlerinin uygulanabilmesi için farklı önışlem aşamalarında geçmesi gerekmektedir. Özellikle metinler üzerinde doğrudan makine öğrenmesi yöntemleri uygulanamayacağından verilerin sayısallaştırılması gerekmektedir. Başka bir deyişle metinlerin vektör uzayında ifade edilmelidir.

Makine öğrenmesi için önışlem aşamaları genel hatları ile aşağıdaki adımlardan oluşmaktadır. Ancak bu yöntemlerin yapılacak çalışmaya bağlı olarak bazıları kullanılmayabilir.

- küçük/büyük harf dönüşümü,
- noktalama işaretlerinin kaldırılması,
- etkisiz kelimelerin silinmesi (remove stopwords),
- kelime köklerinin çıkarılması (stemming),
- öznitelik çıkarımı,
- öznitelik seçimi.

İstatistiksel yöntemlerde yapılacak önışlem aşamaları makine öğrenmesi yöntemleri gibi karmaşık olamamakla beraber, etkisiz kelimelerin kullanılması belirleyici öznitelikler olmaktadır. Bu anlamda Kelime Tabanlı İstatistiksel Yöntem (KTİY), langdetect ve fasttext kullanılarak yapılan sınıflandırma küçük/büyük harf dönüşümü ve noktalama işaretlerinin kaldırılması dışında herhangi bir önışlem adımı uygulanmamıştır.

2.6. Testlerin Değerlendirilmesi

Yöntemlerin sınıflandırma başarısını ölçmek için doğruluk, duyarlılık, kesinlik F1 skoru ve jaccard skoru değerleri, sklearn.metrics paketindeki ilgili fonksiyonlar kullanılarak elde edilmiştir. Yöntemlerin işlem süreleri "Intel Core i7 9750H 2.60 GHz" işlemci, "16 GB" hafıza ve "Windows 10 Pro 64-bit" işletim sistemi kullanan bir bilgisayar ile ölçülmüştür.

2.6.1. Doğruluk, Kesinlik, Duyarlılık, F1 Skoru ve Jaccard Skoru

Sınıflandırma performansını ölçmek için kullanılan Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru dört temel değer üzerinden hesaplanırlar: Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN).

- **Doğruluk:** Doğru olarak tahmin edilen örneklerin sayısının, veri kümesinde bulunan tüm örneklerin sayısına bölünerek hesaplanır.

$$\text{doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (4)$$

- **Kesinlik:** Doğru Pozitif olarak tahmin edilen örneklerin sayısının, tüm pozitif örneklerin sayısına bölünerek hesaplanır.

$$\text{kesinlik} = \frac{DP}{DP + YP} \quad (5)$$

- **Duyarlılık:** Doğru Pozitif olarak tahmin edilen örneklerin sayısının hem Doğru Pozitif hem de Yanlış Negatif örneklerin toplam sayısına bölünmesi ile hesaplanır:

$$\text{duyarlılık} = \frac{DP}{DP + YN} \quad (6)$$

- **F1 Skoru:** Duyarlılık ve Kesinlik değerlerinin harmonik ortalaması ile hesaplanır.

$$\text{F1 Skoru} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$

- **Jaccard Skoru:** Jaccard indeksi veya Jaccard benzerlik katsayısı olarak da bilinen Jaccard skoru, kesişme boyutunun iki etiket kümesinin birleşiminin boyutuna bölünmesi olarak tanımlanır ve aşağıdaki gibi hesaplanabilir [25]. Başka bir ifade ile jaccard skoru Doğru Pozitif örneklerin sayısının, Doğru Negatif dışındaki (DP, YP, YN) tüm örneklerin sayısının toplamına bölünmesi ile hesaplanabilir.

$$Jaccard\ Skoru(d1, d2) = \frac{d1 \cap d2}{d1 \cup d2} \quad (8)$$

$$Jaccard\ Skoru = \frac{DP}{DP + YP + YN} \quad (9)$$

3. Test Sonuçları

3.1. A Veri Seti Grubu Testleri

Tablo 1’de 6.000 özet içeren A1 eğitim veri setinin farklı öznitelik seçme teknikleri ve 10-Kat çapraz doğrulama kullanılarak makine öğrenmesi yöntemleri ile sınıflandırılması sonucu elde edilen performans değerleri verilmiştir. Yapılan 3 değerlendirmede de kullanılan 4.153 öznitelik sayısı SelectFromModel-LR tarafından belirlenen en önemli özniteliklerdir. Elde edilen performans değerleri incelendiğinde veri setinin uygunluğu yüksek doğruluk değerleri ile doğrulanmıştır. En yüksek doğruluk %99,92 değeri öznitelik seçimi olarak SelectFromModel-LR, sınıflandırma yöntemi olarak ise M-NB kullanıldığında elde edilmiştir. Ayrıca her üç öznitelik seçim tekniğinde M-NB en iyi sınıflandırmayı yapmıştır. Makine öğrenmesi yöntemleri için en uygun öznitelik seçim tekniği değerlendirildiğinde en uyumlu ikililerin M-NB – SelectFromModel, B-NB – SelectFromModel, G-NB – Ki-Kare, KA – Ki-Kare, RO – Ki-Kare, KNN – Ki-Kare, DVM – TF-IDF şeklinde olduğu anlaşılmaktadır. KNN sınıflandırma yöntemi ile beraber TF-IDF öznitelik seçim tekniği uygulandığında en düşük doğruluk değerine ulaşılmıştır.

Tablo 1. A1 veri setinin sınıflandırılmasında SelectFromModel-LR, Ki-Kare, TF-IDF ile öznitelik seçimi ve 10-Kat çapraz doğrulama tekniği uygulanarak elde edilen performans değerleri

SelectFromModel-LR							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,92%	99,67%	99,75%	98,45%	99,73%	94,57%	99,57%
F1 Skoru	99,91%	99,66%	99,75%	98,44%	99,74%	94,73%	99,57%
Duyarlılık	99,91%	99,65%	99,75%	98,42%	99,73%	94,55%	99,56%
Kesinlik	99,92%	99,67%	99,75%	98,48%	99,74%	95,65%	99,58%
Jaccard Skoru	99,83%	99,32%	99,50%	96,94%	99,48%	90,26%	99,14%
Ki-Kare							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,87%	99,60%	99,80%	98,63%	99,77%	95,35%	99,70%
F1 Skoru	99,87%	99,59%	99,80%	98,63%	99,77%	95,49%	99,70%
Duyarlılık	99,87%	99,58%	99,80%	98,61%	99,76%	95,35%	99,69%
Kesinlik	99,87%	99,61%	99,79%	98,67%	99,78%	96,17%	99,71%
Jaccard Skoru	99,73%	99,19%	99,60%	97,31%	99,54%	91,59%	99,40%
TF-IDF							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,87%	99,62%	98,45%	98,28%	99,72%	72,40%	99,85%
F1 Skoru	99,87%	99,61%	98,43%	98,27%	99,72%	74,44%	99,85%
Duyarlılık	99,87%	99,60%	98,43%	98,26%	99,72%	72,34%	99,85%
Kesinlik	99,86%	99,62%	98,45%	98,30%	99,72%	90,23%	99,85%
Jaccard Skoru	99,73%	99,23%	96,92%	96,62%	99,44%	62,56%	99,70%

Makine öğrenmesi yöntemlerinde kullanılan öznitelik sayısı hem sınıflandırma performansını hem de sınıflandırma süresini doğrudan etkilemektedir. Bu çalışmada yapılan sınıflandırma dil tanımaya yönelik olduğundan veri setine ait özniteliklerin tamamı kullanılmadan bile yüksek doğruluk değeri ile sınıflandırma yapılabileceği öngörülmektedir.


Tablo 2’de 24.000 özet içeren A2 test veri setinde bulunan özetlerin, A1 veri seti ile kurulan modele göre yazıldıkları dillerin tahmin edilmesine yönelik makine öğrenmesi ile farklı öznitelik sayısı kullanılarak edilen performans değerleri verilmiştir. Öznitelik seçim tekniği olarak SelectFromModel-LR ile oluşan hem 4.153 belirleyici öznitelik hem de bunlar arasındaki en belirleyici 25 öznitelik kullanılarak elde edilen performans değerlerine göre en yüksek doğruluk değeri 4.153 öznitelik sayısı ile M-NB kullanıldığında elde edilmiştir. En

düşük doğruluk değeri ise 4.153 öznitelik sayısı ile KNN olduğu görülmektedir. B-NB, KA, KNN ve DVM sınıflandırma yöntemlerinde 25 öznitelik kullanıldığında daha yüksek doğruluk değerleri elde edilmiştir. Metin sınıflandırma problemlerinin en önemli ve en zor aşaması olan en uygun özniteliklerin belirlenmesidir. Bu anlamda dil tanıma problemlerinde özniteliklerin sadece bir kısmı kullanılarak bile yüksek doğruluk değeri ile sınıflandırma yapılabileceği anlaşılmıştır.

Tablo 2. Öznitelik seçimi olarak SelectFromModel-LR, model kurmak için (öğrenme) A1 kullanılarak A2 veri setindeki özetlerin dillerinin belirlenmesinde edilen performans değerleri

SelectFromModel-LR- 4.153 Öznitelik							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,71%	91,45%	99,13%	96,67%	98,09%	86,80%	97,34%
F1 Skoru	99,71%	90,64%	99,12%	96,65%	98,07%	86,91%	97,30%
Duyarlılık	99,71%	93,63%	99,13%	96,79%	98,18%	92,22%	97,55%
Kesinlik	99,71%	91,45%	99,13%	96,67%	98,09%	86,80%	97,34%
Jaccard Skoru	99,42%	85,08%	98,26%	93,57%	96,27%	79,08%	94,89%
SelectFromModel-LR- 25 Öznitelik							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	97,90%	95,30%	95,67%	97,23%	97,98%	95,60%	97,35%
F1 Skoru	97,90%	95,21%	95,67%	97,24%	97,99%	95,63%	97,37%
Duyarlılık	97,99%	95,73%	95,90%	97,33%	98,05%	95,95%	97,54%
Kesinlik	97,90%	95,30%	95,67%	97,23%	97,98%	95,60%	97,35%
Jaccard Skoru	95,91%	91,09%	91,70%	94,66%	96,07%	91,66%	94,93%

Şekil 1’de makine öğrenmesi yöntemlerinin A1 veri seti ile oluşturulan modele göre A2 veri setine ait özetleri dillerine göre sınıflandırma süreleri saniye türünden verilmiştir. Sınıflandırma işlemi SelectFromModel-LR öznitelik seçimi ile elde edilen hem 4.153 hem de 25 öznitelik kullanılarak iki farklı şekilde yapılmıştır. Buna göre en hızlı sınıflandırma yönteminin M-NB, en yavaş sınıflandırma yönteminin ise RO olduğu görülmektedir. Ayrıca daha az öznitelik kullanılarak daha hızlı sınıflandırma yapılabileceği Şekil 1’den açıkça anlaşılmaktadır.



Şekil 1. A2 veri setinin makine öğrenmesi yöntemleri ile farklı öznitelik sayısındaki sınıflandırma süreleri (sn)

Tablo 3’te A2 veri setinin fasttext, KTİY ve langdetect ile sınıflandırılması sonucu elde edilen performans değerleri ve sınıflandırma süreleri verilmiştir. Buna göre %99,79 doğruluk değeri ile en iyi sınıflandırma fasttext yöntemi ile olurken, %96,79 doğruluk değeri ile en düşük sınıflandırmayı yapan yöntem KTİY olmuştur. Ancak KTİY ile yapılan sınıflandırmanın fasttext’e göre daha hızlı olduğu anlaşılmaktadır. fasttext yöntemi ile yapılan

sınıflandırmanın, Tablo 2' de verilen makine öğrenmesi yöntemlerinden hem süre hem de doğruluk oranı bakımından en iyi sınıflandırmayı yapan M-NB' den daha iyi olduğu görülmektedir.

Tablo 3. A2 veri setinin fasttext, KTİY ve langdetect ile sınıflandırma performans değerleri ve süreleri

	fasttext	KTİY	langdetect
Doğruluk	99,79%	96,99%	99,66%
F1 Skoru	99,79%	97,00%	99,66%
Duyarlılık	99,79%	97,13%	99,66%
Kesinlik	99,79%	96,99%	99,66%
Jaccard Skoru	99,58%	94,21%	99,33%
Süre (sn)	1,58	0,97	151,49

3.2. B Veri Seti Grubu Testleri

Tablo 4'te 6.000 özet içeren B1 eğitim veri setinin farklı öznitelik seçme teknikleri ve 10-Kat çapraz doğrulama kullanılarak makine öğrenmesi yöntemleri ile sınıflandırılması sonucu elde edilen performans değerleri verilmiştir. SelectFromModel-LR kullanılarak elde edilen öznitelik sayısı 10.100' dür. Ancak A veri seti grubu ile yapılacak karşılaştırmanın daha adil olması için en değerli 4.153 öznitelik kullanılmıştır. Elde edilen performans değerleri incelendiğinde veri setinin uygunluğu yüksek doğruluk değerleri ile doğrulanmıştır. En yüksek doğruluk değeri olan %99,99, öznitelik seçimi olarak SelectFromModel-LR, sınıflandırma yöntemi olarak ise B-NB kullanıldığında elde edilmiştir. Diğer öznitelik seçim teknikleri ile yapılan sınıflandırmalarda M-NB ile B-NB arasında anlamlı bir fark oluşmadığı görülmektedir. Kullanılan veri seti için makine öğrenmesi yöntemleri ile uyumlu öznitelik seçim teknikleri değerlendirildiğinde en uyumlu ikililerin B-NB – SelectFromModel-LR, G-NB – Ki-Kare, KA – SelectFromModel-LR, RO – Ki-Kare, KNN – Ki-Kare, DVM – (Ki-Kare ve TF-IDF) şeklinde olduğu anlaşılmaktadır. Sınıflandırma yöntemi olarak KNN ve öznitelik seçim tekniği olarak Ki-Kare kullanıldığında en düşük performans değeri elde edildiği ayrıca anlaşılmaktadır.

Tablo 4. B1 veri seti LR, Ki-Kare, TF-IDF ile öznitelik seçimi ve 10-Kat çapraz doğrulama tekniği uygulanarak elde edilen performans değerleri

SelectFromModel-LR							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,98%	99,99%	99,72%	98,67%	99,97%	99,52%	99,90%
F1 Skoru	99,98%	99,99%	99,72%	98,67%	99,97%	99,52%	99,90%
Duyarlılık	99,98%	99,99%	99,71%	98,66%	99,96%	99,51%	99,89%
Kesinlik	99,98%	99,99%	99,72%	98,69%	99,97%	99,53%	99,91%
Jaccard Skoru	99,97%	99,98%	99,44%	97,38%	99,93%	99,04%	99,80%
Ki-Kare							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,98%	99,98%	99,93%	98,62%	99,93%	95,70%	99,93%
F1 Skoru	99,98%	99,98%	99,93%	98,62%	99,93%	95,80%	99,93%
Duyarlılık	99,98%	99,98%	99,93%	98,61%	99,93%	95,70%	99,93%
Kesinlik	99,98%	99,98%	99,94%	98,65%	99,94%	96,37%	99,94%
Jaccard Skoru	99,97%	99,97%	99,87%	97,29%	99,87%	92,11%	99,87%
TF-IDF							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,98%	99,98%	98,80%	98,57%	99,95%	98,37%	99,93%
F1 Skoru	99,98%	99,98%	98,80%	98,56%	99,95%	98,36%	99,93%
Duyarlılık	99,98%	99,98%	98,80%	98,54%	99,95%	98,35%	99,93%
Kesinlik	99,98%	99,98%	98,81%	98,60%	99,95%	98,41%	99,94%
Jaccard Skoru	99,97%	99,97%	97,65%	97,18%	99,90%	96,79%	99,87%


Tablo 5'te 24.000 özet içeren B2 test veri setinde bulunan özetlerin, B1 veri seti ile kurulan modele göre yazıldıkları dillerin tahmin edilmesine yönelik makine öğrenmesi ile farklı öznitelik sayısı kullanılarak edilen performans değerleri verilmiştir. Öznitelik seçim tekniği olarak SelectFromModel-LR ile oluşan hem 4.153 en

önemli öznitelik hem de bunlar arasındaki en önemli 25 öznitelik kullanılarak elde edilen performans değerlerine göre en yüksek doğruluk değeri 4.153 öznitelik sayısı ile B-NB kullanıldığında elde edilmiştir. Ayrıca en düşük doğruluk değeri 25 öznitelik sayısı ile KNN olduğu görülmektedir. KA en yüksek doğruluk değerini 25 öznitelik sayısında verirken diğer yöntemler 4.153 öznitelik sayısı ile daha yüksek doğruluk değerleri vermiştir. Bu veri setinde de sadece 25 öznitelik kullanılarak metinlerin dillerinin yüksek doğruluk değeri ile belirlenebileceği anlaşılmıştır.

Tablo 5. B1 veri seti ile kurulan modele göre B2 veri setinin sınıflandırılması

SelectFromModel-LR- 4.153 Öznitelik							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,97%	99,98%	99,77%	98,71%	99,98%	99,44%	99,93%
F1 Skoru	99,97%	99,98%	99,77%	98,71%	99,97%	99,44%	99,93%
Duyarlılık	99,97%	99,98%	99,77%	98,71%	99,98%	99,44%	99,93%
Kesinlik	99,97%	99,98%	99,77%	98,71%	99,98%	99,44%	99,93%
Jaccard Skoru	99,95%	99,96%	99,54%	97,46%	99,95%	98,88%	99,86%
SelectFromModel-LR- 25 Öznitelik							
	M-NB	B-NB	G-NB	KA	RO	KNN	DVM
Doğruluk	99,60%	99,64%	98,90%	98,85%	99,63%	98,10%	99,54%
F1 Skoru	99,60%	99,64%	98,89%	98,85%	99,63%	98,10%	99,54%
Duyarlılık	99,61%	99,64%	98,90%	98,85%	99,63%	98,18%	99,54%
Kesinlik	99,60%	99,64%	98,90%	98,85%	99,63%	98,10%	99,54%
Jaccard Skoru	99,21%	99,28%	97,82%	97,72%	99,27%	96,30%	99,08%

Şekil 2' de makine öğrenmesi yöntemlerinin B1 veri seti ile oluşturulan modele göre B2 veri setine ait özetleri dillerine göre sınıflandırma süreleri saniye türünden verilmiştir. Sınıflandırma işlemi SelectFromModel-LR öznitelik seçimi ile elde edilen hem 4.153 hem de 25 öznitelik kullanılarak iki farklı şekilde yapılmıştır. Bu veri setinde kullanılan özetlerin boyutu A veri seti grubundakilerden daha büyük olmasına rağmen Şekil1'deki gibi benzer sınıflandırma süreleri oluşması kullanılan öznitelik sayısı ile açıklanabilir.



Şekil 2. B2 veri setinin makine öğrenmesi yöntemleri ile farklı öznitelik sayısındaki sınıflandırma süreleri (sn)

Tablo 6'da B2 veri setinin fasttext, KTİY ve langdetect ile sınıflandırılması sonucu elde edilen performans değerleri ve sınıflandırma süreleri verilmiştir. Buna göre %99,99 doğruluk değeri ile en iyi sınıflandırma fasttext yöntemi ile olurken, %99,93 doğruluk değeri ile en düşük sınıflandırmayı yapan yöntem KTİY olmuştur. Bu veri setinde de KTİY ile yapılan sınıflandırmanın fasttext'e göre daha hızlı olduğu anlaşılmaktadır. fasttext yöntemi ile yapılan

sınıflandırmanın, Tablo 4'te verilen makine öğrenmesi yöntemlerinden en hızlı olan M-NB' den, doğruluk bakımından en iyi sınıflandırmayı yapan B-NB' den daha iyi olduğu görülmektedir.

Tablo 6. A2 veri setinin fasttext, KTİY ve langdetect ile sınıflandırma performans değerleri ve süreleri

	fasttext	KTİY	langdetect
Doğruluk	99,99%	99,93%	99,97%
F1 Skoru	99,99%	99,93%	99,97%
Duyarlılık	99,99%	99,93%	99,97%
Kesinlik	99,99%	99,93%	99,97%
Jaccard Skoru	99,98%	99,86%	99,94%
Süre (sn)	2,95	1,68	179,16

4. Sonuçlar

Bu çalışmada A1, A2, B1 ve B2 veri setleri kullanılarak dil tanımaya yönelik farklı sınıflandırma yöntemleri kullanılarak sınıflandırma çalışması yapılmıştır. Makine öğrenmesi ile yapılan sınıflandırmalarda A1 ve B1 veri setleri kullanılarak bir model oluşturulmuş ve kurulan modellerin uygunluğu test edilmiştir. Yapılan testler sonucunda 0,2 KB'tan küçük ve 0,2 KB – 0,5 KB arası kısa metinleri içeren sırası ile A1 ve B1 veri seti için farklı öznitelik seçim teknikleri uygulanarak ve 10-kat çapraz doğrulama yapılarak model geçerliliği doğrulanmıştır. Makine öğrenmesi yöntemlerinin sınıflandırma başarıları kullanılan kısa metinlerin büyüklüğüne, öznitelik seçim tekniği ve sayısına göre değiştiği görülmüştür. 0,2 KB ve daha küçük kısa metinler için makine öğrenmesi ile yapılacak sınıflandırmalarda M-NB ve B-NB ile SelectFromModel-LR, G-NB, KA, RO ve KNN ile Ki-Kare, DVM ile TF-IDF öznitelik seçim tekniğinin kullanılması ile daha yüksek doğruluk değerleri elde edilmiştir. Boyutu 0,2 KB ve 0,5 KB arasında değişen kısa metinlerde ise tüm yöntemler ile SelectFromModel-LR öznitelik seçim tekniği ile en yüksek doğruluk değerleri olduğundan bu boyuttaki kısa metinlerin sınıflandırılmasında SelectFromModel-LR seçim tekniğinin kullanılmasının daha uygun olduğu anlaşılmıştır. Yapılan testlere göre öznitelik sayısının fazla olması daha yüksek doğruluk ile sınıflandırma yapılacağı garantisini vermediğini göstermektedir. 0,2 KB'den küçük metinlerde KNN, B-NB, KA ve DVM, 0,2-0,5 KB arasındaki kısa metinlerde ise KA 25 öznitelik kullanıldığında 4.153 öznitelik kullanıldığı duruma göre daha yüksek doğruluk değeri ile sınıflandırma yapılabilmektedir. Makine öğrenmesi yöntemlerinde hem 4.153 hem de 25 öznitelik sayısı ile yapılan sınıflandırmalara göre 0,2 KB'den küçük metinlerde M-NB, 0,2-0,5 KB arası metinlerde ise B-NB kullanılmasının daha uygun olduğu anlaşılmıştır. Eşit sayıda özet içeren hem 0,2 KB hem de 0,2-0,5 KB arası veri seti gruplarında makine öğrenmesi yöntemlerinde eşit sayıda öznitelik kullanılarak yapılan test sonuçlarında göre benzer sınıflandırma süreleri oluşmuştur. Bu durum kullanılan öznitelik sayısının sınıflandırma süresinde belirleyici bir etken olduğunu açıklamaktadır. Makine öğrenmesi yöntemleri ile sadece 25 öznitelik kullanıldığında bile KTİY' nin hem A2 veri setini hem de B2 veri setini dillerine göre çok daha hızlı bir şekilde ayırdığı yapılan testler ile doğrulanmıştır. KTİY tüm yöntemler arasında en hızlı yöntem olurken 0,2 KB ve daha küçük boyuttaki kısa metinleri sınıflandırma başarısı, 0,2-0,5 KB arasındaki boyutlardan oluşan kısa metinleri sınıflandırma başarısından daha düşük olduğu görülmüştür. Diğer tüm sınıflandırma yöntemlerinin 02-05 KB boyuttaki kısa metinleri sınıflandırma başarıları daha yüksek olmuştur. Tüm kullanılan sınıflandırma yöntemleri arasında en yüksek doğruluk değeri ile sınıflandırma yapan yönteminin fasttext olduğu yapılan testler sonucunda anlaşılmıştır.

Kaynakça

- [1] Gülşen, E., Gündüz, H., Cataltepe, Z., & Serinol, L. (2015, May). Big data feature selection and projection for gender prediction based on user web behaviour. *In 2015 23rd Signal Processing and Communications Applications Conference (SIU) (pp. 1545-1548). IEEE.*
- [2] Yengi, Y., & Omurca, S. İ. (2015). Lojistik Regresyonun Özellik Azaltma Teknikleri ile Gen Dizilimlerinin Sınıflandırılmasındaki Başarısı. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 8(1), 1-12.
- [3] Parlar, T., Saraç, E., & Özel, S. A. (2017, May). Comparison of feature selection methods for sentiment analysis on Turkish Twitter data. *In 2017 25th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.*
- [4] Sel, İ., Karci, A., & Hanbay, D. (2019, September). Feature Selection for Text Classification Using Mutual Information. *In 2019 International Artificial Intelligence and Data Processing Symposium (IDAP) (pp. 1-4). IEEE.*

- [5] Erdem, H., & Özgür, A. (2018). Feature selection and multiple classifier fusion using genetic algorithms in intrusion detection systems. *Journal of the Faculty of Engineering and Architecture of Gazi University* 33:1, 75-87.
- [6] Akyol, K. (2018). Meme Kanseri Tanısı İçin Özniteliklerin Öneminin Değerlendirilmesi Üzerine Bir Çalışma. *Akademik Platform Mühendislik ve Fen Bilimleri Dergisi*, 6(2), 109-115.
- [7] Ataş, P. K., Tufan, K., & Şevkli, A. Z. (2016, April). A variable neighborhood search based feature selection model for early prediction of the Alzheimer's disease. In *2016 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT) (pp. 1-4)*. IEEE.
- [8] Kaya, Y., Ertuğrul, Ö. F., & Tekin, R. (2015). Doküman dili tanıma için ikili örüntüler tabanlı yeni bir yaklaşım. *Akademik Bilişim, Eskişehir*.
- [9] Rish, I. (2001, August). An empirical study of the naive Bayes classifier. In *IJCAI 2001 workshop on empirical methods in artificial intelligence Vol. 3, No. 22*, pp. 41-46.
- [10] Agrawal, R., Imielinski, T., & Swami, A. (1993). Database mining: A performance perspective. *IEEE transactions on knowledge and data engineering*, 5(6), 914-925.
- [11] Fix, E. (1951). Discriminatory analysis: nonparametric discrimination, consistency properties. *USAF School of Aviation Medicine*.
- [12] Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- [13] Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- [14] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- [15] Tipping, M. E. (2000). The relevance vector machine. In *Advances in neural information processing systems (pp. 652-658)*.
- [16] Danilk M.M., (2013) <https://pypi.org/project/langdetect/>, Erişim (Tarihi: 11.06.2021).
- [17] Joulin, A., Grave, E., Bojanowski, P., Douze, M., Jégou, H., & Mikolov, T. (2016). Fasttext. zip: Compressing text classification models. *arXiv preprint arXiv:1612.03651*.
- [18] Paulsen Jr, R. C., & Martino, M. J. (2004). U.S. Patent No. 6,704,698. *Washington, DC: U.S. Patent and Trademark Office*.
- [19] Kınık, D. (2020). *TF-IDF ve Doc2vec Tabanlı Metin Sınıflandırma Sisteminin Başarım Değerinin Ardışık Kelime Gurubu Tespiti İle Arttırılması*. (Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, İstanbul)
- [20] Çekik R. (2020). *Kısa Metin Sınıflandırma İçin Öznitelik Seçimi*. (Fen Bilimleri Enstitüsü Doktora Tezi, Eskişehir).
- [21] https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.SelectFromModel.html. (Erişim Tarihi: 11.06.2021).
- [22] Popov, N. V., Razmochaeva, N. V., & Klionskiy, D. M. (2020, June). Investigation of Algorithms for Converting Dimension of Feature Space in Retail Data Analysis Problems. In *2020 9th Mediterranean Conference on Embedded Computing (MECO) (pp. 1-4)*. IEEE.
- [23] Önder, H., & Cebeci, Z. (2002). Lojistik regresyonlarda değişken seçimi. *Çukurova Üniv. Ziraat Fakültesi Dergisi*, 17(2), 105-114.
- [24] Çokluk, Ö. (2010). Lojistik Regresyon Analizi: Kavram ve Uygulama. *Educational Sciences: Theory & Practice*, 10(3).
- [25] Jaccard, P., (1901). Étude comparative de la distribution florale dans une portion des Alpes et des Jura. *Bull Soc Vandoise Sci Nat* 37, 547-579.



Classification of Epileptic Seizure Dataset Using Different Machine Learning Algorithms and PCA Feature Reduction Technique

Shamriz NAHZAT¹ , Mete YAĞANOĞLU² 

(Alınış / Received: 01.10.2021, Kabul / Accepted: 23.12.2021, Online Yayınlanma / Published Online: 31.12.2021)

Keywords

Epileptic Seizures
K-Nearest Neighbors (KNN)
Machine Learning (ML)
Principal Components Analysis (PCA)
Random Forest (RF)

Abstract: Epileptic seizures are currently one of the leading reasons for morbidity and mortality in the world. With the rise of epileptic seizures around the world and their effect on people's lives, it's more important than ever to get an accurate and timely diagnosis. These days, machine learning techniques are utilized to forecast or diagnose various life-threatening diseases such as epilepsy, cancer, diabetes, heart disease, thyroid, and so on. Early detection and treatment of diseases such as epilepsy will save a person's life. The fundamental goal of this work is to find the best classification algorithm for epileptic seizures by applying the Principal Components Analysis feature reduction technique in the dataset. In this paper, we applied K-Nearest Neighbors, Random Forest, Support Vector Machine, Artificial Neural Network, and Decision Tree algorithms by using the Principal Components Analysis feature reduction technique in the dataset to predict epilepsy, and the performance of classifiers are analyzed with using Principal Components Analysis and without using the Principal Components Analysis technique. The models used in this analysis have various degrees of accuracy. This study indicates that the used model can accurately predict epilepsy. Our findings indicate that using Principal Components Analysis feature reduction in the dataset, the Random Forest, classifier with 97 % accuracy and low computational times (training and testing time) produces the best results. Also, the K-Nearest Neighbors and Random Forest with 99 % accuracy without using Principal Components Analysis feature reduction in the dataset shows the best result compared to other machine learning techniques.

1. Introduction

Seizure, which is, exactly known as an epileptic seizure, is a transient neurological disorder of the brain that can be triggered by a sudden over-activity of nerve cells in the brain [1]. It is a widespread neurological condition that affects people of all ages [2]. One percent of people around the world suffer from this disease [3].

There are many causes of epilepsy, including vascular, brain infections, brain tumors, nutritional deficiencies, pyridoxine deficiency, and calcium metabolism disorders. To accurately diagnose epilepsy, research is needed to properly understand the mechanisms that cause epileptic disorders.

Magnetic resonance imaging (MRI), computed tomography (CT) scan, positron emission tomography (PET), ultrasound, and electroencephalogram (EEG) diagnostic tools are available. However, MRI, CT scan, and Ultrasound are expensive and can't be used for long-term detection. On the other hand, EEG, is a low-cost test, that can be used for long-term detection. As a result, EEG is the most effective method for diagnosing epilepsy [4].

¹ Atatürk University, Department of Computer Engineering, 25240, Erzurum, Türkiye

² Atatürk University, Department of Computer Engineering, 25240, Erzurum, Türkiye

The EEG provides a wealth of physiological and pathological data that is useful in the treatment of epilepsy cases, such as assessing the epileptogenic zone for presurgical assessments [5]. Currently, EEG diagnosis focuses on neurologists physically inspecting EEG recordings. The visual scoring of long-term EEG is time-consuming and boring. As a result, the automatic recognition technology is helpful to neurologists when analyzing EEG records or informations.

Machine learning (ML), a sub-branch and cornerstone of artificial intelligence (AI), has made great strides over the past two decades. ML uses mathematical and computer science concepts as well as algorithms to reveal the underlying features of data and intrinsic connections. It is currently widely used in the field of disease diagnosis. These days, machine learning techniques are utilized to forecast or diagnose various dangerous sicknesses such as epilepsy, cancer, diabetes, heart disease, thyroid, and so on. Early detection and treatment of diseases such as epilepsy will save a person's life.

But diagnosing possible seizures in advance is not an easy job. The majority seizures occur unexpectedly and finding ways to diagnose feasible seizures before they occur, is a challenge for many researchers. The method utilized in this article, will aid in determining whether or not somebody is having a seizure.

The fundamental goal of this work is to find the best classification algorithm for epileptic seizures by applying the Principal Components Analysis (PCA) feature reduction technique in the dataset. In this paper, we applied K-Nearest Neighbors (KNN), Random Forest (RF), Support Vector Machine (SVM), Artificial Neural Network (ANN), and Decision Tree (DT) algorithms by using the PCA feature reduction technique in the dataset to predict epilepsy, and the performance of classifiers are analyzed with using PCA and without using the PCA technique.

2. Related Works

This part of the paper is allocated to several scholars who have discussed issues relating to epileptic seizures and have used machine learning methods to predict epileptic seizures. We discuss a number of recent studies on epileptic seizure diagnosis using EEG signals.

In 2020 Almustafa has utilized various Machine learning techniques like RF, DT, K-NN, Naïve Bayes, Logistic Regression, Random Tree, J48 and Stochastic Gradient Descent (S.G.D.) to the classification of the Epileptic Seizure dataset and achieved 97.08% accuracy by using the Random Forest classifier [5].

In 2019 Nandy et al. used SVM classifier for classification Epileptic Seizure and for optimization of hyper-parameters of SVM has used a Bayesian optimization algorithm. Furthermore, they used Linear Discriminant Analysis (LDA) and Quadratic Linear Discriminant Analysis (QLDA) for comparison, in their paper, the SVM classifier shows 97.05% accuracy [4].

In 2019 Usman et al. have used principal component analysis (PCA) for feature extraction and support vector machines classifier to the classification of the Epileptic Seizure, the proposed model shows an average sensitivity of 93.1% [6].

Hamad et al. have utilized the discrete wavelet transform (DWT) approach to extract features, then, these features are employed to train the SVM with radial basis function (RBF) kernel function. In order to achieve an effective EEG classification, the grey wolf optimizer (GWO) was employed to choose the important feature subset and the appropriate SVM parameters [7].

In 2016 Sharmila & Geethanjali mainly used discrete wavelet transforms (DWT) to decompose EEG data into separate sub-bands and then derive statistical features. The classifier is trained using the DWT-derived statistical features. The signals are then classified using two classifiers to decide if they are epileptic or not. The KNN and Naive Bayes classifiers are the two classifiers that are used in this study. This study compares the success of 14 different two-class epilepsy detection combinations. The results of the experiments showed that, in order to diagnose epileptic seizures, The Naive Bayes classifier achieves the highest accuracy with less computing time for most dataset combinations [8].

Swami et al. used dual-tree complex wavelet transform (DTCWT) for decomposition of signals and calculated statistical measurements then all statistical measurements were trained using by general regression neural network classifier, finally the model shows 95.24% accuracy [9].

3. Material and Methods

The goal of our work is to find the best classification algorithm for epileptic seizures by applying the PCA feature reduction technique in the dataset.

The phases will be discussed in the following sections. Figure 1. illustrates the overall flow chart of the suggested model.

3.1. Dataset Description

The epileptic seizure dataset utilized in this paper is from Bonn University, which can be found on the UCI Machine Repository website [10]. This dataset include five classes of 1 to 5, each of which is 100 signals with a length of 23.6 seconds, the Classes 5 and 4 were taken from five healthy human beings with open eyes and closed eyes. The other three classes (3, 2, and 1) were recorded from five epileptic patients. The two classes 3 and 2 were recorded, when there is no epileptic seizure, (the class 3 were recorded from pre-seizure hippocampal contralateral hemisphere and the class 2, was obtained from epileptogenic region of patient.) And the class1 was recorded during seizures.

All EEG signals are captured by a 128-channel system with a sampling rate of 173.61 Hz using a 12-bit analog-to-digital converter. There are 11,500 samples in the dataset, each having 178 attributes, and they are regularly distributed. All of the cases in classes 2, 3, 4, and 5 have never had an epileptic seizure. Only class 1 people experienced epileptic seizures [10]. As a result, for epileptic seizure and non-epileptic seizure instances, our analysis will be a binary structure, with classes 2,3,4,5. Table 1. displays the number of cases for each of the classes utilized, and we can see that all of them have an equal number of samples. Figure 2. shows the epileptic seizure dataset in a sample view.

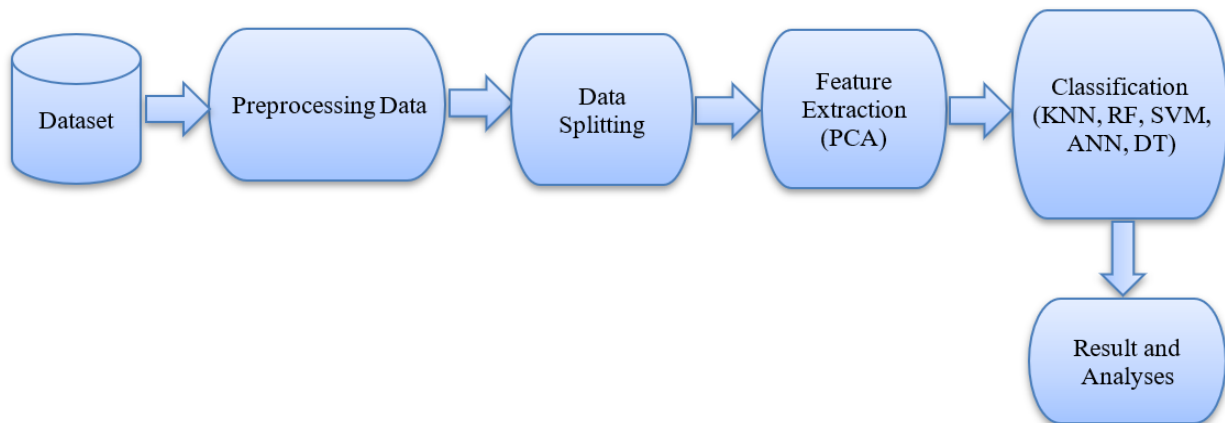


Figure 1. Proposed Model

Table 1. Dataset Description and number of cases in each class.

Classes	The Class Description	The Patient State	The Number of cases	Binary case
1	Seizure activity is recorded from epileptic patients	General epilepsy (with seizures)	2300	2300
2	The tumor was observed in epileptic patients	Partial epilepsy (without seizures)	2300	
3	The E.E.G. signal was recorded from a healthy brain region of epileptic patients	Partial epilepsy (without seizures)	2300	9200
4	eyes closed	Healthy	2300	
5	eyes opened	Healthy	2300	

	Unnamed: 0	X1	X2	X3	X4	X5	X6	X7	X8	X9	...	X170	X171	X172	X173	X174	X175	X176	X177	X178	y
11495	X22.V1.114	-22	-22	-23	-26	-36	-42	-45	-42	-45	...	15	16	12	5	-1	-18	-37	-47	-48	2
11496	X19.V1.354	-47	-11	28	77	141	211	246	240	193	...	-65	-33	-7	14	27	48	77	117	170	1
11497	X8.V1.28	14	6	-13	-16	10	26	27	-9	4	...	-65	-48	-61	-62	-67	-30	-2	-1	-8	5
11498	X10.V1.932	-40	-25	-9	-12	-2	12	7	19	22	...	121	135	148	143	116	86	68	59	55	3
11499	X16.V1.210	29	41	57	72	74	62	54	43	31	...	-59	-25	-4	2	5	4	-2	2	20	4

Figure 2. The epileptic seizure dataset in a sample view.

3.2. Data Preprocessing

One of the most critical and required stages in machine learning is data preparation. This technique is essential for reliable, accurate, and successful prediction outcomes when using machine learning algorithms in a data set [11]. Data preparation is a methodology that includes turning raw and unprocessed data into a suitable format for the classification process.

Data from the real world is frequently insufficient, untrustworthy, and/or lacking in specific behaviors or patterns, as well as including various mistakes. Pre-processing data is a tried-and-true way to solve such issues. Raw data is pre-processed to make it ready for subsequent processing.

In our dataset, there are no missing values (NaN). According to Table 1 we can observe that in the binary class, there is an unbalanced class distribution issue; to avoid this, we employ under sampling approaches. Under sampling is a term that refers to a series of strategies for balancing the class distribution in a classification dataset with a skewed class distribution.

To standardize our dataset, we employed the Min-Max normalization technique. After normalization of the dataset in the proposed methodology, we used 75 percent of the data for validation and training and 25 percent of data for the testing.

3.3. Feature Extraction

The purpose of the feature extraction phase is to minimize the amount of attributes by creating new ones from the dataset's current ones. Most of the information and features in the original dataset should be summarized by this new reduced feature set. As a result of combining the original set, a concise version of the primary features can be generated [12].

As we discussed earlier, there are 178 features in our data set, if we use all the features for training, the training time will be very long, so in our study, to extract and reduce the features we, used Principal Components Analysis (PCA).

3.3.1. Principal Components Analysis (PCA)

PCA is an information extraction approach that involves projecting data from a high-dimensional space onto a lower-dimensional subspace. It seeks to maintain the data's key bits with the highest variance and delete the non-essential sections with the least variance [13].

Our objective with PCA is to discover a collection of input characteristics that can best explain the distribution of the original data by decreasing its original dimensions. PCA may achieve this by maximizing variances and decreasing reconstruction error by monitoring fragmented distances. Our main data is projected onto a set of orthogonal axes, with each axis rated in order of relevance in PCA.

PCA is an unsupervised learning method that is not interested in data labels and only cares about diversity [14].

When PCA is used, the majority of the variation in the data is concentrated in the first few components. As a consequence, only those components with significant differences are retained, while rests are ignored.

The n-dimensional mean vector μ is computed first, followed by the $n \times n$ covariance matrix R , which is then sorted in decreasing order of eigenvalues. After sorting, the largest eigenvalues are picked. Noise is considered in

the other dimensions. If we create a $n \times n$ matrix A with n eigenvectors in columns, the data can be retrieved using the below equation after pre-processing [14].

$$X' = At(x - \mu) \tag{1}$$



Figure 3. The distribution of X_Train without using PCA.

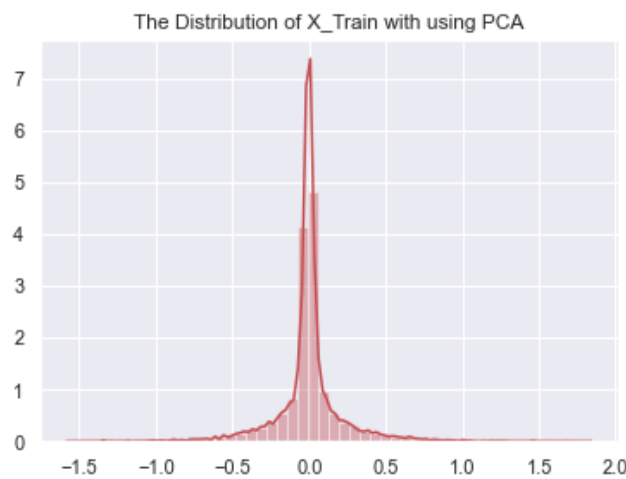


Figure 4. The distribution of X_Train using PCA.

Figure 3. illustrates the distribution of X_Train without the use of PCA, whereas Figure 4. represents the distribution of X_Train with the use of PCA, in here we can see applying PCA reduces the size of the data.

3.4. Algorithms used for Classification

The algorithms and practical machine learning methods for categorization and estimation utilized throughout this article are:

3.4.1. K-Nearest Neighbors (KNN)

K-NN is among the supervised learning techniques frequently used in classification studies. It is a nonparametric and basic technique that classifies objects in the input space based on the nearest samples [15]. While the number of neighbors is shown with k , it is named k -nearest neighbor algorithm because its proximity to the data to be classified is important. The KNN Classification method aims to address both classification and regression problems. The KNN algorithm is one of the algorithms that take a long time to learn [16].

K-NN is a learning algorithm based on calculating the sample distance, each time the algorithm encounters a new data sample, the distance is calculated on all samples in the new data. After this calculation, class labels are classified by finding k closest neighbors from previously known data samples and comparing them with the examples in the education data in the new example and looking at the similarities between them [17].

Figure 5. shows the Confusion matrix for KNN algorithm when k=1 is selected, and the PCA feature reduction technique is used to forecast epilepsy. In figure 6. we can see the best value for k is one because it shows the highest accuracy in training and testing.

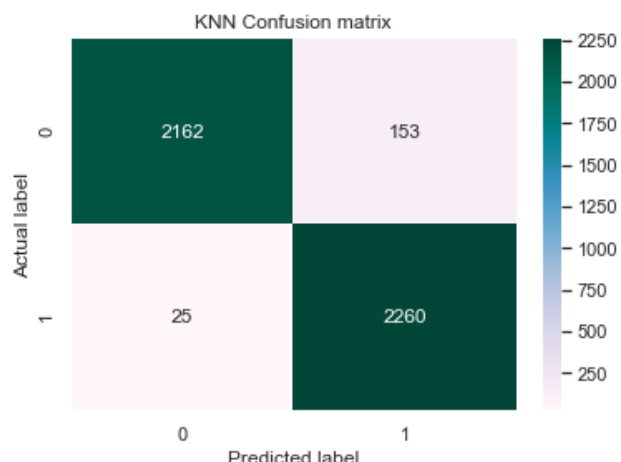


Figure 5. Confusion matrix for KNN algorithm with using of PCA feature reduction technique.




Figure 6. The Train Score and Test Score of KNN algorithm with different k values.

3.4.2. Random Forest (RF)

The RF classifier, which has been developed in recent years, provides an advantage over Acceleration [18] and Bagging [19] methods, which are known as two very good methods in collective learning, in terms of both fast and high accuracy. Compared to learning methods, the RF classifier is much faster during the training phase, especially than the Acceleration method. It is a very useful classifier with its efficiency and accuracy [20].

RF is an easy-to-use ML algorithm that, even without changing its meta parameters, often delivers great results. This algorithm is one of the most commonly utilized machine learning algorithms for both “Classification” and “Regression” due to its simplicity and usability. This algorithm would randomly create a forest. The built “forest” is actually a “Decision Trees” band. This strategy can undoubtedly deal with huge datasets.

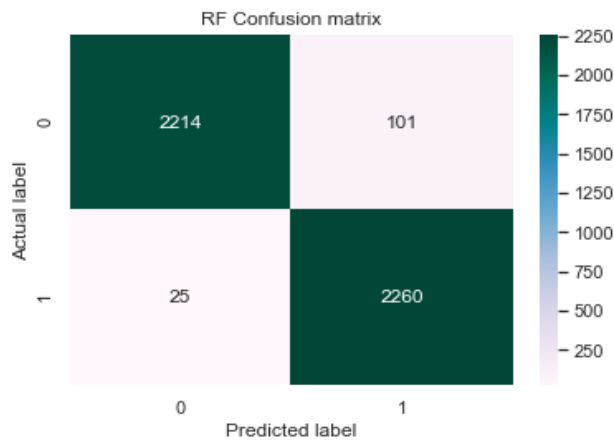


Figure 7. Confusion matrix for Random forests algorithm using PCA feature reduction technique.

Random Forest was created by Leo Bremen. It selects samples randomly from the dataset then builds a decision tree for each sample. A prediction result is measured from each decision tree. Then vote the prediction result after that the most votes consider the final prediction model [21].

Figure 7. illustrates the Confusion matrix for the RF algorithm when 100 estimators are selected, and the PCA feature reduction technique is used to forecast epilepsy.

3.4.3. Support Vector Machine (SVM)

SVM stands for supervised machine learning. Vapnik and Chervonenkis were the first to present the SVM in 1963. The SVM tries to locate an ideal hyperplane ready to isolate the examples of any class. If groups can be divided linearly, hyperplanes with maximum margins might be used to identify them. Otherwise, if the data are not linearly separable, they can be transferred to a bigger space to separate them linearly (i.e. feature space). The kernel function is the name for this conversion. This classifier specifies the hyperplane that isolates the spots to put the most noteworthy number of points of a similar class on a similar side while expands the interval of each class to such a hyperplane. The support vectors comprise of the closest points of the hyperplane. The interval from a class to a hyperplane is the littlest interval among them and the spots in that class [16].

The hyperplane can be utilized for grouping or regression moreover. SVM separates examples in particular groups and can likewise characterize the substances which are not upheld by data. Detachment is finished by through hyperplane plays out the partition to the nearest training spot of any group.

Figure 8. Shows the Confusion matrix for SVM algorithm using of PCA feature reduction technique to predict epilepsy.

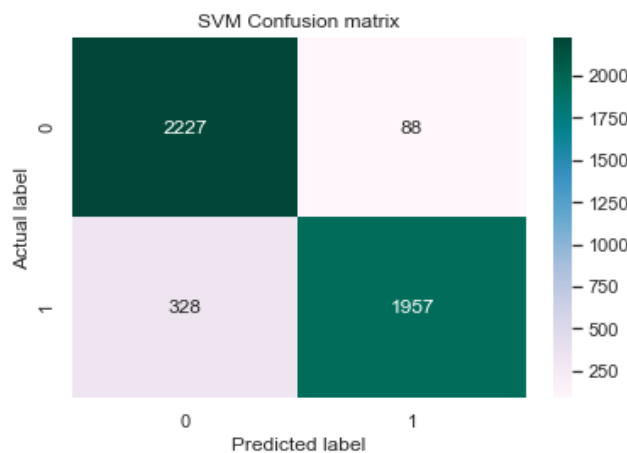


Figure 8. Confusion matrix for SVM algorithm with PCA feature reduction technique.

3.4.4. Artificial Neural Network (ANN)

ANNs are a network structure composed of a series of interconnected elements called neurons, each of which has an input and output and performs a relatively simple operation. Neural networks generally learn their function through a learning process. In fact, by processing data, they discover the law underlying them and transmit it to the network.

In fact, these networks are a software programs that can act like human beings in such a way that:

- More experienced, through over the time and by more interaction with the environment.
- In addition to performing calculations, able to draw logical conclusions.
- Provide a suitable solution in new conditions.

Artificial neural networks are computational structures modeled on the human brain. ANN is made up of many interconnected unit operations that cooperate to process data. They often deliver beneficial outputs as a result of it. In general, the ANN is comprised of network layers and network tasks, which the network layers namely the input layer, hidden layer and output layer. For the data mining model, the input neurons determine all the input attribute values [22].

A significant number of new headways have been made in the field of Artificial Intelligence, utilizing Artificial Neural Networks including Voice Recognition, Image Recognition and Robotics.

In Figure 9. The Confusion matrix for ANN algorithm using the PCA feature reduction technique to predict epilepsy is shown.

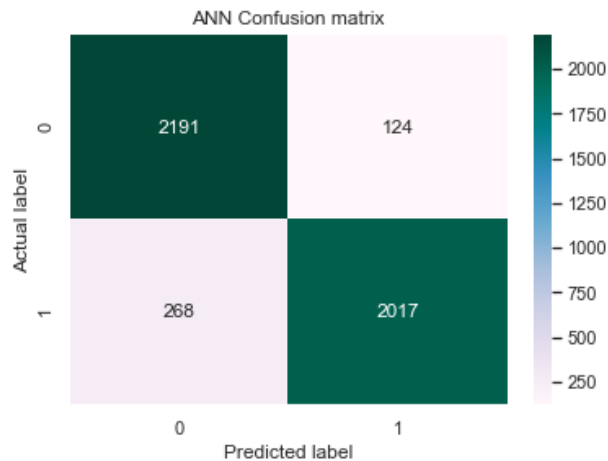


Figure 9. Confusion matrix for ANN algorithm using PCA feature reduction technique.

3.4.5. Decision Tree (DT)

A DT is a decision-making aid that employs tree modeling. DT is a fundamental classification and regression technique. In operations and research, the decision tree is commonly used. DT model that has a tree structure can be used to define the mechanism of classifying instances based on characteristics [23]. When the result attribute is categorical, a decision tree is used.

The root node, branches, and leaves make up the decision tree graph. Classification takes place on the leaves, while the outcomes of each occurrence are stored on the branches. The pathways from the root node to the leaf nodes are taken into account while creating categorization rules [24].

Both nominal and numerical features are provided by the decision tree algorithm. It has the potential to tolerate noise and unstable values. The decision tree uses a top-down approach to categorize the whole qualified dataset by partitioning the nodes from the topmost to the class node. Every node represents the instance's test attribute, with each node representing one of the several likely values for that feature attribute.

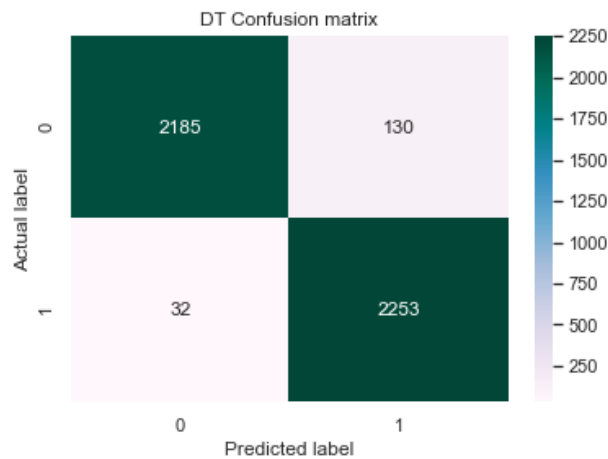


Figure 10. Confusion matrix for DT algorithm using PCA feature reduction technique.

From the top node to the attack class node level by level, a decision tree can easily turn the specified set of instances into meaningful patterns.

In Figure 10. the Confusion matrix for DT algorithm using the PCA feature reduction technique to predict epilepsy is Shown.

4. Results and Discussion

The outcomes of utilizing several classifiers to classify the epilepsy data set and the performance of the classifications using PCA and without using PCA feature reduction are analyzed in this section.

Table 2 and Figure 11. shows the Comparison of the different Classification Techniques using PCA feature reduction and setting 75% of the dataset for training and 25% for testing. According to the Table 2. We see that the RF Classification algorithm with 97 % accuracy and with low Computational times (training time and test time) shows the best result, after the RF the KNN and DT algorithms with 96 % accuracy and too low Computational times are shown the best result. It is worth to mentioning that the Computational times is also related to power of the computer workstation, it means that in a powerful workstation the Computational times will be too low.

Table 2. Comparison of the different Classification Techniques using PCA feature reduction and setting 75% of the dataset for training and 25% for testing.

Classification Techniques	Accuracy	Precision	Recall	F1 score	Train time (S)	Test time (S)
KNN	96%	96%	96%	96%	0.015	0.29
RF	97%	97%	97%	97%	0.92	0.05
SVM	90%	91%	90%	90%	2.23	0.41
ANN	91%	91%	91%	91%	6.70	0.005
DT	96%	96%	96%	96%	0.057	0.0009

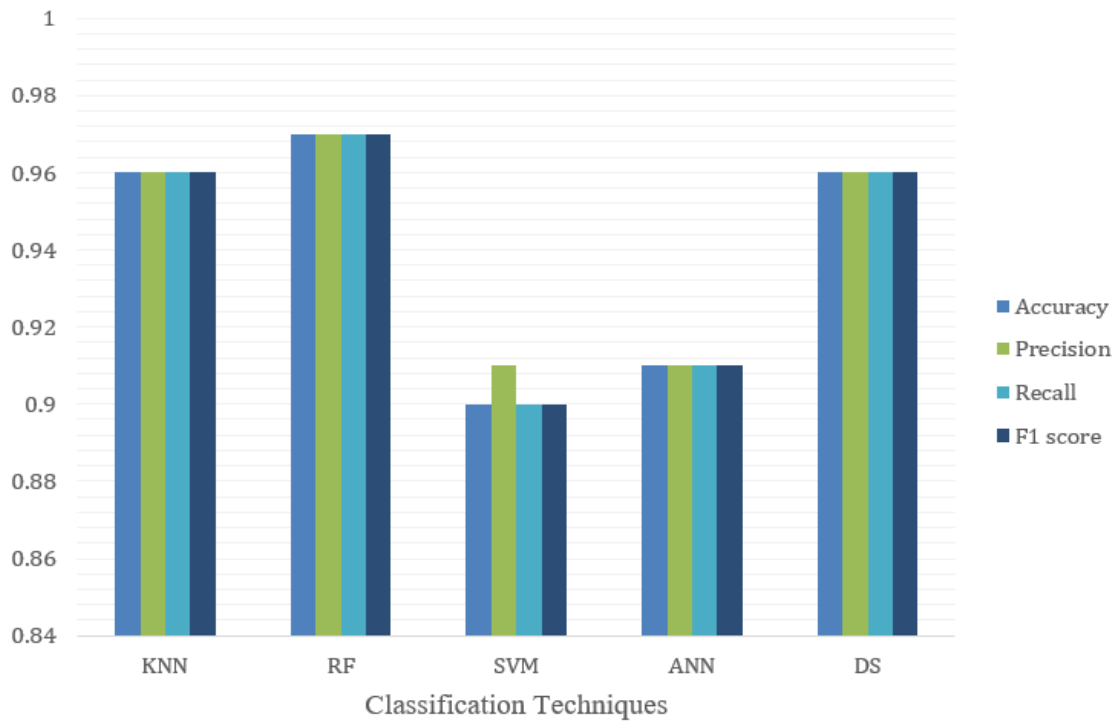


Figure 11. Comparison of the different Classification Technique using PCA feature reduction and setting 75% of dataset for training and 25% for testing

Table 3. Comparison of the different Classification Techniques without using the PCA feature reduction and setting 75% of dataset for training and 25% for testing.

Classification Techniques	Accuracy	Precision	Recall	F1 score	Train time (S)	Test time (S)
KNN	99%	99%	99%	99%	1.00	15.68
RF	99%	99%	99%	99%	6.83	0.072
SVM	97%	97%	97%	97%	10.15	2.517
ANN	92%	92%	92%	92%	22.11	0.014
DT	97%	97%	97%	97%	3.13	0.009

Table 4. Comparison of the different classification techniques with using PCA feature reduction and setting 70% of dataset for training and 30% for testing.

Classification Techniques	Accuracy	Precision	Recall	F1 score	Train time (S)	Test time (S)
KNN	96%	96%	96%	96%	0.014	0.331
RF	97%	97%	97%	97%	0.986	0.068
SVM	90%	91%	90%	90%	1.735	0.424
ANN	91%	91%	91%	91%	5.9	0.005
DT	96%	96%	96%	96%	0.0519	0.0009

According to Table 3 We see that without using the PCA feature reduction technique the classification algorithms show high accuracy, but with high Computational times, in this case the KNN and random Forest (RF) Classification algorithms with 99 % accuracy shows best result. After the KNN and RF the DT and SVM Classifiers with 97 % accuracy has good result.

Table 4 illustrates the comparison of the different classification techniques using the PCA feature reduction technique and setting 70% of dataset for training and 30% for testing. In this case, we see that the RF classifier shows the best result with 97% accuracy.

Table 5. Comparison of the different classification techniques without using the PCA feature reduction and setting 70% of dataset for training and 30% for testing.

Classification Techniques	Accuracy	Precision	Recall	F1 score	Train time (S)	Test time (S)
KNN	99%	99%	99%	99%	0.961	16.20
RF	99%	99%	99%	99%	5.62	0.075
SVM	97%	97%	97%	97%	8.56	2.43
ANN	92%	92%	92%	92%	22.297	0.0139
DT	97%	97%	97%	97%	2.81	0.008

Table 6. Accuracy Comparison of Classification Techniques using PCA and without using PCA

Classification Techniques	Accuracy using the PCA	Accuracy without using the PCA
KNN	96%	99%
RF	97%	99%
SVM	90%	97%
ANN	91%	92%
DT	96%	97%

Table 7. Computational time evaluation of Classification Techniques using PCA and without using the PCA.

Classification Techniques	Using PCA		Without Using PCA	
	Train time (S)	Test time (S)	Train time (S)	Test time (S)
KNN	0.015	0.29	1.00	15.68
RF	0.92	0.05	6.83	0.072
SVM	2.23	0.41	10.15	2.517
ANN	6.70	0.005	22.11	0.014
DT	0.057	0.0009	3.13	0.009




Figure 12. Accuracy Comparison of Classification Techniques using the PCA and without using the PCA.

Table 8. The result comparisons of different research studies with our study.

Research Studies	Number of Classes	Methods	The best method	Accuracy	
Almustafa[5]	2	RF, DT, K-NN, Naïve Bayes, Logistic Regression, Random Tree, J48 and Stochastic Gradient Descent (S.G.D.)	RF	97%	
Nandy et al., [4]	2	SVM classifier for classification, Linear Discriminant Analysis (LDA) and Quadratic Linear Discriminant Analysis (QLDA) for comparison.	SVM	97%	
Usman et al., [6]	2	PCA for feature extraction and SVM classifier to classification.	SVM	Average sensitivity 93.1%	
Swami et al.,[9]	2	Used dual-tree complex wavelet transform (DTCWT) for decomposition of signals and calculate statistical measurements, and general regression neural network classifier for classification	Neural network	95%	
This Paper	2	K-NN, RF, SVM, ANN & DT	K-NN	Without PCA	Using PCA
			RF	99%	96%
			DT	99%	97%
			DT	97%	96%

Table 5 also illustrates the Comparison of the different classification techniques without using the PCA feature reduction technique and setting 70% of dataset for training and 30% for testing. In this case, we see that the KNN and RF classifier also show the best result with 99% accuracy, in addition, shows a little low training and testing time compared to setting the 75% of dataset to training.

According to Table 6, we can see that the RF classifier shows the best result using the PCA feature reduction technique with 97 %. At the same time, without using the PCA feature reduction technique, the KNN and RF with 99 % accuracy, it shows the best result.

Table 7 shows the Computational times evaluation of Classification Techniques using the PCA and without using the PCA feature reduction technique. According to this table we can say that by using PCA feature reduction technique, we reduce the computational times. At the same time, according to Figure 12. the accuracy of the classifiers is reduced.

Table 8 compares the results of other research papers in the field of Epileptic Seizure classification with our paper.

5. Conclusion

Epileptic seizures are currently one of the leading reasons for morbidity and mortality in the world. With the rise of epileptic seizures around the world and their effect on people's lives, it's more important than ever to get an accurate and timely diagnosis.

The fundamental goal of this paper was to discover the best classification algorithm for epileptic seizures by applying the Principal Components Analysis (PCA) feature reduction technique in the dataset.

In this paper, we applied K-Nearest Neighbors (KNN), Random Forest (RF), Support Vector Machine (SVM), Artificial Neural Network (ANN), and Decision Tree (DT) algorithms by using the PCA feature reduction technique in the dataset to predict epilepsy, and the performance of classifiers are analyzed with using PCA and without using the PCA technique.

It has been demonstrated that the Random Forest classifier (RF) with an accuracy of 97% and with low Computational times (training time and test time) shows the best result by using the PCA feature reduction in the dataset. In addition, the K-Nearest Neighbors (KNN) and random forest classifiers (RF) with 99 % accuracy without using PCA feature reduction in dataset, shown the best result.

It is worth to mentioning that using PCA feature reduction technique reduces the computational times. At the same time, the accuracy of the classifiers is also reduced. In both cases, using PCA and without using PCA after the random forest classifier (RF) the KNN Classifier with 96% accuracy by using PCA and 99 % accuracy without using PCA has shown good result.

References

- [1] Fisher, R., Acevedo, C., Arzimanoglou, A., Bogacz, A., Cross, J., Elger, C., et al. (2014). ILAE official report: a practical clinical definition of epilepsy, *Epilepsia*, 55,4, 475-482.
- [2] Ramgopal, S., Thome-Souza, S., Jackson, M., & Kadish, N. E., Sánchez Fernández, I., Klehm, J., Bosl, W., Reinsberger, C., Schachter, S., & Loddenkemper, T. (2014). Seizure detection, seizure prediction, and closed-loop warning systems in epilepsy. *Epilepsy & behavior: E&B*, 37,291–307.
- [3] Lehnertz, K., Mormann, F., Kreuz, T., Andrzejak, R. G., Rieke, C., David, P., & Elger, C. E. (2003). Seizure prediction by nonlinear EEG analysis. *IEEE engineering in medicine and biology magazine: the quarterly magazine of the Engineering in Medicine & Biology Society*, 22,1,57–63.
- [4] Nandy, A., Alahe, M. A., Nasim Uddin, S. M., Alam, S., Nahid, A. A., & Awal, M. A. (2019). Feature Extraction and Classification of EEG Signals for Seizure Detection. *2019 International Conference on Robotics,Electrical and Signal Processing Techniques (ICREST)*.
- [5] Almustafa, K. M. (2020). Classification of epileptic seizure dataset using different machine learning algorithms. *Informatics in Medicine Unlocked*, 21, 100444.
- [6] Usman, S. M., Latif, S., & Beg, A. (2019). Principal components analysis for seizures prediction using wavelet transform. *International Journal of Advanced and Applied Sciences*, 6, 3, 50–55.
- [7] Hamad, A., Houssein, E. H., Hassanien, A. E., & Fahmy, A. A. (2017). A Hybrid EEG Signals Classification Approach Based on Grey Wolf Optimizer Enhanced SVMs for Epileptic Detection. *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics*, 108–117.
- [8] Sharmila, A., & Geethanjali, P. (2016). DWT Based Detection of Epileptic Seizure from EEG Signals Using Naive Bayes and k-NN Classifiers. *IEEE Access*, 4, 7716–7727.
- [9] Swami, P., Gandhi, T. K., Panigrahi, B. K., Tripathi, M., & Anand, S. (2016). A novel robust diagnostic model to detect seizures in electroencephalography. *Expert Systems with Applications*, 56, 116–130.
- [10] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 64, 6.
- [11] Soni, M., & Varma, S. (2020), Diabetes Prediction using Machine Learning Techniques, *International Journal of Engineering Research & Technology (IJERT)*, 9, 9.
- [12] Ippolito, P. P. (2019). Feature Extraction Techniques - Towards Data Science. Retrieved, from <https://towardsdatascience.com/feature-extraction-techniques-d619b56e31be>, (Date of access: December 27, 2020).
- [13] Qiu, J., Wang, H., Lu, J., Zhang, B., & Du, K. L. (2012). Neural Network Implementations for PCA and ItsExtensions. *ISRN Artificial Intelligence*, 2012, 1–19.
- [14] Ghosh-Dastidar, S., Adeli, H., & Dadmehr, N. (2008). Principal Component Analysis-Enhanced Cosine Radial Basis Function Neural Network for Robust Epilepsy and Seizure Detection. *IEEE Transactions on Biomedical Engineering*, 55(2), 512–518.
- [15] Yağanoğlu, M., & Köse, C. (2018). Real-Time Detection of Important Sounds with a Wearable Vibration Based Device for Hearing-Impaired People. *Electronics*, 7, 4, 50.
- [16] Rodrigues, J. D. C., Filho, P. P. R., Peixoto, E., N, A. K., & de Albuquerque, V. H. C. (2019). Classification of EEG signals to detect alcoholism using machine learning techniques. *Pattern Recognition Letters*, 125, 140–149.
- [17] Mitchell, T. M. (1997). Does Machine Learning Really Work?. *AI Magazine*, 18, 3, 11..
- [18] Freund, Y., Schapire, R.E., 1996. Experiments with a new boosting algorithm. In: *Machine Learning. Proceedings of the Thirteenth International Conference*. 148–156.
- [19] Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24, 2, 123–140.
- [20] Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random Forests for land cover classification. *Pattern Recognition Letters*, 27, 4, 294–300.
- [21] Fawagreh, K., Gaber, M. M., & Elyan, E. (2014). Random forests: from early developments to recent advancements. *Systems Science & Control Engineering*, 2, 1, 602–609.
- [22] Walczak, S., & Cerpa, N. (2003). Artificial Neural Networks. *Encyclopedia of Physical Science and Technology*, 631–645.

- [23] Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1, 1, 81–106.
- [24] Geetha, A., & Nasira, G. M. (2014). Data mining for meteorological applications: Decision trees for modeling rainfall prediction. *2014 IEEE International Conference on Computational Intelligence and Computing Research*.



AZ31 Magnezyum Alaşımı İçin Aşırı Yaşlandırmanın Bazı Mekanik Özelliklere Etkisi

Mehmet ŞAHBAZ*^{ID}

(Alınış / Received: 04.10.2021, Kabul / Accepted: 09.12.2021, Online Yayınlanma / Published Online: 31.12.2021)

Anahtar Kelimeler

Basma Testi
Charpy Darbe Testi
Isıl İşlem
Sertlik Testi

†Öz: Bu çalışmada ağırlığına oranla yüksek mukavemeti ile son yıllarda oldukça ilgi gören magnezyum alaşımlarından alüminyum (Al~%3) ve çinko (Zn~%1) oranının çoğunlukta bulunduğu AZ31 alaşımının ısıl işlemler sonucu bazı mekanik özellikleri incelendi. Numunelere ilk olarak iki saat boyunca 345 °C sıcaklıkta homojenleştirme tavlama yapıldı, böylece malzemedeki iç gerilmeler giderilmiş oldu. Daha sonra karşılaştırma yapmak için numunelerin bir kısmına 180 °C de 12 saat süreyle yapay aşırı yaşlandırma işlemi yapıldı. Mukavemet değerlerinin ölçümü için basma ve sertlik testleri uygulandı ve elde edilen sonuçlar gösterdi ki; aşırı yaşlandırma işlemi malzemenin basma ve sertlik değerlerinde olumlu bir etki göstermedi. Ayrıca bu çalışmada, Charpy impact testi kullanılarak aşırı yaşlandırma işleminin malzemenin ani darbeler karşısındaki dayanımına etkisi incelenmiştir. Sertlik ve basma test değerlerinin aksine darbe test sonuçları, aşırı yaşlandırmadan olumsuz etkilenmemiş olup, aşırı yaşlandırılan malzemenin darbe sönümlenme dayanımı (J/cm²) tavlama sonrası yaklaşık %13 daha yüksek elde edildi. Bunun sebebi aşırı yaşlandırılmış malzemenin tane sınırındaki çökelmelerin ani dinamik yükleme sonucu göstermiş oldukları davranışlarıyla açıklanabilir.

The Effect of Over-Aging on Some Mechanical Properties for AZ31 Magnesium Alloy

Keywords

Compression Test
Charpy Impact Test
Heat Treatment
Hardness Test

Abstract: In this study, some mechanical properties of the AZ31 alloy, which has the majority of aluminum (Al~3%) and zinc (Zn~1%) magnesium alloys, which have attracted a lot of attention in recent years due to its high strength compared to its weight, were investigated as a result of heat treatment. The samples were first homogenized annealed at 345 °C for two hours, so that the internal stresses in the material were relieved. Then, for comparison, some of the samples were artificially over-aged at 180 °C for 12 hours. Compression and hardness tests were applied to measure the strength values and the results showed that; The over-aging process did not have a positive effect on the compression and hardness values of the material. In addition, in this study, the effect of over-aging on the strength of materials against sudden impacts was investigated using the Charpy impact test. Contrary to the hardness and compression test values, the impact test results were not adversely affected by over-aging, and the impact damping strength (J/cm²) of over-aged materials was obtained approximately 13% higher than the annealed ones. The reason for this can be explained by the behavior of the grain boundary precipitates of the over-aged material as a result of sudden dynamic loading.

1. Giriş

Metallerin darbe (impact) testleri, malzemelerin kırılma özelliklerini incelemek için kullanılan en yaygın testlerden biridir. Bu test ile önceleri sadece kırılma enerjisi elde edilebilirken günümüzde daha fazla bilgi elde

¹ Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, 70100, Karaman

edilebilmekte, tüm kuvvet-yer değiştirme eğrisini ölçmeye izin veren aletli Charpy cihazları kullanılmaktadır [1-3]. Bununla birlikte, darbe testleri, hızlı ve ekonomik olma özelliğiyle, bir maddenin tokluğunu değerlendirmek için en yaygın kullanılan testlerden biri olarak kabul edilmektedir. Genellikle Charpy darbe testi, malzemeler darbe yükü ile kırılırken kırılma sırasında emilen enerji miktarını hesaplayarak malzemelerin darbe direncini veya tokluğunu belirlemek için yapılmaktadır. Darbe testi, sıcaklığın darbe enerjisi üzerindeki etkisini ortaya çıkarmak için çeşitli sıcaklıklarda da gerçekleştirilebilir. Böylece, bir malzemenin belirli şartlardaki ortam ve uygulama için uygunluğunu değerlendirmede ve beklenen hizmet ömrünü tahmin etmede çok faydalı olabilecek test sonuçları elde edilir. Bu test, metaller, kompozitler, seramikler ve polimerler gibi mühendislik malzemelerinin çentik hassasiyetini ve darbe tokluğunu belirlemek için ekonomik bir kalite kontrol yöntemi olarak kullanılmaya devam etmektedir [4].

Metallerin darbe testleri, bir malzemenin gevrek veya sünek olarak sınıflandırılıp sınıflandırılmayacağını da gösterir. Test esnasında sönmüş enerji miktarı metalin gevrekliği veya kırılabilirliği hakkında fikir sahibi olmamızı sağlar. Test sonrası kırılma yüzeyinin görünümü, meydana gelen kırılma tipi hakkında bilgi verir; kırılma bir malzemenin yüzeyi parlak ve kristaldir, sünek bir malzeme yüzeyi ise donuk ve liflidir. Darbe testi sonrası kırılan yüzeyden hesaplanan yüzde (%) kristallik oranı, gevrek kırılma miktarının bir ölçüsüdür. Yine darbe testi sonrası kırılan yüzeyin kesit alanı ölçülerek tespit edilen yanal genişleme ise, numunenin sünekliğinin bir ölçüsüdür. Sünek bir metal kırıldığında, test parçası kırılmadan önce deforme olur ve malzeme, sıkıştırma yüzünün kenarlarından yığılma yapar. Numunenin bu şekilde ne kadar deforme olduğu ölçülür ve milimetre yanal genişleme olarak ifade edilir. Charpy testinin sonuçlarında, emilen enerji (Joule cinsinden) genellikle verilirken, yüzde kristallik ve yanal genişleme çoğu zaman verilmeyebilir [5].

Ayrıca yaşlandırma, tavlama, homojenleştirme ve çöktürme alma gibi ısıl işlemlerin metal malzemelerin mikroyapısı ve mekanik özellikleri üzerindeki etkileri de bilinmekte ve bu alanda incelemeler devam etmektedir [6]-[10]. Aşağıda literatürde rastlanan ve bu çalışmanın altyapısını oluşturan çalışmalardan bazıları kısaca özetlenmiştir. Kerenciler vd. yaptıkları çalışmada yaşlandırma işleminin AZ31 Magnezyum alaşımının mekanik ve mikroyapısal özellikleri üzerine etkilerini araştırmışlardır [16, 17]. Gür vd. yaptıkları çalışmada ramor zırh çeliğinin farklı sıcaklıklarda tavlama ve farklı ortamlarda soğutulması sonucu mikroyapı ve sertlik değerlerindeki değişimleri incelemişlerdir. Kızılkaya ve Ovalı ise AISI-4140 çeliğine yüksek sıcaklıkta östenitleme ve temperleme ısıl işlemleri uygulayıp devamında ise -197 C de kriyojenik işlem uygulamışlardır. Bu işlemlerin malzemenin sertlik ve Charpy darbe dayanımını artırdığını test ederek göstermişlerdir. Matik ise akımsız Ni-B kaplanmış demir esaslı toz metal kompaktların sertlik ve yapısal özelliklerine ısıl işlemin etkisini incelemiş ve sonuçları çalışmada göstermiştir. Şahbaz vd. yaptıkları çalışmada AA5083 ve AZ31 alaşımlarına aşırı plastik deformasyon (APD) uygulamadan önce tavlama ısıl işlemi yaparak malzemeleri homojenleştirmiş, böylece APD işleminin malzemelerin mikroyapısı ve mekanik özellikleri üzerindeki etkilerini daha doğru ve hassas belirlemişlerdir [9-10].

Bazı çalışmalarda ise doğrudan yapay yaşlandırmanın malzeme tokluğu üzerindeki etkileri incelenmiştir [11], [12]. Alexopoulos vd. farklı yaşlandırma ortamlarının A357 (Al-7Si-0.7Mg) alaşımının dinamik tokluğu üzerine etkisini Charpy darbe testi kullanarak incelemişlerdir. Liu vd. ise bir magnezyum alaşımı olan Mg-10Gd-3Y-0.5Zr için bazı ısıl işlemlerin malzemenin yorulma ve kırılma tokluğu özelliklerinde meydana getirdiği değişimleri incelemişlerdir.

Magnezyum 1.738 g/cm³ yoğunluk ile alüminyumdan üçte bir oranında daha hafif olması nedeniyle, otomotiv, havacılık ve bilişim endüstrisi gibi sektörlerde kullanımı giderek yaygınlaşmaktadır. Ayrıca magnezyum hekzagonal kristal kafes yapısına sahip bir malzeme olduğu için oda sıcaklığında şekillendirilmesi zordur ve 150 °C altında şekil değişimine karşı yüksek direnç göstermektedir [13].

Bununla birlikte, genel olarak alaşım şeklinde kullanılan magnezyumun alüminyum içeren alaşımlarında (AZ, AS, AM vb. seriler) alüminyum magnezyum ile reaksiyona girerek β (Mg₁₇Al₁₂) fazını oluşturmaktadır. Bu durum, alaşımın genel olarak dökülebilirliğini, sertliğini ve akma mukavemetini arttırmakla birlikte malzemenin sünekliğini de geliştirmekte alaşımın korozyon dayanımını iyileştirmektedir. Çinko (Zn), Mg alaşımlarında genellikle Al ile beraber kullanılmaktadır ve Mg içerisinde kolay bir şekilde çözünebilmektedir. Mg ile reaksiyona girerek ikincil fazı oluşturmakta ve tane sınırları boyunca bu faz yerleşmektedir. Bu durum mekanik özellik olarak alaşımın çekme mukavemetini arttırmakta ve katı çözünürlük ve yaşlandırma sertleşmesini geliştirici etki yapmaktadır. Bununla birlikte çinko düşük oranlarda eklendiğinde alaşım üzerinde korozyon direncini artırıcı etki göstermektedir [14], [15].


Endüstride kullanımı giderek artmakta olan magnezyum alaşımından üretilen parçalar (özellikle dış yüzeyde kullanılanlar) zamanla doğal yaşlanmaya (hatta aşırı yaşlanmaya) maruz kalmaktadırlar. Ayrıca bu parçalar çevreden gelebilecek darbelere de doğrudan maruz kalmaktadırlar. Literatür incelendiğinde aşırı yaşlandırılmış malzemelerin mekanik özelliklerinin (özellikle sertlik ve mukavemet değerlerinin) aşırı yaşlandırmadan

olumsuz etkilendiği görülmektedir [16]. Fakat çalışmalarda aşırı yaşlandırmanın malzemenin darbe dayanımına olan etkisini araştıran bir çalışmaya rastlanmamıştır. Bu sebepten aşırı yaşlandırılmış magnezyum alaşımının mekanik özelliklerinin (özellikle darbe dayanımının) test edilmesi bu alanda ileride karşılaşılabilecek sorunların öngörülmesi açısından faydalı olacağı düşünülmüştür. Bu çalışmada aşırı yaşlandırma işleminin AZ31 magnezyum alaşımı üzerinde bazı mekanik özelliklere etkisi incelenmiştir. Mekanik özelliklerin tespiti için sertlik (Vickers), basma ve Charpy darbe testleri standartlara uygun hazırlanmış numuneler üzerine uygulanmıştır. Elde edilen sonuçlar, ısıl işlem sonucu mikroyapıda meydana gelen değişiklikler ile karşılaştırmalı olarak incelenmiş olup aralarında bağlantı kurulmuştur.

2. Materyal ve Metot

Bu çalışmada hafifliğine oranla yüksek dayanımı ile son yıllarda alüminyum alaşımlarına alternatif olan magnezyum alaşımlarından AZ31 kullanılmıştır. Metot olarak bu çalışmada öncelikle malzemenin aşırı yaşlandırma sonrası mekanik özellikleri incelendiği için önce ısıl işlem yöntemleri sonrasında ise mekanik test yöntemleri anlatılacaktır. Isıl işlem olarak öncelikle tüm numuneler 345 °C de 2 saat boyunca gerilim giderme ve homojenleştirme tavlmasına tabi tutuldu. Devamında ise bazı numunelere 12 saat boyunca 180 °C de yapay yaşlandırma işlemi uygulandı.

Isıl işlemlerin malzeme üzerindeki etkileri incelemek için ise mekanik test olarak, sertlik, basma ve Charpy darbe testleri uygulandı. Sertlik ölçümlerinde 30kgf yük, 6 saniye bekleme süresi ve elmas piramit uç ile Vickers-30 (HV30) test metodu kullanıldı. Sertlik ölçümleri için her numune üzerinden farklı bölgelerden sekiz iz ölçümü yapıldı. Basma testi ise kenar uzunluğu 10 mm olan küp şeklinde hazırlanan tavllanmış ve aşırı yaşlandırılmış numunelere 1 mm/d hız ile uygulandı, her durum için basma testi beşer defa tekrarlandı. Darbe testi olarak ise Charpy darbe testi 140 derece açılı mesafeden 300 J enerjiye karşılık gelen 21.3 kg ağırlığındaki çekicinin numuneye 5.308 m/s ile çarptırılması ile gerçekleştirildi ve absorbe edilen enerji, cihazın dijital ekranından okundu. Bu test ise her durum için üçer defa tekrarlandı. Şekil 1'de Charpy darbe testi için hazırlanmış çentikli ve çentiksiz numuneler (Şekil 1a) ve test cihazı kataloğunda yer alan standartlara (EN ISO 10045'e) göre hazırlanmış teknik çizimler gösterilmiştir (Şekil 1b-d).

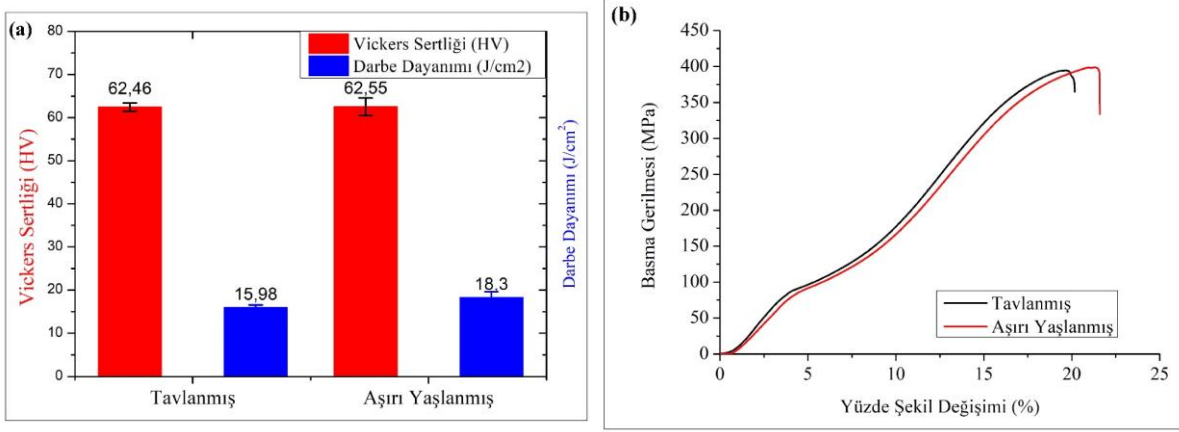


Şekil 1. Charpy test numuneleri ve boyutları, (a) çentikli ve çentiksiz numuneler, (b) u-çentikli numunenin boyutları, (c) u-çentiğin detaylı görünümü, (d) çentik kesit alanı boyutları

3. Bulgular

Bu kısımda uygulanan ısıl işlemlerin malzeme üzerindeki etkilerini görmek için, tavllanmış ve aşırı yaşlandırılmış numunelerin öncelikle sertlik test sonuçları, sonra basma test sonuçları ve son olarak Charpy darbe test sonuçları sunulmaktadır karşılaştırılacaktır.

HV30 sertlik testi ile yapılan ölçümlerin sonuçları alttaki grafikte verilmiş olup aşırı yaşlandırma neticesinde sertlik değerlerinin hemen hemen tavllanmış malzemenin sertlik değerlerinde olduğu gözlemlenmiştir (Şekil 2a). Sertlik ölçümleri sekiz defa yapılmış ve dikkat çeken bir durum olarak, ortalama değerler yakın olsa da ölçümlerdeki standart hatanın aşırı yaşlandırılmış numunelerde diğerinden fazla olduğu gözlemlenmiştir. Bunun sebebi olarak tane sınırlarındaki heterojen faz çökelmelerinin sertlik ölçümlerini etkilediği öngörülmektedir. Öyle ki sertlik ölçümlerinin tüm yüzeyde homojenlik göstermediği farklı bölgelerde farklı çıkarak standart sapmayı artırdığı görülmektedir. Tavllanmış numunelerde ise bu durumun aksine sertlik ölçümleri neredeyse homojen olup standart sapmanın düşük olduğu görülmektedir.




Şekil 2. Tavlanmış ve aşırı yaşlandırılmış AZ31 alaşımı için (a) sertlik ve darbe dayanım testi sonuçları grafiği (b) basma testi sonuçları grafiği

Basma testleri ise tavlanmış ve aşırı yaşlandırılmış numunelere beşer defa uygulanmış ve basma gerilmesinin (MPa) yüzde yer değişimi (%) ile karşılaştırılması grafik olarak incelenmiştir (Şekil 2b). Normal süreli yaşlandırma işleminin malzemenin gerilme değerlerini artırması beklenirken [17], Şekil 2b'de de görüldüğü gibi aşırı yaşlandırma işlemi bu kazanımları yok etmiş ve gerilme değerleri neredeyse tavlanmış malzeme seviyesine kadar düşmüştür. Bu durum yine aşırı yaşlandırma ile çökelen fazın kendi kafes sistemini oluşturması ile matris yapısındaki çarpılmanın azalmasına bağlı olarak sertlik ve mukavemet değerlerinin düşmesi ile açıklanabilir. Bu durum basma testi sonuçlarında da gözlemlenmiş olup aşırı yaşlandırmanın etkisi ile elde edilen değerler yaşlandırma öncesi değerlere yakın çıkmıştır.


Sertlik ve basma testi sonuçlarının aksine Charpy darbe test sonuçları, aşırı yaşlandırmadan olumsuz etkilenmemiş olup aşırı yaşlandırılan malzemenin darbe sönümlenme dayanımı (J/cm²) tavlanmış olandan yaklaşık %13 daha yüksek çıkmıştır (Şekil 2a, Tablo 1). Bunun sebebi aşırı yaşlandırılmış malzemenin tane sınırındaki çökelmelerin (β fazlarının) ani dinamik yükleme sonucu davranışıyla açıklanabilir. Darbe testindeki hız ve aşırı kuvvet malzemenin, kırılma anında ani pekleşmesine sebebiyet verip malzeme tokluğunu, dolayısıyla darbe dayanımını arttırmış olmalıdır.

Beta fazlarının yaşlandırma ile oluşması, boyutları ve taneler arasındaki dağılımları için aşağıdaki şekiller bilgilendirici olacaktır. Şekil 3'te AZ31 malzemesi için sırasıyla temin edilmiş hali, homojenleştirme tavlama yapılmış hali ve aşırı yaşlandırma yapılmış hali verilmiştir. Aşırı yaşlandırmanın etkisi ile Beta fazlarının irileştiği ve heterojen dağıldıkları görülmektedir.



Şekil 3. AZ31 için optik mikroskop görüntüleri a) temin edildiği hali, b) homojenleştirme tavlaması yapılmış hali, c) aşırı yaşlandırılmış hali [17]


Şekil 4'te ise aşırı yaşlandırılmış malzemenin SEM ve EDS görüntüsü verilmiş olup ((β - $Mg_{17}Al_{12}$) fazları tespit edilmiştir. Ayrıca Şekil 5'te XRD grafiği yardımı ile yaşlandırma işlemi sonucu Beta fazlarının oluşumu gösterilmiştir.



Şekil 4. AZ31 için SEM ve EDS görüntüleri ikincil fazların gösterimi [17]

Bu durumu daha iyi açıklamak için aynı malzemeden (AZ31) çentiksiz numune hazırlanmış ve darbe testi aynı şartlarda gerçekleştirilmiştir. Şekil 6a-b de görüldüğü üzere kare kesite sahip olan numune yüksek hız ve kuvvetten dolayı kesit alanında yüksek şekil değişimine maruz kalmıştır. Çekicinin vurduğu yerde malzeme

yığılmasından dolayı kalınlaşma (yanal genişleme) olurken diğer tarafta gerilmeden dolayı incelme olmuştur (Aynı durum Şekil 3c de çentikli numunedeki kısmen görülmüş olup ölçüm yapılarak bu durum doğrulanmıştır).

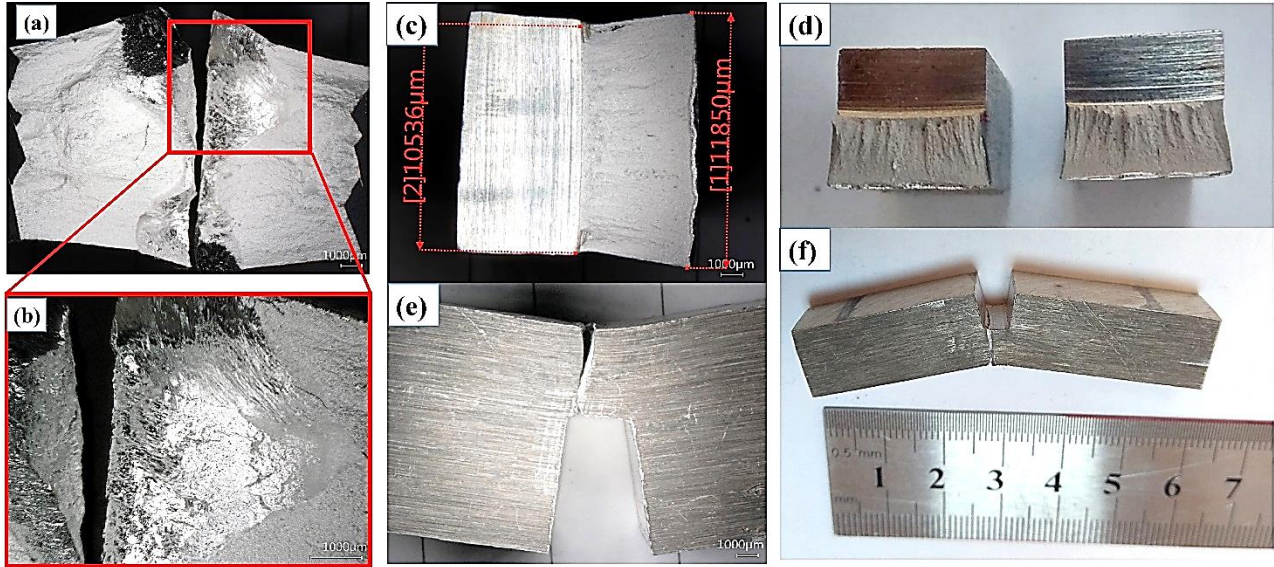


Şekil 5. AZ31 için XRD grafikleri üstte yaşlandırılmış, altta solüsyona alınmış (tavlanmış) [18]

Bu ani ve aşırı yükleme sonucu malzemede gerinim sertleşmesi (strain hardening) meydana gelmiş olup malzeme vurulan alanda pekleşerek sertleşmiş ve kırılganlaşmış olmalıdır. Darbe testi sonunda kırık yüzey incelendiğinde kristalli parlak yüzeyler malzemenin kırılgan olduğu, donuk ve lifli yüzeyler ise malzemenin sünek olduğu hakkında bilgi verdiğiinden girişte bahsedilmiştir [5].

Tablo 1. Tavlanmış ve aşırı yaşlandırılmış AZ31 malzemenin sertlik, basma ve darbe test sonuçları

Malzeme Isıl İşlemi	Maks. Gerilme (MPa)	Yüzde Uzama (%)	Sertlik (HV)	Charpy Darbe (J/cm ²)
Tavlanmış	394.44 ± 6.50	20.47 ± 0.52	62,46 ± 0,96	15.98 ± 0.57
Aşırı Yaşlandırılmış	397.70 ± 5.78	21.32 ± 1.13	62,56 ± 2,00	18.30 ± 1.33



Şekil 6. Charpy darbe testi sonucu kırık yüzeyler (a-b) çentiksiz numune yüzeyi, (c-d) çentikli numune yüzeyi, (e-f) kırılma sonrası çentikli numunedeki deformasyonun yandan görünüşü

Ayrıca bu çalışmada çentikli ve çentiksiz darbe testi sonucu malzeme tarafından absorbe edilen enerji miktarını belirlemek ve karşılaştırmak için aynı şartlarda her iki deneyde ısıl işlem yapılmamış ham AZ31 numuneler üzerinde üçer defa tekrar edildi (Şekil 6). Ortalamaları alınan testlerden çentikli test sonucu 16.16 J/cm² çıkarken, çentiksiz test sonucu 62.54 J/cm² olarak ölçülmüştür. Tavlanmış ve aşırı yaşlandırılmış numunelerin

Charpy darbe testi sonuçları Tablo 1 de verilmiş olup diğer mekanik testlerin (sertlik, basma) aksine bu testlerde aşırı yaşlandırılmış AZ31'in test sonuçları tavllanmış olandan daha yüksek çıktığı gösterilmiştir.

4. Tartışma

Bu çalışmada, bir ısıl işlem olan (yapay) aşırı yaşlandırmanın AZ31 magnezyum alaşımının bazı mekanik özellikleri üzerine etkileri araştırıldı. Yapılan çalışmada malzemenin mekanik özelliklerini belirlemede yaygın kullanılan sertlik ve basma testlerinin yanında Charpy darbe testleri de kullanıldı. Bu testler neticesinde tavllanmış ve aşırı yaşlandırılmış numunelerin sertlik ve basma test sonuçları beklendiği gibi çok küçük farklarla yakın değerler olarak elde edildi. Charpy darbe test sonuçlarında ise, aşırı yaşlandırılmış numunelerin test sonuçları %13 daha fazla elde edildi. Bu durumun aşırı yaşlandırma sonucu tane sınırlarında çökelen ikincil (β -Mg₁₇Al₁₂) fazların darbe testinde meydana gelen ani ve aşırı yüklenme ile malzemeyi pekleştirdiği ve netice olarak ta sonuçları yükselttiği ön görülmüştür. Bu görüşü destekler bir durum ise çentikli ve çentiksiz numunelerin darbe test sonuçları karşılaştırılmasında görüldü. Çentiksiz numunelerde daha fazla pekleşme, yanal genleşme meydana geldi ve böylece malzemenin gerinim sertleşmesi yükseldi ve malzemenin enerji sönümleme kapasitesi arttı. Kırık yüzeydeki yanal genleşme ve kristal-parlak alan bu durumun bir göstergesidir [19]. Bu durumun neticesinde ise çentiksiz numunelerin darbe test sonuçları çentikliden yaklaşık dört kat daha fazla çıktı.

Ayrıca bu çalışmada tespit edilen bir durum ise, yapılan ısıl işlemlerin malzemenin homojenliği üzerine etkileri oldu. Aşırı yaşlandırılmış malzemelerin tüm mekanik test sonuçlarındaki standart sapmalar, tavllanmış olanlardan yaklaşık iki kat daha fazla çıkararak bu işlemin malzeme homojenliğini azalttığı tespit edilmiştir. Bunun sebebi yukarıdaki şekillerde de gösterildiği gibi; yaşlandırma sonucu çökelen fazların boyutlarının irileşmesi ve bu fazların malzeme içinde heterojen bir şekilde dağılmış olması ile açıklanabilir.

5. Sonuç

AZ31 Magnezyum alaşımı üzerinde yapılan bu çalışmada, aşırı yaşlandırmanın basma ve sertlik testi sonuçlarını neredeyse etkilemediği deneysel olarak gösterilmiştir. Fakat yapılan Charpy impact testi sonuçlarında aşırı yaşlandırılan numuneler kırılırken daha fazla enerji sönümledikleri tespit edilmiştir.

Aşırı yaşlandırma, çökelen fazın (çoğunlukla β fazı-Mg₁₇Al₁₂) kendi kafes sistemini oluşturması ile matris yapısındaki çarpılmanın azalmasına bağlı olarak sertlik ve mukavemet değerlerinde düşmesine sebep olan bir durumdur. Darbe testindeki hız ve aşırı kuvvet aşırı yaşlandırılmış malzemenin, kırılma anında (malzemenin tane sınırındaki çökeltilerin ani dinamik yüklenme sonucu göstermiş oldukları davranışlarıyla neticesinde) ani pekleşmesine sebebiyet verip böylece malzeme tokluğunu, dolayısıyla darbe dayanımını arttırmış olacağı varsayılmaktadır.

Teşekkür

Laboratuvar imkânları ve malzeme tedariki için KMÜ Makine Mühendisliği Bölüm Başkanı Prof. Dr. Uğur Köklü ve yönetimine, makalenin inceleme ve değerlendirme aşamasında yapmış oldukları katkılardan dolayı editör ve hakemlere teşekkür ederim.

Kaynakça

- [1] Russell, S. B. (1898). Experiments with a new machine for testing materials by impact. *Transactions of the American Society of Civil Engineers*, 39,1380, 17-45.
- [2] Saba, N., Jawaid, M., & Sultan, M. T. H. (2018). An overview of mechanical and physical testing of composite materials. In *Mechanical and Physical Testing of Biocomposites, Fibre-Reinforced Composites and Hybrid Composites*, 1-12.
- [3] Tanguy, B., Besson, J., Piques, R., & Pineau, A. (2005). Ductile to brittle transition of an A508 steel characterized by Charpy impact test. Part II: Modeling of the Charpy transition curve. *Engineering Fracture Mechanics*, 72,3, 413-434.
- [4] Laboratory Testing Inc. 2021. Impact testing of metals. <https://www.labtesting.com/services/materials-testing/mechanical-testing/impact-testing/> (Erişim Tarihi: 24.06.2021).
- [5] TWI, L. 2021. What is the Charpy Test? The welding institute website: <https://www.twi-global.com/technical-knowledge/faqs/faq-what-is-charpy-testing> (Erişim Tarihi: 24.06.2021).
- [6] Gür, A. K., Taşkaya, S., & Özay, Ç. (2019). Ramor 500 çeliğinde ısıl işlemin mikroyapı, mikrosertlik ve abrasiv aşınma direncine etkisinin taguchi metoduyla değerlendirilmesi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 8,3, 1045-1056.

- [7] Matik, U. (2017). Akımsız Ni-B kaplanmış demir esaslı toz metal kompaktların sertlik ve yapısal özelliklerine ısıtma işleminin etkisi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 5,2, 223–230.
- [8] Kızılkaya, E., & Ovalı, İ. (2018). AISI 4140 Çeliğine uygulanan sığ kriyojenik işleminin mekanik özellikler üzerindeki etkisi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 6,1, 137–148.
- [9] Şahbaz, M., Kentli, A., & Kaya, H. (2021). Performance of novel TWO-CAP (thin-walled open channel angular pressing) method on AA5083. *Metals and Materials International*, 27,7, 2430-2437.
- [10] Şahbaz, M., Kaya, H., & Kentli, A. (2020). A new severe plastic deformation method: thin-walled open channel angular pressing (TWO-CAP). *International Journal of Advanced Manufacturing Technology*, 106,3–4, 1487–1496.
- [11] Liu, W., Jiang, L., Cao, L., Mei, J., Wu, G., Zhang, S., Ding, W. (2014). Fatigue behavior and plane-strain fracture toughness of sand-cast Mg-10Gd-3Y-0.5Zr magnesium alloy. *Materials and Design*, 59, 466–474.
- [12] Alexopoulos, N. D., Stylianos, A., & Campbell, J. (2013). Dynamic fracture toughness of Al-7Si-Mg (A357) aluminum alloy. *Mechanics of Materials*, 58, 55–68.
- [13] Öztürk, F., & Kaçar, İ. (2016). Magnezyum alaşımları ve kullanım alanlarının incelenmesi. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 1,2, 12–20.
- [14] Altay, M. (2012). AZ91 Magnezyum alaşımının mikro ark oksidasyon işleminde elektriksel parametrelerin etkisi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.
- [15] Çim, S. (2018). AZ91 Magnezyum alaşımının korozyon özelliklerinin ti mikro alaşımlama ile geliştirilmesi. Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi.
- [16] Kerenciler, H. (2014). Magnezyum alaşımlarında yaşlanma sertleşmesinin mekanik özelliklere etkisi, Yüksek Lisans Tezi, Karabük Üniversitesi.
- [17] Kerenciler H., S. Gündüz, M. A. Erden, M. Türkmen, and H. Karabulut, (2016). Effect of aging on the microstructure and mechanical properties of magnesium alloy AZ31. *Met. Sci. Heat Treat.*, 58, 3–4, 179–184.
- [18] Xu, D., K. Zhao, C. Yang, H. Li, and J. Zhang, (2018). Effect of heat treatment on microstructure and mechanical properties of the az31/we43 bimetal composites. *Metals (Basel)*, 8, 11, 971.
- [19] ASTM E 23-16, (2021). Standard test methods for notched bar impact testing of metallic materials. <https://www.astm.org/e0023-16.html> (Erişim Tarihi: 26.11.2021).



Health 4.0: Blockchain Applications in Healthcare

Ibrahim KAYA¹, Sercan DEMİR²

(Alınış / Received: 26.09.2021, Kabul / Accepted: 09.12.2021, Online Yayınlanma / Published Online: 31.12.2021)

Keywords

Blockchain technology

Industry 4.0

Health 4.0

IoT

Medical cyber-physical systems

Abstract: During the last decades, the advancement in industrial technology manifested itself in the concept of Industry 4.0, which incorporates digitization, smart automation technologies, the Internet of things, self-monitoring, and optimizing machines. Health science, one of the most interdisciplinary fields, with its sub-disciplines, constitutes a platform open to novel technologies from various fields such as pure science, engineering, and management. One of the fields transformed by Industry 4.0 is healthcare. An umbrella term “Health 4.0” is derived to cover all the recent technology advancements in the health field. Some of these advancements are the Internet of Things (IoT), Internet of Services (IoS), Medical Cyber-Physical Systems (CPS), Health Cloud, Health Fog, Health Big Data Analytics, Mobile Communication Networks, and Blockchain Technologies. Health 3.0 focused on the patients, communication, and monitoring of patients using new technologies like smart sensors, wearable devices, and big data. Health 4.0 added real-time monitoring, prediction, and AI-supported diagnostics to Health 3.0. The main objective of Health 4.0 is to provide high-quality healthcare services, improved efficiency and effectiveness, and optimization of the costs and resources. Blockchain technology offers a promising solution for healthcare data management with exceptional features such as decentralization, enhanced security, and immutability. However, the potential of blockchain technology has not been investigated in detail. This paper examines the prominent blockchain applications and challenges in Health 4.0 and its impact on the health industry.

1. Introduction

As the longevity of the world population increases with the advancements in healthcare, the aging of the population will increase healthcare costs [1]. The amount of funds spent on the health sector is growing larger each year, which causes an enormous burden on the economic development of countries. The countries need to transform their health organizations into a cost-effective yet high-quality producing structure. This will be one of the main factors that enable a nation to reach high welfare and prosperity in the next century. This transformation requires the adoption of the recent technological advancements in the Industrial Revolution as well as science. The young population percentage decreases by the aging population, which jeopardizes traditional hospital-based healthcare services [1]. A radical paradigm shift in health care is required for a more sustainable and high-quality health service in the near future. This is one of the most important driving factors for the emergence of the Health 4.0 concept.

The main objective of this paper is to provide and present the potential of blockchain technologies in the healthcare field. The paper is organized as follows. In Section 2, the historical progress of Industrial evolution and the emergence of Industry 4.0 are summarized. In section 3, the evolution of health care technologies and the Health

¹ Department of Biomedical Engineering, İzmir Katip Celebi University, İzmir, Türkiye

² Department of Industrial Engineering, Harran University, Şanlıurfa, Türkiye

4.0 concept are introduced. In section 4, Blockchain technology, one of the emerging technologies in the Industry 4.0 era, is explained. In section 5, some applications of the blockchain in healthcare are discussed. Finally, a summary of the blockchain and Health 4.0 are discussed in the conclusion.

2. Industry 4.0

Although there is no defined rule for categorizing the advancements in industrial technologies over time, the evolution of industrial technology can be divided into four stages. The water and steam-powered mechanical manufacturing, mass production technologies powered by electricity, and the electronics and information technologies-based industrial processes constitute the first three industrial revolutions, respectively [2]. Following the computerized machining by Industry 3.0, the main motivations for Industry 4.0 are to improve autonomous and smart industrial operations, achieve cost reduction and high quality by optimization, automation, and the use of intelligent services [3]. Globalization in recent decades required better efficiency, competency, and competitiveness, leading to a demand for high-level industrialization, informatization, and manufacturing digitization by Industry 4.0 [4]. Completely integrated digital systems and end-to-end digitization are two essential properties of Industry 4.0 [4].

The virtualization of the physical systems by such technologies as the Internet of Things (IoT) and machine-to-machine communication enable the movement of technological perspectives from embedded electronic systems to Cyber-Physical Systems (CPS) [5]. To support this movement, smart factories are being developed to realize complex production schemes in CPS. Cloud technology using distributed resources and CPS by connecting physical and software entities provides better integration in physical and virtual domains [4, 6].

Hermann et al. (2015) proposed six design principles of Industry 4.0: interoperability, virtualization, decentralization, real-time capability, service orientation, and modularity [7]. Interoperability stands for the capability of a system to share information with others to achieve a function or action. In cyber-physical systems, interoperability is key to completing the system loop and exchanging data without interruption [8]. Virtualization is the ability of a system to monitor physical processes by CPS and create a virtual copy. [7]. By decentralization, there is no necessity for a central trusted agency to process the data [9]. Real-time capability is the ability of a system to operate in real-time interactions with other systems or units to satisfy the system's integrity. Service orientation refers to more customer-centered services with Internet of Things (IoT), Internet of Services (IoS), and Internet of People (IoP) technologies. Modularity stands for the ability to replace or expand parts and adapt the system to changes flexibly [1].

3. Evolution of Healthcare Technology and Health 4.0

Technological milestones can analyze the evolution of healthcare technologies. Health 1.0 focused on the high utilization of computers for administration procedures; Health 2.0 focused on organizational data sharing using cloud computing [10]. Later Health 3.0 shifted the focus on the patients, communication, and monitoring of patients using new technologies like smart sensors, wearable devices, and big data. Finally, Health 4.0 added real-time monitoring, prediction, and AI-supported diagnostics [10]. The main objectives of the Health 4.0 can be summarized as high-quality healthcare services, improved efficiency and effectiveness, and optimization of the costs and resources. Health 4.0 introduces integrated healthcare platforms for all healthcare stakeholders by providing virtual, distributed, and real-time services to move healthcare services from empirical to personalized healthcare services [3]. Patients, medical professionals, medical equipment, hospitals, clinics, pharmaceuticals, and medical suppliers are connected to a smart healthcare network through Health 4.0 [3]. By Health 4.0, a new paradigm shift from the hospital-based professional system to a distributed patient-centered healthcare in the world [11]. With increased connectivity, mobile digital technology platforms (m-health) connect patients and caregivers across the globe. People in remote areas can easily access high-quality health services [12, 13]. Health 4.0 offers flexible, scalable, reliable, agile, cost-effective, and high-quality healthcare services and operations [14]. It requires highly complex design and implementation to build and provide Health 4.0 based applications. Advanced service-oriented middleware (SOM) framework with cloud computing, edge/fog computing, IoT, IIoT (Industrial IoT), CPS, and big data can satisfy the needs for such complex systems [3].

Internet of Medical Things (IoMT) is a connected health system where medical devices, systems, software, and services are connected for cooperation [15]. The benefits of IoMT can be summarized as improved patient outcomes such as decreased costs, improved drug management, enhanced patient experience, improved diagnostics and treatment, remote monitoring of diseases, improved disease management [16]. Internet of

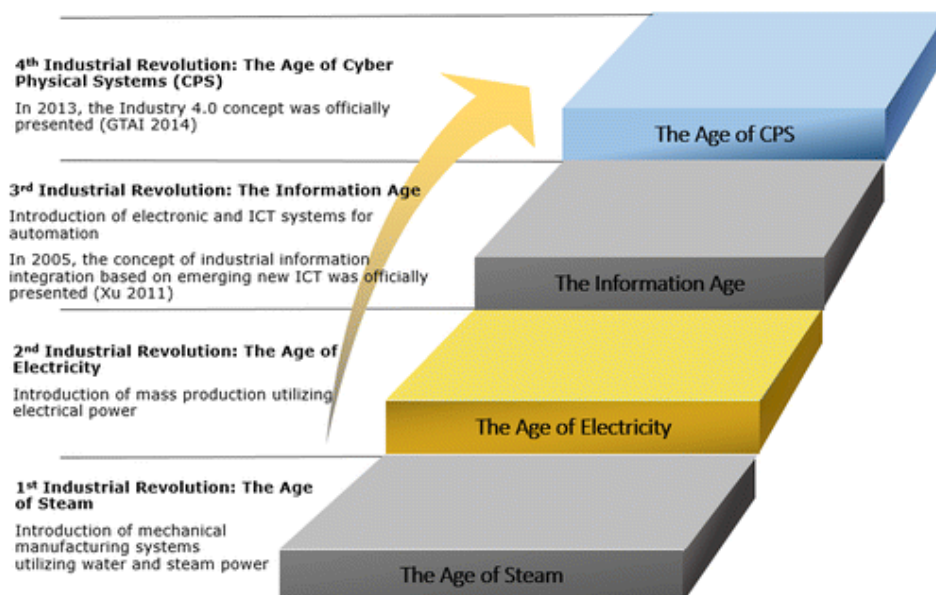


Figure 1. Industrial evolution stages. Adapted from [4]

Services is software-based medical devices, systems, and organizations provided via Internet interfaces [17]. Medical Cyber-Physical Systems, another Health 4.0 technology, are integrated systems of medical devices driven by embedded software and connected to networks that are distributed systems capable of monitoring and controlling patients' physiology [18]. With the digitization and particularly with the virtualization of healthcare, a higher quality of health services in the form of personalization for patients, professionals, and other stakeholders is available [19]. Another technology is health fog; in fog computing, three layers exist. They are the medical device, fog, and cloud layers [10]. Medical sensors are connected to the patient in the medical device layer, and data is collected by real-time monitoring via the Internet of medical things (IoMT) [10]. On top of the medical device is the fog layer, where sensor data is processed quickly and transmitted to the top cloud layer. The medical data is analyzed, stored, and provided to the clients, such as doctors and patients [10]. As another technology, Health Big Data Analytics enables better decision-making by learning from the enormous health data recorded over time using techniques such as machine learning. Healthcare big data is different from conventional databases. It has more complex and diverse formats, types, and contexts [19]. It is challenging to merge [19]. Moreover, Next Generation Mobile Communication Networks will allow new medical applications using the faster connection and smarter data management capabilities [3]. Finally, blockchain technology provides a decentralized and secure platform for critical health data management.

4. Blockchain Technology

Even though Stuart Haber and W. Scott Stornetta had started the research on digital ledgers in 1991, the first appearance of blockchain was in 2008. Blockchain has been invented with the idea of building a system that does not allow anybody to access or change document time-stamps. Developer(s) working under the pseudonym Satoshi Nakamoto conceptualized the first blockchain in 2008. Blockchain's design was based on Hashcash cryptographic algorithm [20]. Blockchain structure is illustrated in Figure 2. Each block represents a transaction. Every user has a digital signature, a private key, and a public key to sign transactions digitally in the signing phase [21]. In the verification phase, encrypted transactions and the original data are broadcasted to other users to verify the transactions using users' public keys [21]. Once the transaction has been validated at each user node, it is added to the blockchain, and money is transferred [22]. Blockchain technology offers advantages such as immutability, irreversibility, distributed system, decentralization, resiliency [22]. It is very hard to change or tamper with a transaction block with immutability. It is irreversible that money can not be double-spent. It is distributed that all the members have a copy of the ledger. It is decentralized that there is no central server mechanism to process. By resiliency, it is immune to safety attacks. Figure 2 represents the structure of blockchain. This structure consists of data, hash, time-stamp, and other information. The stored data in the blockchain is based on the service and application type. This data can be used in various applications like recording the transaction details, banking, contracting, and IoT. A hash function is responsible for taking an input of any length and generating the output with a unique fixed length. These functions are universally used in blockchain technology. They increase the integrity and trustfulness of data stored in blockchains. Timestamping is a method to record a document's creation and modification time, and it is crucial to saving these records every time a block is created. Other information in a blockchain system includes but is not limited to digital signatures, nonce values, and nBits [23].

In addition to financial applications, blockchain technology is crucial for healthcare. The use of blockchain technology in the medical field has been urged by the need for data share across departments of the same hospital, for an updated set of records for reference across multiple healthcare facilities, for the exigency of trusted and transparent documentation of individual health data [24].

5. Prominent Applications of Blockchain in Health

Blockchain technology has a great potential to improve business processes by virtue of its immutable, time-stamped, secured, and decentralized consensus feature [25]. Blockchain technology can be implemented in many industrial and technical areas. The inherent decentralized structure is one of the strongest points of blockchain technology. Each participant in a blockchain system can view the transaction records; however, they cannot change and delete them. For this reason, blockchain technology builds up transparent, immutable, and secure digital systems [26].

Blockchain technology consists of many interdisciplinary techniques: cryptography, algorithms, economic models, and mathematics. This technology merges or combines peer-to-peer networking and distributed consensus algorithms [23].

Some of the prominent applications of blockchain technology are illustrated in Figure 3. Blockchain technology has many potential application areas such as finance, healthcare, mobile technologies, defense systems, automobile, and the IoT. Among these application areas, blockchain has a wide range of applications and prominent uses in healthcare. Mettler (2016) states that blockchain technology can be implemented in healthcare, such as public health management, the pharmaceutical sector, medical research, and consumer-oriented healthcare [27].

Even though the research endeavors of blockchain technology in the healthcare industry have started in recent years, its applications will have widespread impacts in the healthcare industry in upcoming years. Some of these research areas in healthcare include, but are not limited to, management of electronic medical records, biomedical research, and education, remote patient monitoring, health data analytics [28]. Gordon & Catalini (2018) analyze the challenges encountered during the transition from institution-driven interoperability to patient-driven interoperability [29]. The authors investigate the applicability of blockchain technology on patient-driven interoperability.

Blockchain applications have started with the cryptocurrency Bitcoin and evolved to cover many other areas, including healthcare. Blockchain technology is expected to positively impact the healthcare industry [28]. One instance is IBM’s Healthchain application. It was developed on Blockchain infrastructure, enabling confidentiality, scalability, and security in health informatics [30]. Another application is offered by a Netherland-based data security firm, Guardtime. The blockchain-based application helps to validate patients’ identities. The patients’ records, such as patients’ private health information and appointment scheduling, are registered in the blockchain and kept secure and auditable. MedRec is another blockchain-based application that is the joint venture of MIT Media Lab and Beth Israel Deaconess Medical Center. This application allows patients to control the entities who can access their healthcare data [31]. Healthcoin is another example of a blockchain application in healthcare.

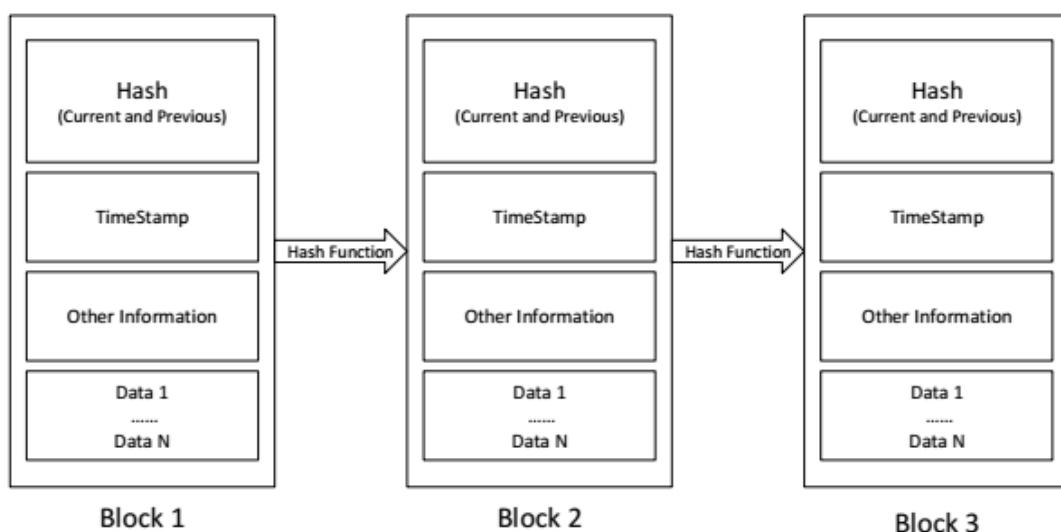


Figure 2. Structure of blockchain [23]

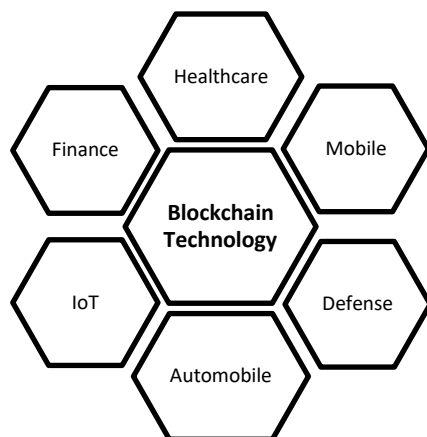


Figure 3. Application Areas of Blockchain Technology [23]

It has been started to help people with diabetes symptoms and later extended its aim to be a global electronic health record system. The application has a patient-centered information control mechanism based on three principles: giving the complete data to the users, allowing users to channel their data to its best use, and allowing users to broadcast outcomes with mechanisms to certify the broadcasted information [32]. Blockchain technology can be applied to many areas in healthcare, such as device tracking, clinical trials, pharmaceutical tracing, and health insurance. Blockchain technology has a great potential to create robust systems against counterfeit and unapproved drugs. Some of the issues within the modern healthcare industry are healthcare data interchange, nationwide interoperability, medical device tracking, and drug tracking [33]. Some of the benefits of blockchain technology in the healthcare industry are shown in Table 1. According to Engelhardt (2017), entrepreneurs focus on four main areas to deal with the challenges in health data management. These are; putting the patient at the center, privacy and access, completeness of information, and cost.

Table 1. The benefits of blockchain to healthcare applications (adapted from [28])

Decentralization	Blockchain technology can be the foundation for decentralized health data management systems from where the system's participants can access the same health records. There will be no central authority in this system that controls the health data.
Improved data security and privacy	The immutability property of blockchain guarantees the security of health data. Once the health data is inserted into a blockchain system, it cannot be deleted, corrupted, or altered. The data on a blockchain system is encrypted, time-stamped, and stored in chronological order.
Health data ownership	The cryptographic structure of blockchain and smart contracts offers solutions to protect patients' data and prevent them from being misused by unauthorized parties.
Availability/robustness	The records on a blockchain system are held on multiple nodes. This feature of blockchain creates a robust and resilient system against possible data losses, data corruption, and attacks.
Transparency and trust	The healthcare stakeholder will be more willing to trust the blockchain-based applications due to their open and transparent nature.
Data verifiability	The integrity and validity of the data records can be verified on blockchain nodes without the need for accessing plaintexts. Fast and easy verification of records yields productive processes in pharmaceutical supply chain management and insurance claim processing.

A comparison of an open-ended loop for a prescription process and a blockchain-based solution for the same process is given in Figure 4.

A doctor provides a prescription to a patient, and then the patient delivers the prescription to a pharmacist himself in an open-ended loop. In this process, the pharmacist has no knowledge about the prescription's originality, accuracy, or any modification made on it. Transactions can be stored access and permission to add data to the blockchain. When a doctor adds the prescription to the system, the pharmacist can check the original document in the closed-loop prescription process. After that, the pharmacist can record his actions on the prescription, and the doctor can see the prescription status [32]. The illustration of two different system design is given in Figure 4.

Blockchain technology can address prescription drug fraud such as modification of prescriptions, duplication of prescriptions, collection of many prescriptions from different doctors. One safety gap in an open-ended loop is the

lack of a sufficient feedback mechanism between prescription writers and prescription fillers. Blockchain offers fast and secure access to the time-stamped prescription documentation against prescription fraud [32].




Figure 4. Traditional open-ended loop for a prescription process (a) vs. blockchain-based solution to a prescription process (b) [32].

Convenient medical care increases its popularity in today’s medical system. The connectivity feature of smart devices can bring patients and doctors without the need for physical meetings and save time and energy. Many healthcare companies offer 24/7 access to healthcare services, and mobile applications continuously monitor patients’ health status and send a report to the health service providers.

Zhang et al. (2018) depict a high-level conceptual infrastructure (see figure 5) where a Blockchain (represented as the dashed ellipse) is connected to disparate health database systems (represented as cylinder database objects) [34]. The keyed file symbol represents a smart contract, and it is used to regulate the data transaction among these systems. These execution operations are based on smart contracts’ mutual agreements, and all transaction records are kept properly. Figure 5 is a simple explanation of the blockchain-based health database systems; however, more components exist in the structure in practice.




Figure 5. Blockchain-based conceptual infrastructure to connect different health database systems [34].

6. Conclusion

Following the Fourth Industrial Revolution, many technological advancements are available for manufacturing and service-based industries. As digital transformation takes place in everyday life, the healthcare industry is being revolutionized by these emerging technologies. These reforms in the healthcare field can be manifested as Health 4.0, which allows higher quality, efficient and effective healthcare products and services, optimizing the costs and resources. In order to achieve these goals, Health 4.0 utilizes such technologies as the Internet of Medical Things, Internet of Services, Medical Cyber-Physical Systems, Digitization and Virtualization, Fog Computing, Cloud and Health Big Data, Next Generation Mobile Communication Networks and Blockchain. The main contribution of this paper is to investigate the potential use of blockchain technology in healthcare. First, we review the evolution of healthcare technologies and how these development stages changed the way patients get treatments. Second, we explore blockchain technology and its potential benefits in many sectors. Finally, we discuss the integration of blockchain technology with the healthcare system and provide some insights regarding the potential gains.

Blockchain technology is one of the emerging technologies, and it offers great potential in improving the healthcare processes where healthcare data is processed fast, secure, and transparent. Blockchain technology eliminates the need for a third party between system participants and develops the healthcare process to minimize time and

effort. Having a direct interaction between healthcare system participants builds trust, minimizes disinformation, and accelerates the process. The healthcare data is recorded in blocks where participants can access the data at any time, anywhere. Each patient's data is stored, viewed, and analyzed without the risk of loss or intervention under his digital ID. Hence, blockchain technology reduces inefficiencies across patient or provider record keeping. Blockchain already has a wide range of applications and uses in the healthcare industry, even though it is new. In the future, blockchain technology will continue to improve security, reliability, privacy, and operational efficiency in the healthcare industry by offering robust and effective digital solutions.

References

- [1] Thuemmler, C., & Bai, C. (Eds.). (2017). Health 4.0: How virtualization and big data are revolutionizing healthcare, 2168-2194. Cham Switzerland: Springer International Publishing.
- [2] Drath, R., & Horch, A. (2014). Industrie 4.0: Hit or hype?[industry forum]. *IEEE industrial electronics magazine*, 8,2, 56-58.
- [3] Al-Jaroodi, J., Mohamed, N., & Abukhousa, E. (2020). Health 4.0: on the way to realizing the healthcare of the future. *IEEE Access*, 8, 211189-211210.
- [4] Xu, L. D., Xu, E. L., & Li, L. (2018). Industry 4.0: state of the art and future trends. *International Journal of Production Research*, 56,8, 2941-2962.
- [5] GTAI (Germany Trade & Invest) (2014) . Industries 4.0-Smart Manufacturing for the Future. Berlin: GTAI.
- [6] Gürdür, D., El-Khoury, J., Seceleanu, T., & Lednicki, L. (2016). Making interoperability visible: Data visualization of cyber-physical systems development tool chains. *Journal of Industrial Information Integration*, 4, 26-34.
- [7] Hermann, M., Pentek, T., Otto, B., Pentek, T., & Otto, B. (2015). Design principles for industry 4.0 scenarios: A literature review. Technische Universität Dortmund.
- [8] Thuemmler, C., & Bai, C. (2017). Health 4.0: Application of industry 4.0 design principles in future asthma management. In Health 4.0: How virtualization and big data are revolutionizing healthcare (pp. 23-37). Springer, Cham.
- [9] Zheng, Z., Xie, S., Dai, H., Chen, X., & Wang, H. (2017, June). An overview of blockchain technology: Architecture, consensus, and future trends. In *2017 IEEE international congress on big data (BigData congress)* (pp. 557-564). IEEE.
- [10] Karboub, K., Tabaa, M., Dandache, A., Dellagi, S., & Moutaouakkil, F. (2019). Toward Health 4.0: Challenges and opportunities. In *International Conference on Innovation and New Trends in Information Technology*, 20-21.
- [11] Kagermann, H., Wahlster, W., & Helbig, J. (2013). Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group. Forschungsunion: Berlin, Germany.
- [12] Bause, M., Esfahani, B. K., Forbes, H., & Schaefer, D. (2019, July). Design for health 4.0: exploration of a new area. In *Proceedings of the Design Society: International Conference on Engineering Design*, 1, 1, 887-896, Cambridge University Press.
- [13] International Telecommunication Union (2018), "M-health for NCD". [online] Available at: <https://www.itu.int/en/ITU-D/ICT-Applications/Pages/mhealth-for-ncd-behealthy-bemobile.aspx> [Accessed 14. November 2018]
- [14] Mohamed, N., & Al-Jaroodi, J. (2019, April). The impact of Industry 4.0 on healthcare system engineering. In *2019 IEEE International Systems Conference (SysCon)*, 1-7, IEEE.
- [15] Andrew Steger (2020) How the Internet of Medical Things is Impacting Healthcare <https://healthtechmagazine.net/article/2020/01/how-internet-medical-things-impacting-healthcare-perfcon>
- [16] Deloitte Retrieved 13 June 2021, from <https://www2.deloitte.com/global/en/pages/life-sciences-and-healthcare/articles/medtech-internet-of-medical-things.html>

- [17] Cardoso, J., Voigt, K., & Winkler, M. (2008, June). Service engineering for the Internet of services. *In International Conference on Enterprise Information Systems*, 15-27, Springer, Berlin, Heidelberg.
- [18] Lee, I., Sokolsky, O., Chen, S., Hatcliff, J., Jee, E., Kim, B., ... & Venkatasubramanian, K. K. (2011). Challenges and research directions in medical cyber-physical systems. *Proceedings of the IEEE*, 100,1, 75-90.
- [19] Khayamian Esfahani, B., Bause, M., & Schaefer, D. (2019, July). Health 4.0: How Digitisation Drives Innovation in the Healthcare Sector. *In The 2019 International Conference on Systematic Innovation*, 75-81, The Society of Systematic Innovation.
- [20] Soni, N. (2020). Evolution of blockchain. medium. retrieved 8 June 2021, from <https://medium.com/@nehasoni1812/evolution-of-blockchain-f243f7509fe6>.
- [21] Zheng, Z., Xie, S., Dai, H., Chen, X., & Wang, H. (2017, June). An overview of blockchain technology: Architecture, consensus, and future trends. *In 2017 IEEE international congress on big data (BigData congress)*, 557-564, IEEE.
- [22] Chatterjee, R., & Chatterjee, R. (2017, October). An overview of the emerging technology: Blockchain. *In 2017 3rd International Conference on Computational Intelligence and Networks (CINE)*, 126-127, IEEE.
- [23] Joshi, A. P., Han, M., & Wang, Y. (2018). A survey on security and privacy issues of blockchain technology. *Mathematical Foundations of Computing*, 1,2, 121.
- [24] Mukherjee, P., & Singh, D. (2020). The opportunities of blockchain in health 4.0. *In Blockchain Technology for Industry 4.0*, 149-164, Springer, Singapore.
- [25] Chang, S. E., Chen, Y. C., & Wu, T. C. (2019). Exploring blockchain technology in international trade: Business process re-engineering for letter of credit. *Industrial Management & Data Systems*.
- [26] Golosova, J., & Romanovs, A. (2018, November). The advantages and disadvantages of the blockchain technology. *In 2018 IEEE 6th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE)*, 1-6, IEEE.
- [27] Mettler, M. (2016, September). Blockchain technology in healthcare: The revolution starts here. *In 2016 IEEE 18th international conference on e-health networking, applications and services (Healthcom)*, 1-3, IEEE.
- [28] Agbo, C. C., Mahmoud, Q. H., & Eklund, J. M. (2019, June). Blockchain technology in healthcare: a systematic review. *In Healthcare*, 7, 2,56. Multidisciplinary Digital Publishing Institute.
- [29] Gordon, W. J., & Catalini, C. (2018). Blockchain technology for healthcare: facilitating the transition to patient-driven interoperability. *Computational and Structural Biotechnology Journal*, 16, 224-230.
- [30] Ahram, T., Sargolzaei, A., Sargolzaei, S., Daniels, J., & Amaba, B. (2017, June). Blockchain technology innovations. *In 2017 IEEE Technology & Engineering Management Conference (TEMSCON)*, 137-141, IEEE.
- [31] Angraal, S., Krumholz, H. M., & Schulz, W. L. (2017). Blockchain technology: applications in health care. *Circulation: Cardiovascular quality and outcomes*, 10,9, e003800.
- [32] Engelhardt, M. A. (2017). Hitching healthcare to the chain: An introduction to blockchain technology in the healthcare sector. *Technology Innovation Management Review*, 7,10.
- [33] Bell, L., Buchanan, W. J., Cameron, J., & Lo, O. (2018). Applications of blockchain within healthcare. *Blockchain in healthcare today*.
- [34] Zhang, P., Schmidt, D. C., White, J., & Lenz, G. (2018). Blockchain technology use cases in healthcare. *In Advances in Computers*, 111, 1-41.

