



JOURNAL OF INFORMATION TECHNOLOGIES

BİLİŞİM TEKNOLOJİLERİ DERGİSİ

Volume / Cilt **16** Number / Sayı **1** Year / Yıl **2023** Month / Ay **January / Ocak**





GAZİ ÜNİVERSİTESİ (GAZİ UNIVERSITY)
BİLİŞİM ENSTİTÜSÜ (INSTITUTE OF INFORMATICS)

BİLİŞİM TEKNOLOJİLERİ DERGİSİ
(JOURNAL OF INFORMATION TECHNOLOGIES)

ISSN: 1307-9697 e-ISSN: 2147-0715



Cilt (Volume): 16

Sayı (Issue): 1

Ocak (January) 2023

Sahibi (Owner)
Dr. Musa YILDIZ
Rektör (Rector)

Genel Yayın Yönetmeni & Baş Editör
(General Publication Director & Editor in Chief)
Dr. Aslıhan TÜFEKÇİ
Bilişim Enstitüsü Müdürü
Director of Institute of Informatics

Yardımcı Editör
(Associate Editor)
Dr. Öner BARUT
Bilişim Enstitüsü Müdür Yardımcısı
Vice Director of Institute of Informatics

Yardımcı Editör
(Associate Editor)
Dr. Murat YILMAZ
Bilişim Enstitüsü Müdür Yardımcısı
Vice Director of Institute of Informatics

Editörler (Editors)

❖ Dr. Ahmet KARAARSLAN	Ankara Yıldırım Beyazıt Üniversitesi (Ankara Yıldırım Beyazıt University)
❖ Dr. Hüseyin POLAT	Gazi Üniversitesi (Gazi University)
❖ Dr. İbrahim KÖK	Pamukkale Üniversitesi (Pamukkale University)
❖ Dr. Mahir DURSUN	Gazi Üniversitesi (Gazi University)
❖ Dr. Mehmet ŞİMŞEK	Milli Savunma Üniversitesi (National Defence University)
❖ Dr. M. Hanefi CALP	Ankara Hacı Bayram Veli Üniversitesi (Ankara Hacı Bayram Veli University)
❖ Dr. Mohammad Abdus SALAM	Southern University and A&M Collage
❖ Dr. Oktay YILDIZ	Gazi Üniversitesi (Gazi University)
❖ Dr. Olgun DEĞİRMENÇİ	TOBB ETÜ (TOBB Economics and Technology University)
❖ Dr. Recep BENZER	Gazi Üniversitesi (Gazi University)
❖ Dr. Serdar KULA	Gazi Üniversitesi (Gazi University)

Yayın Danışma Kurulu (Editorial Advisory Board)

Dr. Ahmet COŞAR Turkish Aeronautical Association University, Turkey	Dr. Aslanbek NAZİEV Ryazan State University, Russia	Dr. Bogdan PATRUT Alexandru Ioan Cuza University of Iasi, Romania
Dr. Deepak GUPTA Maharaja Agrasen Institute of Technology, India	Dr. Jafar A. ALZUBİ Al-Balqa Applied University, Jordan	Dr. Jolanta SABAITYTĖ Vilnius Gediminas Technical University, Lithuania
Dr. İlya LEVİN Tel Aviv University, Israel	Dr. Pınar KARAGÖZ Middle East Technical University, Turkey	Dr. Ufuk ÇAĞLAYAN Yaşar University, Turkey

Dr. Veysi İŞLER <i>Hasan Kalyoncu University, Turkey</i>	Dr. Victor Hugo Costa DE ALBUQUERQUE <i>Universidade de Fortaleza, Brazil</i>	Dr. Vijender Kumar SOLANKİ <i>CMR Institute of Technology, India</i>
Dr. Ebrahim KHOSRAVI <i>Clayton State University, United States</i>		

Dil Editörü <i>(Language Editor)</i> Dr. Çağla Gizem AKKAŞ <i>Bilişim Enstitüsü</i> <i>Institute of Informatics</i>

Teknik Koordinatör <i>(Technical Coordinator)</i> Dr. Muhammed Ali KOŞAN <i>Bilişim Enstitüsü</i> <i>Institute of Informatics</i>

Teknik Sorumlu <i>(Technical Assistant)</i> Merve ÇELEBİ <i>Bilişim Enstitüsü</i> <i>Institute of Informatics</i>

Teknik Sorumlu <i>(Technical Assistant)</i> Tuana İRKEY <i>Bilişim Enstitüsü</i> <i>Institute of Informatics</i>
--

Sekreterlik <i>(Secretary)</i> Bilişim Teknolojileri Dergisi <i>Bilişim Enstitüsü</i> <i>Institute of Informatics</i>

Bilişim Teknolojileri Dergisi uluslararası hakemli bir dergidir. Journal of Information Technologies is an international refereed journal.
Yazışma Adresi (Contact Address) Tunus Cad. No: 35 Kavaklıdere Çankaya/ANKARA Telefon / Telephone: 0312 202 38 01 Faks / Fax: 0312 212 79 29
Çevrimiçi Değerlendirme Sistemi (Online Evaluation System) http://dergipark.gov.tr/gazibtd E-posta (e-mail): btd@gazi.edu.tr
Bilişim Teknolojileri Dergisi 3 ayda bir (Ocak, Nisan, Temmuz, Ekim) yayınlanmaktadır. Journal of Information Technologies is published every 3 months (January, April, July, October).

Coronavirüs Sürü Bağışıklığı Algoritması ile Otsu Tabanlı Optimal Çok Düzeyli Görüntü Eşiği

Araştırma Makalesi/Research Article

 İsmail KOÇ

Yazılım Mühendisliği Bölümü, Konya Teknik Üniversitesi, Konya, Türkiye

ismailkoc@ktun.edu.tr

(Geliş/Received:09.09.2022; Kabul/Accepted:07.11.2022)

DOI: 10.17671/gazibtd.1172909

Özet— Eşik seçimi, görüntü bölütlemede önemli bir rol oynamaktadır. Eşik seçimiyle ilgili en faydalı yöntemler olarak minimum hata yöntemi, iteratif yöntem, entropi yöntemi ve Otsu yöntemi bilinmektedir. Bu çalışmada eşikleme yöntemi olarak Otsu tekniği kullanılmaktadır. Eşik sayısının (K) artmasına bağlı olarak problemin karmaşıklık düzeyi üstel olarak artacağı için matematiksel yöntemler yerine sürü zekâsı algoritması kullanılması daha uygun görülmektedir. Bundan dolayı, bu çalışmada sürü zekâsı algoritması olarak da son yıllarda literatüre kazandırılmış olan Coronavirüs sürü bağışıklığı algoritması (CHIO) kullanılmaktadır. Deneysel çalışmalarda test verisi olarak altı farklı görüntü kullanılmaktadır. K değeri bu çalışmada 2, 3, 4 ve 5 olarak belirlenmektedir. Bu veri seti kullanılarak CHIO algoritması ile literatürde yer alan diferansiyel evrim (differential evolution: DE), gri kurt (gray wolf optimizer: GWO), parçacık sürü (particle swarm optimization: PSO) algoritmaları gibi başarılı algoritmalarla eşit koşullarda kıyaslanmaktadır. Elde edilen sonuçlara göre, CHIO algoritması kullanılarak 6 test verisi üzerinde yapılan çalışmalarda K=2 olduğunda verilerin %100, K=3 ve 4 iken %83 ve son olarak K=5 iken %50'sinde en iyi sonuçları yakaladığı görülmektedir. Bu sonuçlar ışığında, CHIO algoritmasının çözüm kalitesi açısından rekabet edici olduğu tespit edilmiştir. Sonuç olarak CHIO algoritması çok düzeyli görüntü eşiği problemi için alternatif bir algoritma olabilir.

Anahtar Kelimeler— coronavirüs sürü bağışıklığı algoritması, yapay zeka, optimizasyon, görüntü eşik seçimi

Otsu Based Optimal Multilevel Image Thresholding Using Coronavirus Herd Immunity Optimizer

Abstract— Thresholding selection plays an important role in image segmentation. Minimum error method, iterative method, entropy method and Otsu method are known as the most useful methods for thresholding selection. In this study, Otsu technique is used as thresholding method. Since the complexity of the problem would increase exponentially depending on the increase in the number of thresholds (K), it seems more appropriate to use a swarm intelligence algorithm instead of mathematical methods. Therefore, in this study, the Coronavirus herd immunity optimizer (CHIO), which has been introduced to the literature in recent years, is used as a swarm intelligence algorithm. In the experimental studies, six different images are used as test data in experimental studies. K value is determined as 2, 3, 4 and 5 in this study. Using this data set, the CHIO algorithm is compared with the successful algorithms in the literature such as differential evolution (DE), gray wolf (GWO), and particle swarm (PSO) algorithms in the equal conditions. According to the results obtained, it is seen that in studies conducted on 6 test data using the CHIO algorithm, the proposed algorithm achieves the best results in 100% of the images when K=2, 83% when K=3 and 4, and finally 50% when K=5. In the light of these results, it has been determined that the CHIO algorithm is competitive in terms of solution quality. As a result, the CHIO algorithm can be an alternative algorithm for the multilevel image thresholding problem.

Keywords— coronavirus herd immunity optimizer, artificial intelligence, metaheuristic, image threshold selection

1. GİRİŞ (INTRODUCTION)

Eşikleme, görüntü segmentasyonu için en önemli ve etkili araçlardan biridir. Eşikleme, video sıkıştırma, [1, 2], görüntü gürültü giderme [3], belge işleme [4] ve hedef tanıma [5] yaygın olarak kullanılan görüntü bölütlemenin ana yöntemi ve önemli bir dalıdır. Eşikleme işlemi bir eşik (th) değeri olarak çalıştığı için, yoğunluk değeri 'th' değerinden yüksek olan pikseller birinci sınıf olarak etiketlenirken geri kalanlar ikinci sınıf olarak etiketlenir [6]. Görüntü arka plan ve hedef nesne olmak üzere iki sınıfa ayrıldığında, görev iki seviyeli eşikleme (BT) olarak adlandırılır ve yalnızca bir 'th' değeri gerektirir. İki seviyeli eşiklemenin uzantısı çok seviyeli eşikleme (MT) olarak adlandırılır [7]. MT'de pikseller ikiden fazla sınıfa ayrılır ve bu da birden fazla 'th' değeri gerektirir [8]. Çok seviyeli eşikleme, gri seviyeli bir görüntüyü birden fazla eşik tespit ederek birkaç farklı bölgeye ayırır [9].

Eşik sayısı arttıkça, eşikleme problemindeki hesaplama karmaşıklığı da önemli ölçüde artmaktadır. Bu nedenle, hesaplama verimliliğini artırmak için bu probleme literatürde çok sayıda sürü zekası optimizasyon algoritması uygulanmaktadır [10, 11]. Akay (2012)'in çalışmasında parçacık sürü (PSO) ve yapay arı koloni (ABC) algoritmalarını kullanılmıştır. 12 farklı görüntü üzerinde yaptığı çalışmalarda ise eşikleme yöntemi olarak Otsu ve Kapur yöntemleri tercih edilmiştir. Oliva vd. çalışmalarında Harmoni arama algoritmasını 10 farklı MRI görüntü üzerinde kullanmışlardır. Algoritmayı ise BF, PSO ve genetik algoritma ile kıyaslamışlardır [8]. Raja vd. Brownian Dağılım rehberli Ateşböceği Algoritması kullanarak Otsu metodu yöntemiyle eşikleme işlemini gerçekleştirmişlerdir. Çalışmalarını 12 adet gri seviye görüntü kullanarak orijinal ateş böceği algoritması ile kıyaslamışlardır [12]. Aziz vd. balina ve güve alive optimizasyon algoritmalarıyla eşikleme problemine çözüm aramışlardır. 8 farklı görüntü üzerinde Otsu yöntemi kullanarak elde ettikleri çözümleri RMSE, PSNR, SSIM gibi kriterlere göre değerlendirmişlerdir [13]. Kotte vd. 10 farklı MRI görüntüsü kullanarak Kapur ve Otsu yöntemleriyle eşikleme işlemini gerçekleştirmişlerdir. Adaptif rüzgar sürücü algoritması (AWDO) ile yaptıkları çalışmada sonuçları PSO ve orijinal WDO algoritması gibi algoritmalarla kıyaslamışlardır [14]. Kahraman vd. renkli görüntülerin çok seviyeli eşiklenmesi ve sınıflandırılması üzerine çalışmışlardır [15]. Koc vd. gri kurt optimizasyon algoritması kullanarak Otsu yöntemiyle eşikleme problemine yeni çözümler üretmiştir. Eşikleme işlemini 6 görüntü üzerinde Otsu yöntemi kullanarak gerçekleştirmişlerdir [16]. Diz evrimsel çok amaçlı algoritma ile yaptıkları çalışmada 6 gri seviye görüntü kullanarak eşikleme işlemini gerçekleştirmişlerdir. Eşikleme tekniği olarak ise Kapur, Otsu ve bulanık C-means gibi yöntemler kullanılmıştır [17]. Çelik ve Demirel zatürre tespiti için Otsu ve Ridler-Calvard görüntü işleme yöntemini önermişlerdir [18]. Karasulu görüntülerde insan kulağı tespit ve bölütlemesini temel alan biyometrik yetkilendirme üzerine bir inceleme yapmıştır. Yapılan çalışmada eşikleme yöntemi kullanılmıştır [19].

Bu çalışmada son yıllarda geliştirilmiş olan Coronavirus sürü bağışıklığı algoritması (CHIO) kullanarak çok düzeyli görüntü eşik seçimi gerçekleştirilmiştir. Yapılan çalışmada 6 farklı görüntü kullanılmış ve eşik seçimi için amaç fonksiyonu olarak Otsu tekniği tercih edilmiştir. Elde edilen sonuçlar GWO, DE gibi güçlü algoritmalar başta olmak üzere toplam altı farklı algoritma ile kıyaslanmıştır. Karşılaştırmalı sonuçlara göre CHIO algoritmasının diğer algoritmalara göre rekabet edici olduğu çok açık bir şekilde söylenebilir.

Bu çalışmanın genel organizasyonu şu şekildedir: Bölüm 2'de Otsu eşikleme metodu ve CHIO algoritmasına ait detaylar sunulmaktadır. Bölüm 3'te ise deneysel çalışmalar karşılaştırmalı verilmektedir. Son olarak Bölüm 4'te ise çalışmaya ilişkin tartışma kısmı yer almaktadır.

2. MATERYAL VE METOD (MATERIAL AND METHOD)

2.1. Çoklu Eşikleme Problemi (Multilevel Thresholding Problem)

Çok seviyeli eşikleme, literatürde çok sıklıkla tercih edilen görüntü segmentasyon yöntemlerinden birisidir [20]. Çok seviyeli eşikleme problemi, bir uygunluk kriterini $I(x,y)$ maksimuma çıkaran $[0, L-1]$ gri ölçek aralığındaki optimal eşikleri bulmakla ilgilenmektedir. Eşik değerlerini bulmak için Otsu'nun sınıflar arası varyans fonksiyonu kullanılır. Optimizasyon probleminin arama boyutu, dikkate alınan eşik sayısına göre atanır [12].

2.2. Otsu Eşikleme Metodu (Otsu Thresholding Method)

Literatürde var olan klasik ve optimizasyon algoritması tabanlı eşikleme yöntemleri, bazı yol gösterici parametreleri karşılayarak parçalı histogramda mümkün olan en iyi eşiği bulmak için kullanılmaktadır. Otsu tabanlı görüntü eşikleme ilk olarak 1979'da önerilmiştir. Bu yöntem, amaç fonksiyonunu maksimize ederek optimal değerleri sunmaktadır. Bu çalışmada Otsu'nun sınıflar arası varyans olarak bilinen parametrik olmayan bölütleme yöntemi ele alınmaktadır [12, 21]. Gri seviye eşikleme yöntemine için amaç fonksiyonuna ait matematiksel modeller aşağıda verilmektedir:

$$t^* = \operatorname{argmax}[f_b(t)] \quad (1)$$

$$f_b(t) = \sigma_0 + \sigma_1 \quad (2)$$

$$\sigma_0 = \omega_0(\mu_0 - \mu_t)^2 \text{ and } \sigma_1 = \omega_1(\mu_1 - \mu_t)^2 \quad (3)$$

$$\mu_0 = \frac{1}{\omega_0} \sum_{i=0}^{t-1} i x p_i \text{ and } \mu_1 = \frac{1}{\omega_1} \sum_{i=t}^{L-1} i x p_i \quad (4)$$

$$\omega_0 = \sum_{i=0}^{t-1} p_i \text{ and } \omega_1 = \sum_{i=t}^{L-1} p_i \quad (5)$$

$$p_i = \frac{x_i}{X} \quad (6)$$

buradaki x_i , I düzeyindeki piksel sayısını, X ise her düzeydeki toplam piksel sayısını ifade etmektedir. p_i

Denklem (6)'daki i . gri seviyenin olasılık değeridir. ω_0 ve ω_1 , Denklem (5)'deki 0. ve 1. segment oluşumunun tahmin edilen olasılığıdır. Denklem (4)'teki μ_0 ve μ_1 , 0. sınıf ve 1. sınıf ortalama yoğunluğudur. μ_t , Denklem(3)'deki orijinal görüntünün ortalama değerine karşılıktır. Denklem (2)'de σ_0 , 0. sınıfın varyansındır ve σ_1 , 1. sınıfın varyansındır.

Sınıflar arası varyansın temel denklemler ışığında, sınıflar arası varyansa dayalı görüntü eşikleme, aşağıdaki gibi verilen çok düzeyli eşikleme genişletilmektedir. Optimum eşik değeri t^* ise Denklem (7)'deki gibi hesaplanmaktadır.

$$t^* = \operatorname{argmax}[f_m(t)] \quad (7)$$

$$f_b(t) = \sum_{i=0}^n \sigma_i \quad (8)$$

$$\sigma_0 = \omega_0(\mu_0 - \mu_t)^2, \sigma_1 = \omega_1(\mu_1 - \mu_t)^2, \dots, \sigma_n = \omega_n(\mu_n - \mu_t)^2 \quad (9)$$

$$\mu_0 = \frac{1}{\omega_0} \sum_{i=0}^{t_0-1} i x p_i, \mu_1 = \frac{1}{\omega_1} \sum_{i=t_0}^{t_1-1} i x p_i, \dots, \mu_n = \frac{1}{\omega_n} \sum_{i=t_n}^{L-1} i x p_i \quad (10)$$

$$\omega_0 = \sum_{i=0}^{t_0-1} p_i, \omega_1 = \sum_{i=t_0}^{t_1-1} p_i, \dots, \omega_n = \sum_{i=t_n}^{L-1} p_i \quad (11)$$

2.3. Coronavirüs Sürü Bağışıklığı Algoritması (Coronavirus Herd Immunity Optimizer)

Coronavirüs sürü bağışıklığı algoritması (CHIO), 2020 yılında Al-Betar vd. tarafından önerilen yeni bir metasezgisel algoritmadır [22]. Diğer birçok sürü zekası algoritmasına benzer şekilde, doğal bir varlığın davranışını taklit eder, bu durumda ilhamını patojenik bir koronavirüsten almaktadır. CHIO, bulaşıcı hastalıklardan bağışıklık elde etme yöntemlerinden biri olarak bilinen sürü psikolojisinin uygulanması yoluyla bir sürüde doğal bağışıklık elde etme sürecini taklit etmektedir.

Koronavirüs sürü bağışıklığı fikri, CHIO adlı teorik bir optimizasyon algoritması oluşturmak için Al-Betar tarafından matematiksel olarak modellenmiştir. Model, enfekte olmayan çaresiz nüfusun büyük kısmını sağlam bir nüfusa dönüştürerek insanlığı hastalığa karşı en iyi şekilde korumanın bir yolunu bulmaya dayanmaktadır [22]. Sonuç olarak, geriye kalan tüm hassas vakalar etkilenmeyecek ve dirençli popülasyon artık hastalığı bulaştırmayacaktır. Modelde, sürü bağışıklığı olan bireylerden oluşan popülasyon üç kategoride sınıflandırılmaktadır: duyarlı, kontamine (veya doğrulanmış) ve bağışıklık kazanmış (veya yeniden kazanmış) kişiler [22, 23]. Algoritmaya ait temel denklemler Denklem (12)-(14)'te verilmiştir.

$$C(X_i^j(t)) = X_i^j(t) + r x (X_i^j(t) - X_i^c(t)) \quad (12)$$

$$N(X_i^j(t)) = X_i^j(t) + r x (X_i^j(t) - X_i^m(t)) \quad (13)$$

$$R(X_i^j(t)) = X_i^j(t) + r x (X_i^j(t) - X_i^m(t)) \quad (14)$$

Algoritma aşağıdaki adımlardan oluşmaktadır:

Adım 1: Algoritmanın başlangıç parametrelerini ayarla.
Parametreleri başlat. (N , HIS , S_r , $MaxIterasyon$, $MaxYas$)

Adım 2: CHIO popülasyonunu üret.

Her bir elamanın maliyetini uygunluk fonksiyonuna göre hesapla.

Adım 3: Populasyon konum güncelle

while $t \leq MaxIterasyon$

for $j=1$ to HIS **do**

Corona($X^j(t)$)=false

for $i=1$ to N

if $r < \frac{1}{3} x BR_r$

$X_i^j(t+1) = C(X_i^j(t))$ [Bakınız: Denklem (12)]

else if $r < \frac{2}{3} x BR_r$

$X_i^j(t+1) = N(X_i^j(t))$ [Bakınız: Denklem (13)]

else if $r < BR_r$

$X_i^j(t+1) = R(X_i^j(t))$ [Bakınız: Denklem (14)]

else

$X_i^j(t+1) = X_i^j(t)$

end if

end for

Adım 4: Populasyondaki elemanları güncelle

if $f(X^j(t+1)) \geq f(X^j(t))$: maksimizasyon işlemi

$X^j(t+1) = X^j(t)$

else

$A_j = A_j + 1$

end if

if $f(X^j(t+1)) < \frac{f(X^j(t+1))}{\Delta f(x)} \wedge S_j = 0 \wedge Corona(X^j(t+1))$

$S_j = 1$

$A_j = 1$

end if

if $f(X^j(t+1)) > \frac{f(X^j(t+1))}{\Delta f(x)} \wedge S_j = 1$

$S_j = 2$

$A_j = 0$

end if

Adım 5: Ölümcül Durumlar

if $A_j \geq MaxYas \wedge (S_j == 1)$

Yeni birey üret.

$S_j = 0$

$A_j = 0$

end if

end for

$t = t+1$


end while

Algoritma ilk olarak probleme uygun olarak parametrelerinin ayarlanması ile başlamaktadır. Adım 2'de popülasyon verilen parametrelere göre üretilir ve problemin amaç fonksiyonu yardımıyla her bir çözümün maliyeti hesaplanır. Adım 3'te verilen iterasyon sayısına göre her bir bireyin önerilen algoritmanın denklemleri yardımıyla mevcut pozisyonları güncellenir. Adım 4'te ise Adım 3'te üretilen yeni pozisyonlara ait çözümler amaç


fonksiyonuna gönderilir ve çözümler daha iyiye yeni çözüm mevcut çözüm ile yer değiştirir (güncellenir). Adım 5'te ise söz konusu çözümde bir iyileşme görülmezse mevcut çözüm yerine arama uzayında yeniden çözüm üretilir. Bu işlem ile global arama güçlendirilir. Tüm bu işlemler maksimum iterasyon boyunca devam ettirilir. Sonuç olarak, elde edilen en iyi sonuç raporlanır.

3. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)


Bu çalışmada çok seviyeli eşikleme yöntemi olarak Otsu tekniği tercih edilmiştir. Eşikleme yöntemlerinde test etmek amacıyla farklı özelliklere sahip 6 görüntü kullanılmıştır [16]. Optimal eşik seviyesi belirlemek amacıyla da literatürde son yıllarda önerilmiş olan Coronavirüs sürü bağışıklık algoritması (CHIO) kullanılmıştır. Görüntülere ait özellikler Şekil 1'de verilmiştir. Ayrıca Otsu yöntemiyle elde edilen sonuçlar da eşik sayısına göre Tablo 1'de sırasıyla verilmiştir. Tüm deneysel çalışmalar Intel Core i7 2.80 GHz CPU, 16 GB RAM ve Windows 10 64-bit işletim sistemi üzerinde Matlab R2021a kullanılarak gerçekleştirilmiştir.




(a) Barbara




(b) Oturma odası (Living room)




(c) Tekneler (Boats)



(d) Goldhill



(e) Göl (Lake)



(f) Anten (Aerial)

Şekil 1. Test verileri
(Test data)

Tablo 1. Otsu yöntemine göre elde edilen test veri sonuçları
(Test data results obtained according to the Otsu method)

Resimler	K	Eşik Değerleri	En iyi değer
Barbara	2	82, 147	2608.611
	3	75, 127, 176	2785.163
	4	66, 106, 142, 182	2856.262
	5	57, 88, 118, 148, 184	2890.977
Oturma odası	2	87, 145	1627.909
	3	76, 123, 163	1760.103
	4	56, 97, 132, 168	1828.864
	5	49, 88, 120, 146, 178	1871.991
Tekneler	2	93, 155	1863.347
	3	73, 126, 167	1994.536
	4	65, 114, 147, 179	2059.866
	5	51, 90, 126, 152, 183	2092.776
Goldhill	2	94, 161	2069.510
	3	83, 126, 179	2220.373
	4	69, 102, 138, 186	2295.380
	5	63, 91, 117, 147, 191	2331.157
Göl	2	85, 154	3974.738
	3	78, 140, 194	4112.631
	4	67, 110, 158, 198	4180.886
	5	57, 88, 127, 166, 200	4216.944
Anten	2	125, 178	1808.171
	3	109, 147, 190	1905.411
	4	104, 134, 167, 202	1957.0180
	5	99, 123, 148, 175, 205	1980.657

Deneysel sonuçların adil bir şekilde karşılaştırılabilmesi için her bir eşik değeri için 25 bağımsız çalışma gerçekleştirilmiştir. Popülasyon sayısı olarak 40 belirlenirken, iterasyon sayısı olarak ise 2000 belirlenmiştir. Elde edilen sonuçlar literatürde yaygın olarak kullanılan PSO, Diferansiyel evrim (DE), Guguk

kuşu arama (CS), Ateş böceği (FA), Yarasa (BA) ve Gri kurt (GWO) algoritmalarının sonuçlarıyla kıyaslanmıştır. Bu algoritmaların sonuçları doğrudan Koc vd. çalışmasından alınmıştır [16]. Sonuçlar ortalama (Ort.) ve standart sapma (Std. Sap.) açısından karşılaştırmalı olarak sunulmuştur. *Ort ve Std. Sap.* Değerleri sırasıyla 25 bağımsız çalışmaya ait Otsu metodu kullanılarak edilen amaç fonksiyonunun sonuçlarının ortalama değerini ve standart sapma değerlerini ifade etmektedir. Tablo 2, 3, 4 ve 5 sırasıyla K=2, 3, 4 ve 5 değerleri için elde edilen

deneysel sonuçları sunmaktadır. Tablo 2-5'te koyu renkle ifade edilen yerler önerilen algoritmanın ilgili test verisi için en iyi olduğunu ifade etmektedir.

Tablo 2 incelendiğinde önerilen CHIO algoritmasının 6 görüntünün tamamında *Ort.* değer açısından en iyi değere ulaştığını göstermektedir. Std. Sap. açısından ise sadece Göl isimli görüntüde en iyiyi yakaladığı görülmektedir. Sonuç olarak CHIO yöntemi K=2 olduğu durumda çok başarılıdır.

Tablo 2. Otsu kriterine göre K=2 için algoritmaların elde edilen sonuçların karşılaştırılması
(Comparison of the results obtained from the algorithms according to the Otsu criterion for K=2)

Yöntem		Barbara	Oturma odası	Tekneler	Goldhill	Göl	Anten
Otsu	En İyi	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
PSO	Ort.	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.82E-12	0.00E+00	0.00E+00	4.55E-13	3.64E-12	2.27E-13
DE	Ort.	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.82E-12	0.00E+00	0.00E+00	4.55E-13	3.64E-12	2.27E-13
CS	Ort.	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.82E-12	0.00E+00	0.00E+00	4.55E-13	3.64E-12	2.27E-13
FA	Ort.	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.82E-12	0.00E+00	0.00E+00	4.55E-13	3.64E-12	2.27E-13
BA	Ort.	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.36E-12	2.27E-13	0.00E+00	4.55E-13	4.09E-12	2.27E-13
GWO	Ort.	2608.611	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.84E-12	6.89E-13	1.84E-12	1.84E-12	2.30E-12	6.89E-13
CHIO	Ort.	2608.898	1627.909	1863.347	2069.510	3974.738	1808.171
	Std. Sap.	1.65E-01	4.64E-13	6.96E-13	1.39E-12	1.39E-12	6.96E-13

Tablo 3. Otsu kriterine göre K=3 için algoritmaların elde edilen sonuçların karşılaştırılması
(Comparison of the results obtained from the algorithms according to the Otsu criterion for K=3)

Yöntem		Barbara	Oturma odası	Tekneler	Goldhill	Göl	Anten
Otsu	En İyi	2785.163	1760.103	1994.536	2220.373	4112.631	1905.411
PSO	Ort.	2785.163	1760.103	1994.536	2220.373	4112.631	1905.411
	Std. Sap.	2.27E-12	2.27E-13	1.59E-12	1.36E-12	4.55E-12	1.14E-12
DE	Ort.	2785.162	1760.103	1994.535	2220.373	4112.631	1905.411
	Std. Sap.	8.31E-03	2.27E-13	7.26E-03	1.36E-12	4.55E-12	1.14E-12
CS	Ort.	2785.163	1760.103	1994.536	2220.373	4112.631	1905.411
	Std. Sap.	2.27E-12	2.27E-13	1.59E-12	1.36E-12	4.55E-12	1.14E-12
FA	Ort.	2785.163	1760.103	1994.536	2220.373	4112.631	1905.411
	Std. Sap.	2.27E-12	2.27E-13	1.59E-12	1.36E-12	4.55E-12	1.14E-12
BA	Ort.	2785.163	1760.103	1994.536	2220.373	4112.631	1905.411
	Std. Sap.	1.36E-12	2.27E-13	1.14E-12	1.36E-12	3.64E-12	1.14E-12
GWO	Ort.	2785.612	1760.103	1994.536	2220.373	4112.631	1905.411
	Std. Sap.	1.38E-12	6.89E-13	1.15E-12	1.38E-12	5.51E-12	9.19E-13
CHIO	Ort.	2785.383	1760.103	1994.536	2220.373	4112.631	1905.411
	Std. Sap.	1.10E-01	6.96E-13	2.32E-13	1.39E-12	0.00E+00	2.32E-13

Tablo 4. Otsu kriterine göre K=4 için algoritmalarından elde edilen sonuçların karşılaştırılması
(Comparison of the results obtained from the algorithms according to the Otsu criterion for K=4)

Yöntem		Barbara	Oturma odası	Tekneler	Goldhill	Göl	Anten
Otsu	En İyi	2856.262	1828.864	2059.866	4180.886	4180.886	1957.0180
PSO	Ort.	2856.261	1828.864	2059.866	2295.380	4180.884	1955.086
	Std. Sap.	6.66E-03	1.59E-12	4.22E-04	1.48E-03	7.41E-03	7.65E + 00
DE	Ort.	2856.261	1828.860	2059.865	2295.380	4180.884	1955.086
	Std. Sap.	2.80E-03	1.30E-02	6.85E-03	1.48E-03	7.41E-03	7.65E + 00
CS	Ort.	2856.262	1828.864	2059.866	2295.380	4180.886	1957.018
	Std. Sap.	2.45E-03	1.59E-12	1.36E-12	2.27E-12	0.00E+00	0.00E+00
FA	Ort.	2856.262	1828.864	2059.866	2295.380	4180.886	1957.018
	Std. Sap.	4.55E-13	1.59E-12	1.36E-12	2.27E-12	0.00E+00	0.00E+00
BA	Ort.	2856.262	1828.864	2059.866	2295.380	4180.886	1957.018
	Std. Sap.	4.55E-13	2.27E-12	9.09E-13	2.27E-12	0.00E+00	2.27E-13
GWO	Ort.	2856.699	1828.864	2059.866	2295.380	4180.886	1957.018
	Std. Sap.	4.59E-13	1.61E-12	2.30E-12	2.30E-12	0.00E+00	2.77E-04
CHIO	Ort.	2856.463	1828.864	2059.866	2295.380	4180.886	1957.018
	Std. Sap.	1.10E-01	4.64E-13	0.00E+00	1.39E-12	0.00E+00	1.16E-12

Tablo 5. Otsu kriterine göre K=5 için algoritmalarından elde edilen sonuçların karşılaştırılması
(Comparison of the results obtained from the algorithms according to the Otsu criterion for K=5)

Yöntem		Barbara	Oturma odası	Tekneler	Goldhill	Göl	Anten
Otsu	En İyi	2890.977	1871.991	2092.776	2331.157	4216.944	1980.657
PSO	Ort.	2890.976	1871.985	2092.771	2331.156	4216.943	1979.170
	Std. Sap.	5.05E-02	2.29E-02	8.36E-03	3.56E-04	3.99E-03	2.51E + 00
DE	Ort.	2890.971	1871.977	2092.767	2331.156	4216.943	1979.170
	Std. Sap.	2.05E-02	2.34E-02	2.71E-02	3.56E-04	3.99E-03	2.51E + 00
CS	Ort.	2890.977	1871.990	2092.776	2331.155	4216.944	1980.651
	Std. Sap.	4.85E-04	2.70E-03	1.03E-03	4.76E-03	9.09E-13	1.16E-02
FA	Ort.	2890.977	1871.991	2092.774	2331.157	4216.944	1980.657
	Std. Sap.	3.64E-12	0.00E+00	3.57E-03	2.27E-12	9.09E-13	9.09E-13
BA	Ort.	2890.977	1871.991	2092.773	2331.157	4216.944	1979.514
	Std. Sap.	2.73E-12	0.00E+00	3.78E-03	2.27E-12	3.64E-12	2.29E + 00
GWO	Ort.	2891.491	1871.985	2092.773	2331.156	4216.943	1980.656
	Std. Sap.	6.96E-03	1.91E-02	6.43E-03	3.42E-03	1.97E-03	2.57E-03
CHIO	Ort.	2891.116	1871.990	2092.774	2331.153	4216.943	1980.589
	Std. Sap.	9.59E-02	3.86E-03	3.32E-03	7.81E-03	7.05E-04	1.01E-01

Tablo 3 detaylı incelendiğinde ortalama değerlere göre Barbara hariç diğer tüm 5 görüntüde CHIO algoritmasının en iyi eşik değerlerini yakaladığı görülmektedir. Standart sapma açısından ise Barbara, Göl ve Goldhill hariç diğer 3 görüntüde en iyi değerleri ürettiği görülmektedir. Sonuç olarak K=3 değerinde önerilen yöntemin çözüm kalitesi açısından diğer algoritmalarla beraber çok başarılı olduğu görülmektedir.

K=4 değeri için Tablo 4'e ait sonuçlar incelendiğinde ortalama değer açısından K=3 olduğu duruma benzer şekilde Barbara verisi hariç diğer tüm görüntülerde en iyi değere ulaştığı görülmektedir. Standart sapma açısından önerilen algoritma değerlendirildiğinde sadece Barbara ve Anten verisinde en iyi değere ulaşamadığı diğer 4 görüntüde kararlı sonuçlar ürettiği görülmektedir. Sonuç olarak K=4 değeri için CHIO algoritması çözüm kalitesi ve kararlılık açısından başarılı bir algoritmadır.


Son olarak Tablo 5 incelendiğinde ise çözüm kalitesi açısından Oturma odası, tekne ve göl görüntülerinde en iyi sonucu yakaladığı görülürken, diğer görüntülerde ise optimal değere çok yaklaştığı görülmektedir. Standart sapma açısından incelendiğinde ise önerilen yöntemin çok başarılı bir performans sergileyemediği görülmektedir. Sonuç olarak CHIO yöntemi K=5 olduğu durumda çözüm kalitesi açısından kayda değer bir başarı yakalarken, standart sapma açısından ise çok kararlı gözükmemektedir.

3.1. Yakınsama Grafikleri (Convergence Curves)


Önerilen CHIO algoritmasına ait 25 bağımsız çalışmadan elde edilen en iyi yakınsama sonuçları her bir görüntü için ayrı ayrı sunulmuştur. Burada CHIO algoritmasıyla elde edilen sonuçlar ile Tablo 1'deki Otsu metoduna ait bilinen en iyi değerlerinin farkı alınmıştır. Böylece hata oranları tespit edilmektedir. K değerleri açısından her bir görüntüye ait sonuçlar kıyaslamalı olarak Şekil 2'de verilmektedir.

Şekil 2(a) incelendiğinde Barbara görüntüsünde K=2, 3, 4 ve 5 olduğu durumlarda yaklaşık ilk 200 iterasyon içerisinde optimal değere ulaşıldığı görülmektedir. Şekil 2(b) incelendiğinde oturma odası'na ait yakınsama sonuçlarında K sayısına bağlı olarak K'nın artması yakınsama süresini uzattığı görülmektedir. K=2 olduğunda neredeyse ilk 100 iterasyonda yakınsamayı tamamlarken, K=5 olduğunda ise yaklaşık 500. iterasyonlarda yakınsamanın tamamlandığı görülmektedir.


Şekil 2(c)'ye ait yakınsama sonuçları incelendiğinde K=2 olduğu durumda hemen ilk iterasyonlarda yakınsama başarıyla tamamlanırken, K=3, 4 ve 5 olduğu durumlarda ise yaklaşık olarak 150-300. iterasyonlar arasında optimal değere ulaştıkları görülmektedir.



(a) Barbara

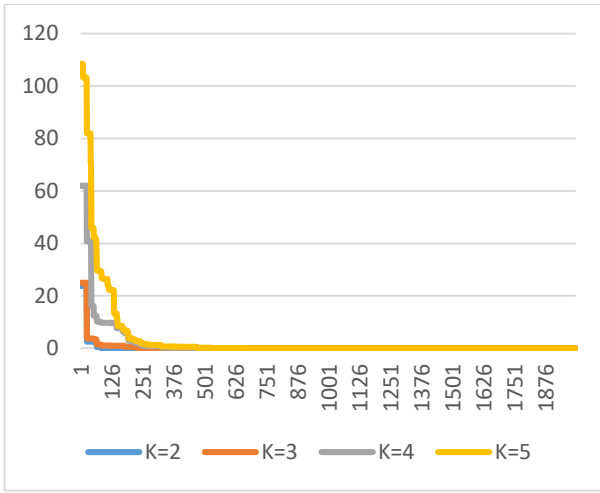


(b) Oturma odası




(c) Tekneler

Şekil 2(d)'ye ait görüntünün iterasyon sonuçları analiz edildiğinde K=2 için çok hızlı bir yakınsama görülmektedir. K=3 olduğunda yaklaşık ilk 200 iterasyonda işlem sonuçlanırken, K=4 ve K=5 durumunda yaklaşık olarak ilk 300 iterasyonda yakınsama işlemi tamamlanmasına karşın K=5 durumunda 250-300. iterasyonlar arasında daha hızlı bir yakınsamaya rastlanmıştır.




(d) Goldhill

Şekil 2(e)'ye ait görüntünün sonuçları incelendiğinde ise yaklaşık olarak ilk 200 iterasyon içerisinde tüm K (2, 3, 4 ve 5) değerleri için algoritmanın yakınsamayı başarıyla tamamladığı açıkça görülmektedir. K değerlerinin artması sadece ilk aşamada optimal değere olan uzaklığı artırırken algoritmanın başarılı yakınsama kabiliyetiyle beraber K değerinin yüksek olması sonucu negatif etkilememektedir.



(e) Göl

Son olarak Şekil 2(f)'teki yakınsama sonuçları analiz edildiğinde ise K=2 durumunda algoritmanın çok kısa bir sürede optimal sonuca ulaştığı görülmektedir. K=3 olduğu duruma bakıldığında yaklaşık olarak ilk 300 iterasyon içerisinde yakınsama işleminin tamamlandığı görülmektedir. K=4 ve K=5 durumunda ise ilk 400 iterasyon içerisinde algoritmanın en iyi sonuca ulaştığı görülmektedir.



(f) Anten

Şekil 2. Görüntülere ait yakınsama grafikleri
(Convergence curves of the test images)

Şekil 3-8'de K değerlerine göre segmente edilmiş tüm sonuçlar verilmiştir. Önerilen algoritma ile elde edilen K değerlerine göre üretilen sonuç görüntüler birlikte sunulmaktadır. Bu sonuçlara K=2 olduğu durumda elde edilen görüntü ile K=5 olduğu durumda elde edilen sonuç görüntü arasında segmentasyon açısından önemli bir fark olduğu açıkça görülmektedir.



Şekil 3. Barbara için K değerlerine göre elde edilmiş görüntüler

(Images obtained by K values for Barbara)



(K=2) 87, 145



(K=3) 76, 123, 163



(K=4) 56, 97, 132, 168



(K=5) 49, 88, 120, 146, 178

Şekil 4. Oturma odası için K değerlerine göre elde edilmiş görüntüler
(Images obtained by K values for Oturma Odası)



(K=2) 94, 161



(K=3) 83, 126, 179



(K=4) 69, 102, 138, 186



(K=5) 63, 91, 117, 147, 191

Şekil 6. Goldhill için K değerlerine göre elde edilmiş görüntüler
(Images obtained by K values for Goldhill)



(K=2) 93, 155



(K=3) 73, 126, 167



(K=4) 65, 114, 147, 179



(K=5) 51, 90, 126, 152, 183

Şekil 5. Tekneler için K değerlerine göre elde edilmiş görüntüler
(Images obtained by K values for Tekneler)



(K=2) 85, 154



(K=3) 78, 140, 194




(K=4) 67, 110, 158, 198



(K=5) 57, 88, 127, 166, 200

Şekil 7. Göl için K değerlerine göre elde edilmiş görüntüler
(Images obtained by K values for Göl)



Şekil 8. Anten için K değerlerine göre elde edilmiş görüntüler
(Images obtained by K values for Anten)

4. SONUÇ (CONCLUSION)

Bu çalışmada çok düzeyli eşik seçimi için literatürde en çok kullanılan tekniklerden biri olan Otsu metodu tercih edilmiştir. Otsu metodu ile elde edilen değerler amaç fonksiyonunun çıktı değerleri olarak kabul edilmiş ve bu değerler bir optimizasyon algoritması ile maksimize edilmeye çalışılmıştır. Bu çalışmada sürü zekâsı algoritması olarak 2021 yılında önerilmiş olan Coronavirüs sürü bağışıklık algoritması (CHIO) kullanılmıştır. Eşik sayısı olarak ise 2 ila 5 değerleri bu çalışmada tercih edilmiştir. Deneysel çalışmalarda test veri seti olarak altı görüntü kullanılmıştır. CHIO algoritması altı farklı algoritma ile adil şekilde kıyaslanmıştır.

K değerlerine bağlı olarak elde edilen çözüm kalitesine ait sonuçlar incelendiğinde K=2 olduğu durumda önerilen algoritma çok iyi sonuçlar üretmektedir. K=3 ve K=4 olduğu durumlarda önerilen algoritma K=2 durumuna göre daha az başarılı görülmektedir. K=5 olduğu duruma bakıldığında ise bu kez diğer durumlara nazaran CHIO algoritmasının başarı grafiğinin belli ölçüde düştüğü görülmektedir. Bu durum dikkate alınarak K değerinin artmasına karşın CHIO yönteminin diğer algoritmalarla rekabet düzeyinin ihmal edilmez düzeyde düştüğü görülmektedir. Standart sapma değerlerine göre incelendiğinde algoritmanın genel olarak daha az başarılı olduğu görülmektedir. Buna rağmen ürettiği değerler makul bir seviyede olduğu düşünüldüğünde algoritmanın kararlı olduğu söylenebilir. Yakınsama grafikleri açısından genel olarak incelendiğinde ise yine K değerlerindeki artışla beraber yakınsama sürelerinin yaklaşık %25

oranında uzadığı görülmektedir. Bununla beraber genel olarak tüm test görüntülerinde CHIO algoritmasının neredeyse ilk 300 iterasyon içerisinde yakınsama işlemini başarıyla tamamladığı görülmektedir. Bu da algoritmanın yakınsama açısından etkili bir yöntem olduğunu göstermektedir. Bununla beraber K değerlerindeki artış durumunda K=3 ve K=4 durumunda önerilen yöntemin Barbara verisi için en başarılı sonucu bulamadığı görülmektedir. K=5 olduğu durumda ise Goldhill ve Anten verisinde de en iyi sonucu bulamamasına karşın sonuçların diğer algoritmalarla elde edilen sonuçlara çok yakın olduğu görülmektedir. Örneğin Goldhill için bulunan en iyi değer 2331.157 iken CHIO algoritması ile 2331.153 değeri bulunmuştur. Söz konusu farkın 0.004 olduğu göz önüne alındığında bu durumun ihmal edilebilir olduğu söylenebilir. Anten verisi için en iyi değer olarak 1980.657 sonucu bulunmuş olup CHIO ile 1980.589 değeri bulunmuştur. Yine bu sonuçlardan hareketle ortalama açısından farkın 0.068 olduğu görülmektedir. Bu sonucun da çok büyük bir fark olmadığı açıktır. Sonuç olarak, tüm bu değerlendirmeler ışığında önerilen yöntemin Barbara verisi hariç diğer tüm veri setleri için başarılı olduğu söylenebilir.

Gelecek çalışmalar için CHIO algoritması daha kararlı bir hale getirilerek K değerlerindeki artışa rağmen daha başarılı sonuçlar üretilebilir. Ayrıca, CHIO algoritması doğrudan ayrık bir uzayda temsil edilerek bu probleme uyarlanabilir ve sonuçlar mukayese edilebilir.

KAYNAKLAR (REFERENCES)

- [1] M. Omari and S. O. Jaafri, "Application of image compression to multiple-shot pictures using similarity norms with three level blurring", *Computers, Materials and Continua*, 58(2), 753-775, 2019.
- [2] Z. Pan, X. Yi, Y. Zhang, B. Jeon, and S. Kwong, "Efficient in-loop filtering based on enhanced deep convolutional neural networks for HEVC", *IEEE Transactions on Image Processing*, 29, 5352-5366, 2020.
- [3] K. Jin and S. Wang, "Image denoising based on the asymmetric Gaussian mixture model", *J. Internet Things*, 2(1), 1-11, 2020.
- [4] S. Susan and K. Rachna Devi, "Text area segmentation from document images by novel adaptive thresholding and template matching using texture cues", *Pattern Analysis and Applications*, 23(2), 869-881, 2020.
- [5] S. Bandyopadhyay, S. Das, and A. Datta, "A hybrid fuzzy filtering-fuzzy thresholding technique for region of interest detection in noisy images", *Applied Intelligence*, 50(4), 1112-1132, 2020.
- [6] K. Sowjanya and S. K. Injeti, "Investigation of butterfly optimization and gases Brownian motion optimization algorithms for optimal multilevel image thresholding", *Expert Systems with Applications*, 182, 115286, 2021.
- [7] B. Akay, "A study on particle swarm optimization and artificial bee colony algorithms for multilevel thresholding", *Applied Soft Computing*, 13(6), 3066-3091, 2013.

- [8] D. Oliva, E. Cuevas, G. Pajares, D. Zaldivar, and M. Perez-Cisneros, "Multilevel thresholding segmentation based on harmony search optimization", *Journal of Applied Mathematics*, 2013, 2013.
- [9] J. N. Kapur, P. K. Sahoo, and A. K. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram", *Computer vision, graphics, and image processing*, 29(3), 273-285, 1985.
- [10] S. Pare, A. Kumar, G. K. Singh, and V. Bajaj, "Image segmentation using multilevel thresholding: a research review", *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 44(1), 1-29, 2020.
- [11] L. Li, L. Sun, Y. Xue, S. Li, X. Huang, and R. F. Mansour, "Fuzzy multilevel image thresholding based on improved coyote optimization algorithm", *IEEE Access*, 9, 33595-33607, 2021.
- [12] N. Sri Madhava Raja, V. Rajinikanth, and K. Latha, "Otsu based optimal multilevel image thresholding using firefly algorithm", *Modelling and Simulation in Engineering*, 2014, 2014.
- [13] M. Abd El Aziz, A. A. Ewees, and A. E. Hassanien, "Whale optimization algorithm and moth-flame optimization for multilevel thresholding image segmentation", *Expert Systems with Applications*, 83, 242-256, 2017.
- [14] S. Kotte, R. K. Pullakura, and S. K. Injeti, "Optimal multilevel thresholding selection for brain MRI image segmentation based on adaptive wind driven optimization", *Measurement*, 130, 340-361, 2018.
- [15] A. S. Kahraman, T. R. Farshi, and R. Demirci, "Renkli görüntülerin çok seviyeli eşiklenmesi ve sınıflandırılması", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6(4), 846-859, 2018.
- [16] I. Koc, O. K. Baykan, and I. Babaoglu, "Gri kurt optimizasyon algoritmasına dayanan çok seviyeli imge eşik seçimi", *Politeknik Dergisi*, 21(4), 841-847, 2018.
- [17] M. Abd Elaziz and S. Lu, "Many-objectives multilevel thresholding image segmentation using knee evolutionary algorithm", *Expert systems with Applications*, 125, 305-316, 2019.
- [18] A. Çelik and S. Demirel, "Otsu ve Ridler-Calvard Görüntü İşleme Yöntemlerinin Zatürre Tespitinde Kullanılması", *Muş Alparslan Üniversitesi Fen Bilimleri Dergisi*, 10(1), 917-923.
- [19] B. Karasulu, "Görüntülerde insan kulağı tespit ve bölütlemesini temel alan biyometrik yetkilendirme üzerine bir inceleme", *Bilişim Teknolojileri Dergisi*, 9(2), 97, 2016.
- [20] Y. Ölmez, A. Sengur, and G. Ozmen Koca, "Multilevel thresholding with metaheuristic methods", *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(1), 213-224, 2020.
- [21] N. Otsu, "A threshold selection method from gray-level histograms", *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66, 1979.
- [22] M. A. Al-Betar, Z. A. A. Alyasseri, M. A. Awadallah, and I. Abu Doush, "Coronavirus herd immunity optimizer (CHIO)", *Neural Computing and Applications*, 33(10), 5011-5042, 2021.
- [23] J. S. Lavine, A. A. King, and O. N. Bjørnstad, "Natural immune boosting in pertussis dynamics and the potential for long-term vaccine failure", *Proceedings of the National Academy of Sciences*, 108(17), 7259-7264, 2011.

Çağrı Merkezlerinde Olumsuzluk İçeren Çağrıların Evrişimsel Sinir Ağları ile Tespiti

Araştırma Makalesi/Research Article

 Ali Fatih KARATAŞ¹,  Öykü Berfin MERCAN¹,  Umut ÖZDİL²,  Şükrü OZAN¹

¹AdresGezini A.Ş. Ar-Ge Merkezi, İzmir, Türkiye

²Elektrik-Elektronik Mühendisliği, İzmir Demokrasi Üniversitesi, İzmir, Türkiye

alifatih449@gmail.com, oykumercan@adresgezini.com, 2117108001@std.idu.edu.tr, sukruozan@adresgezini.com

(Geliş/Received:04.08.2022; Kabul/Accepted:09.11.2022)

DOI: 10.17671/gazibtd.1156330

Özet— Bu çalışmada çağrı merkezi çalışanları ile müşteriler arasındaki telefon konuşmalarının otomatik olarak olumlu veya olumsuz şeklinde değerlendirilmesi üzerine odaklanılmıştır. Çalışmada kullanılan veri seti firma bünyesinde gerçekleştirilen telefon görüşmelerinden oluşmaktadır. Veri seti üçer saniyelik 10411 adet ses kaydını içermekte olup bu kayıtların 5408 tanesi olumlu kayıtlardan 5003 tanesi münakaşa, öfke ve hakaret içeren olumsuz kayıtlardan oluşmaktadır. Çağrı merkezi kayıtlarından duygu tanıma için anlamlı öznitelikler elde etmek amacıyla her bir ses kaydından MFCC öznitelikleri çıkarılmıştır. Çağrı merkezi kayıtlarını olumlu olumsuz olarak sınıflandırmak için önerilen CNN mimarisi MFCC öznitelikleriyle eğitilmiştir. Önerilen CNN modeli %86,1 eğitim başarısı, %77,3 doğrulama başarısı göstermiş olup test verileri üzerinde %69,4 sınıflandırma başarısı elde edilmiştir. Bu çalışma ile çağrı merkezlerinde gerçekleşen konuşmaların otomatik analizi yapıp olumsuz durumların kalite yöneticilerine bildirilmesiyle gerekli önlemlerin alınarak müşteri memnuniyetinin artırılması amaçlanmaktadır.

Anahtar Kelimeler— ses sinyalinde duygu tanıma, çağrı merkezi, MFCC, CNN.

Detection of Negative Calls in Call Centers with Convolutional Neural Networks

Abstract— In this study, it is focused on the automatic evaluation of telephone conversations between call center employees and customers as positive or negative. The dataset used in the study include telephone conversations between call center employees and customers in the company. The data set contains 10411 three-second call center records; 5408 of them are positive records and 5003 of them are negative records that include arguments, anger and insults. In order to obtain meaningful features for emotion recognition from voice records, MFCC features were extracted from each call center records. The proposed CNN architecture is trained with MFCC features to classify call center records as positive or negative. The proposed CNN model showed 86.1% training accuracy, 77.3% validation accuracy and it achieved 69.4% classification accuracy on the test data. This study aimed to increase customer satisfaction by automatic analysis of conversations in call centers and notifying quality managers of negative records.

Keywords— emotion recognition from audio signal, call center, MFCC, CNN

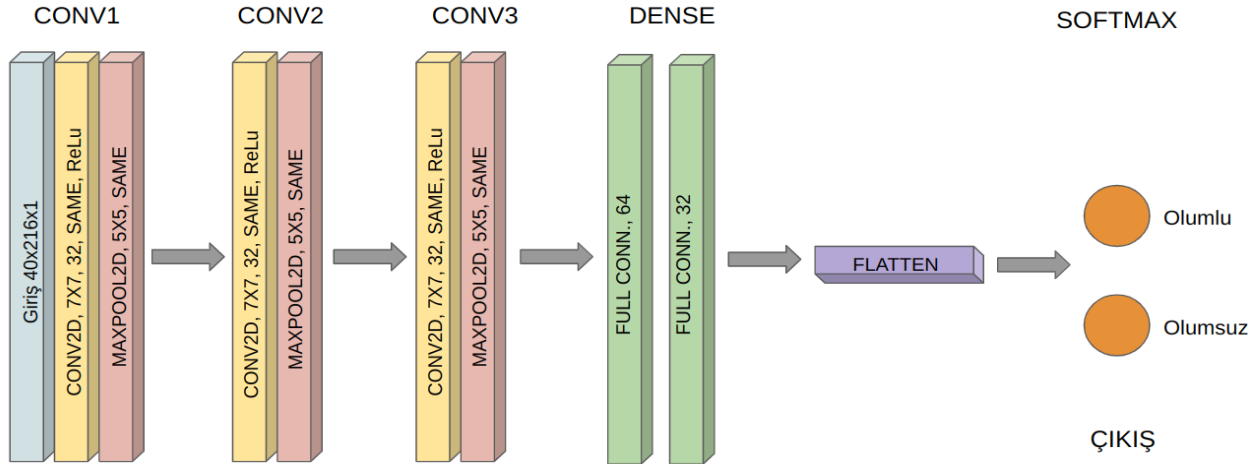
1. GİRİŞ (INTRODUCTION)

Müşteri ilişkilerinin oldukça önem kazandığı günümüzde firmalar müşterileri ile iletişim kurmak amacıyla çevrimiçi yöntemler ve telefon görüşmelerini yaygın olarak kullanmaktadırlar. Teknolojik gelişmelerin sağladığı imkanlarla çevrimiçi görüşmelerdeki kalite ve standartların iyileştirilmesi hedeflenerek müşteri memnuniyetinin üst düzeye çıkarılması hizmet veren kurumların öncelikli hedefi haline gelmiştir. Bu kapsamda çevrimiçi görüşmelerdeki sahtekarlık, anomali ve duygu tespitinin gerçekleştirilmesi amaçlanmaktadır. Dijitalleşme ile birlikte çevrimiçi görüşmelerdeki artış veri yığını oluşturmakta olup görüşmelerde anomali ve duygu tespitinin hızlı ve etkili bir şekilde gerçekleştirilmesinde zorluklarla karşılaşmaktadır. Son yıllarda genel olarak yapay zeka alanında ve özel olarak da dijital ses işleme alanında yaşanan gelişmelerle birlikte otomatik konuşma tanıma ve ses verisinden duygu tanıma konularında elde edilen başarılı sonuçlar ses verilerinin geleneksel yöntemlerle analizinde karşılaşılan zorluklara pratik ve hızlı çözümler sunmaktadır [1-3]. Özlan vd. derin evrişimli sinir ağları ile sahte çağrı merkezi görüşmelerini otomatik olarak tespit eden yöntemi önermişlerdir. Önerilen yöntem konuşma tanıma motoru kullanılarak metne çevrilmiş çağrı merkezi görüşmelerini metin sınıflandırma algoritmasıyla sınıflandırarak sahte görüşmeleri otomatik algılamaktadır [1]. Iheme vd. doğrusal olmayan güç dönüşümü, sinirsel özellik öğrenme ve kümeleme içeren yarı denetimli yöntem ile çağrı merkezi temsilcisi hatasını tespit eden bir çalışma sunmuşlardır [2]. Çağrı süresindeki sessizlik miktarı önemli bir performans göstergesi olarak belirlenmiş olup, önerilen sistem ile kalite kontrol yöneticilerinin ve çağrı merkezi çalışanlarının performansında artış gözlemlendiği belirtilmiştir. Pappas vd. konuşma sinyalinden doğrudan çıkarılan Mel Frekans Cepstral Katsayısı (Mel Frequency Cepstral Coefficient- MFCC) öznitelikleri ile eğitilen Lojistik Regresyon sınıflandırıcısıyla çağrı merkezi diyalogunda %70 başarı ile öfke tespiti gerçekleştirmiştir [3].

Ses işleme araştırmalarında MFCC önemli bir yere sahip olup yüksek başarı oranıyla ses verisinden öznitelik elde edilmesinde yaygın olarak kullanılan bir tekniktir [4]. Ses verilerinden çıkarılan MFCC'nin makine öğrenmesi ve derin öğrenme algoritmalarında öznitelik olarak kullanılmasyla dijital ses işleme alanında birçok çalışma gerçekleştirilmiştir [5-11]. Turnbull vd. ses kayıtlarının müzik türlerine göre otomatik sınıflandırılmasını amaçlayan çalışmada MFCC ve ses sinyalinin kısa süreli Fourier dönüşümüne (STFT) dayalı öznitelikleri ile Radyal Temelli Fonksiyon (RBF) eğitilmiş ve önerilen yöntemin insan performansına yakın başarı gösterdiği gözlemlenmiştir [5]. Iheme vd. ses verisinin sessizlik, konuşma ve müzik olmak üzere üç sınıftan biri olarak sınıflandırmak amacıyla ses verilerinin MFCC katsayılarını, türevlerini ve ikinci türevlerini SVM (Support Vector Machine) ve Naive Bayes algoritmalarının eğitiminde öznitelik olarak kullanmış ve

bu özniteliklerin başarıya etkilerini araştırmışlardır [6]. MFCC öznitelikleri konuşma duygusu tanımda yaygın olarak kullanılmaktadır. Likitha vd. konuşmacıların ses sinyallerinden duygunun tespit edilmesi için önerdikleri çalışma, MFCC kullanarak öznitelik çıkarımına ve standart sapma kullanarak karar vermeye dayanmaktadır. Çalışmada kullanılan veri seti farklı duygulara sahip 60 farklı kişinin ses kaydını içermektedir. Ses kayıtlarından MFCC öznitelikleri elde edilmiş ardından MFCC'nin ortalama değeri ve ortalama değerinin standart sapması bulunmuştur. Elde edilen standart sapma, farklı duygular için optimize edilmiş standart sapma değerleriyle "if-else" yapısında karşılaştırılarak sese ait duygu tespit edilmiştir [7]. Bir diğer bir duygu tespiti çalışmasında Milton vd. Berlin EmoDB veri setinde bulunan 7 farklı duyguyu sınıflandırmak için 535 tane ses verisinden elde edilen MFCC öznitelikleri SVM sınıflandırıcısının eğitiminde kullanılmıştır. Performans analizi sonucu da %68'dir [8]. Waghmare vd. yapay duygusal Marathi konuşma veri tabanından konuşma duygusunu analiz etmek ve tanımak için MFCC öznitelikleri çıkarmış, çıkarılan öznitelikler LDA (Lineer Diskriminant Analiz) sınıflandırıcısının eğitiminde kullanılmıştır [9]. Demircan vd. Berlin EmoDB veri setiyle gerçekleştirdikleri çalışmada ses kliplerinden MFCC'leri çıkardıktan sonra konuşma duygusunu sınıflandırmak için bir KNN (K En Yakın Komşu) algoritması önermişlerdir. 7 farklı duygunun sınıflandırıldığı bu çalışmada %50 sınıflandırma başarısı elde edilmiştir [10]. Nalini vd. YSA (Yapay Sinir Ağları), SVM, RBFNN (Radyal Temel Fonksiyonu Sinir Ağları) kullanarak müzikte duyguyu tanımak için MFCC kullanmışlardır [11].

Makine öğrenmesi ve ses verisinden öznitelik çıkarma yöntemleri ile gerçekleştirilen çalışmalar ile başarılı sonuçlara ulaşılmış ve ses işleme alanına olan ilgi artmıştır. Yeterli sayıda ses verisi ile yapay sinir ağları eğitilerek Konuşma Duygusu Tanıma (KDT) alanında birçok çalışma gerçekleştirilmiştir [12-14]. CNN'ler (Evrişimsel Sinir Ağları (Convolutional Neural Network)) ve RNN'lere (Tekrarlayan Sinir Ağları (Recurrent Neural Network)) dayalı KDT algoritmasına değinilmiş ve birleştirilmiş CNN'ler ve RNN'lere dayalı bir KDT yöntemi önerilmiştir [12]. Bir diğer çalışmada konuşma duygusunu tanımak için 1B ve 2B CNN LSTM (Uzun Kısa Süreli Bellek (Long Short Term Memory)) ağları incelenmiştir [13]. Bu iki ağın kıyaslanması için iki farklı veri seti üzerinde çalışma gerçekleştirilmiştir. Tasarlanan iki CNN LSTM ağının, duygusal bilginin ayırt edici özelliklerini öğrenebileceği ve üst düzey soyutlamaları modelleyebileceği gösterilmiştir. Deneysel sonuçlar karşılaştırıldığında 2B CNN LSTM ağının performansının 1B CNN LSTM ağının performansına göre yüksek olduğu gözlemlenmiştir. Duygu tanıma amacıyla gerçekleştirilen başka bir çalışmada ise LSTM tabanlı sınıflandırma ağı ile öznitelik çıkarmak için paralel evrişimli katmanların ortaklaşa eğitimi önerilmiştir. Önerilen çalışma paralel çok katmanlı CNN ağının bir LSTM üzerinde istiflendiğini ve ham konuşma kullanan mevcut yöntemlerle karşılaştırıldığında daha iyi doğruluk sağladığını göstermiştir [14].



Şekil 1. Önerilen CNN model
(Proposed CNN model)

Ham ses sinyallerinden MFCC gibi yüksek seviyeli bilgilerin alınması ve ardından bu bilgilerin bir sınır ağından geçirilmesiyle konuşma duygusu tanıma alanında çalışmalar kaydedilmiştir. Wang vd. MFCC özniteliklerine ve ses sinyallerinden üretilen mel-spektrogramlarına dayalı olarak duyguları tahmin eden çift aşamalı bir yöntem önermişlerdir [15]. Önerilen yöntemde standart bir LSTM, MFCC özelliklerini işlerken, Dual-Sequence LSTM (DSLSTM) olarak belirtilen yeni bir LSTM mimarisi, iki mel-spektrogramı aynı anda işler. EmoDB veri seti ile gerçekleştirilen başka bir çalışmada ise spektrogram, Mel-spektrogram ve MFCC olmak üzere önerilen CNN+BLSTM mimarisi üç farklı öznitelik ile eğitilmiş ve konuşma duygusu tanımadaki MFCC özniteliklerinin başarılı sonuçlar verdiği gözlemlenmiştir [14, 16].

Literatürde yer alan çalışmalar incelendiğinde EmoDB veri setinin duygu tanımadaki yaygın olarak kullanıldığı görülmektedir [8, 10, 12, 14, 16]. Berlin EmoDB [17], 7 duygu içeren ve sınıflandırma doğruluğunu doğru bir şekilde değerlendirmek için her duyguyu neredeyse aynı sayıda içeren dengeli bir veri setidir. 10 profesyonel oyuncunun duygu ifadelerini öfkeli, can sıkıntısı, iğrenme, korku, mutlu, nötr ve hüzünlü bir şekilde söylemesiyle veri seti oluşturulmuştur. Günlük iletişimden gelen ve tüm duygularda yorumlanabilen 535 cümle vardır. Berlin EmoDB ve bu veri seti gibi konuşma duygusu tanıma çalışmalarında kullanılmak üzere oluşturulan veri setleri haricinde çağrı merkezi konuşmaları, röportajlar ve televizyon programları gibi kayıtlar gerçek duyguları içeren, duyguların doğal olarak elde edilebileceği veri kaynaklarını oluşturmaktadır. Spontane duyguları içeren, üç boyutlu bir duygu alanı çerçevesinde oluşturulan VAM veri tabanı [18, 19] bir Alman TV talk-show'u "Vera am Mittag" kaydedilmiştir. Veri tabanı talk-show'da tartışılan konular nedeniyle çoğunlukla nötr ve olumsuz duygular içerir. [3]'de kullanılan veri seti ise bir telefon sağlayıcı şirketin çağrı merkezinden toplam 9 saat 30 dakika uzunluğunda 137 kayıtlı müşteri temsilcisi görüşmesini içeren Yunanca görüşmelerden oluşmaktadır.

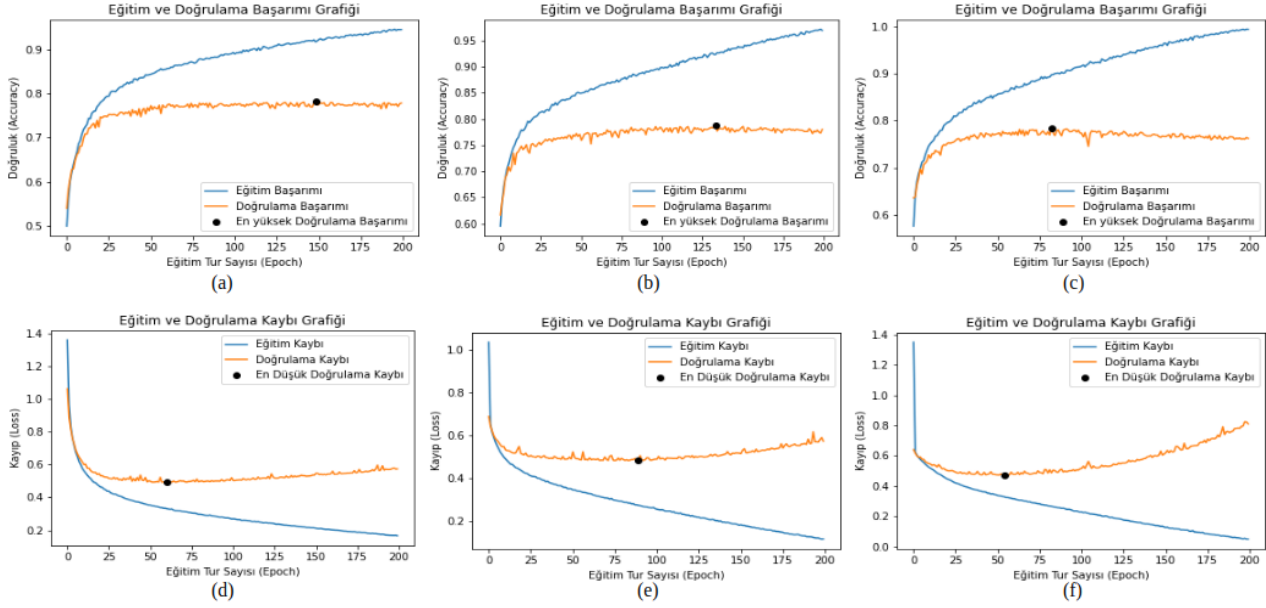
Bu çalışma ile çağrı merkezleri telefon görüşmelerinin otomatik olarak analizinin yapılmasıyla müşteri ve müşteri temsilcisi arasında gerçekleşen görüşmelerde müşteri memnuniyetini olumsuz etkileyen münakaşa durumlarının otomatik olarak tespiti sağlanması önerilmiştir. AdresGezini A.Ş. bünyesindeki çağrı merkezi görüşmelerinden oluşturulan veri setinin MFCC öznitelikleri çıkarılmış ve CNN modeli bu özniteliklerle eğitilerek modelin başarısı değerlendirilmiştir. Önerilen yöntem ile çağrı merkezi görüşmelerini olumlu ve olumsuz olarak değerlendiren bir sistem oluşturularak firmaların müşteri memnuniyetini artırmak için kullanılması amaçlanmıştır.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir; 2. Bölümde çalışmada kullanılan veri seti, öznitelik çıkarımı ve derin öğrenme mimarisi açıklanmıştır. 3. Bölümde elde edilen sonuçlar açıklanmıştır. 4. Bölümde gerçekleştirilen çalışma özetlenmiş ve gelecek çalışmalara yer verilmiştir.

2. MATERYAL VE METOD (MATERIAL AND METHOD)

2.1. Veri Seti (Dataset)

Veri seti, şirket bünyesinde gerçekleştirilen çağrı merkezi görüşme kayıtlarından oluşmaktadır. Müşteri ve müşteri temsilcileri arasında gerçekleşen, uzunluğu 2 ile 5 dakika arasında değişen, içeriğinde küfür, hakaret, öfke gibi olumsuz duyguların bulunduğu farklı uzunluklardaki 100 görüşme kaydı kullanılarak oluşturulmuştur. Her bir görüşme birer saniye kaydırılarak oluşturulmuş üçer saniyelik ses kayıtlarına ayrılmıştır. Ardından üçer saniyelik bu kayıtlar münakaşa, küfür, hakaret içeriyorsa olumsuz, nötr veya olumlu seyir gösteren kayıtlar olumlu şeklinde etiketlenmiştir. Oluşturulan 3 saniyelik parçaların sadece çağrı merkezi çalışanı ve müşterinin aktif olarak konuştuğu kısımlardan veri seti oluşturulmuştur. 5408 adet olumlu 5003 adet olumsuz olarak ayrılan toplamda 10411 adet ses kaydı içeren bir veri seti elde edilmiştir.



Şekil 2. Modeller için eğitim ve doğrulama başarımı grafikleri Model 1 (a), Model 2 (b), Model 3 (c), modeller için eğitim ve doğrulama kaybı grafikleri Model 1 (d), Model 2 (e), Model 3 (f) (Training and validation performance graphs for models Model 1 (a), Model 2 (b), Model 3 (c), training and validation loss graphs for models Model 1(d), Model 2(e), Model 3(f))

2.2. Yöntem (Method)

2.2.1. Öznitelik Çıkarımı (Feature Extraction)

MFCC, sinyal işleme için popüler ve yüksek performanslı bir tekniktir. İnsan kulağının kritik frekans bant genişliğini temel almasıyla yaygın olarak kullanılan MFCC katsayıları, dijital ses işleme alanında önemli bir öznitelik çıkarma yöntemidir [4]. Sınırlı sayıda veriyle, frekans alanı özellikleri, ses sinyalinde potansiyel olarak sinyalin altında yatan duyguyu tanımlamamıza yardımcı olabilecek daha derin kalıpları ortaya çıkarır. MFCC öznitelik vektörleri oluşturulurken ilk olarak Hamming penceresi ile ses sinyalini küçük pencereler şeklinde tekrar şekillendirir ardından çerçevelere böler. Spektrum, Hızlı Fourier Dönüşümü ile her çerçeve için oluşturulur ve her biri filtre bankası kullanılarak ağırlıklandırılır. Ardından MFCC öznitelik vektörü Logaritma ve Ayrık Kosinüs Dönüşümü kullanılarak hesaplanır [20]. MFCC öznitelik vektörleri iki boyutlu matris veya ortalaması alınarak tek boyutlu matris şeklinde elde edilmektedir. Bu durum genellikle iki veya tek boyutlu matrislerin sınıflandırılması için kullanılan CNN modellerinde MFCC'lerin girdi olarak kullanılarak sınıflandırma çalışmaları yapılmasına imkan tanımaktadır. Bu kapsamda Python'ın Librosa kütüphanesi kullanılarak ses kayıtlarından elde edilen 2 boyutlu MFCC öznitelik matrisleri CNN modellerinde girdi verisi olarak kullanılmıştır. Veri seti içerisindeki ses kayıtlarının öznitelik sayısı literatürdeki çalışmaların başarıları dikkate alındığında 40 olarak belirlenmiştir [20, 21].

2.2.2. Derin Öğrenme Mimarisi (Deep Learning Architecture)

Evrişimli Sinir Ağı (Convolutional Neural Network (CNN)) ileri beslemeli yapay sinir ağıdır [22]. Çok sayıda

evrişimli katman, havuzlama ve tamamen bağlı katmanlar başta olmak üzere farklı katman türleri ile derin evrişimsel sinir ağı oluşturulur. Verinin öznitelikleri evrişim katmanında elde edilir. Evrişim katmanında, girdi verisi üzerinde öznitelikleri çıkaran birden çok filtre (kernel) kayar. Filtrelerin ve girdinin her elemanın elemana çarpımının toplamı bu katmanın çıktısı olan özellik haritasını verir. Evrişim katmanı, filtre boyutu, adım değeri (stride) ve dolgu (padding) ile özelleştirilebilir. Adım değeri filtrenin girdi verisi üzerinde kaç adım kaydırılacağını belirler. Dolgu ise evrişim katmanının çıktısı olan özellik haritasının boyutu ve orijinal girdi matrisinin boyutunu eşlemek için sıfırlardan oluşan satır ve sütunlar ekler. Sinir ağlarının yalnızca doğrusal bir fonksiyonu öğrenmesi ve hesaplaması değil aynı zamanda görüntü, video, ses, metin gibi kompleks veri türlerini modelleme görevini gerçekleştirilmesi amaçlanmaktadır. Bir yapay sinir ağına, girdiler ve çıktılar arasındaki doğrusal olmayan eşlemelerin öğrenilmesi ve anlamlandırılması için aktivasyon fonksiyonları önem taşımaktadır. Aktivasyon fonksiyonu, bir giriş sinyalini, sırayla yığındaki bir sonraki katmana girdi olarak beslenen bir çıkış sinyaline dönüştürmek için özel olarak kullanılır [23]. Ağırlıklara göre kayıpları hesaplayıp kaybın azaltılması için bir optimizasyon tekniği kullanılarak ağırlıkların optimize edilmesi gerekmekte olup optimizasyon tekniğinin uygulanması için aktivasyon fonksiyonun türevlenebilir olması gerekmektedir. Literatürdeki çalışmalarda Sigmoid, Tanh, ReLu (Rectified Linear Unit), SoftMax yaygın olarak kullanılan aktivasyon fonksiyonlarıdır [24]. Havuzlama katmanı önemli bilgileri koruyup gereksiz detayları azaltmasıyla özellik haritasının boyutunu küçültürken ağır hesaplama karmaşıklığını azaltır [25]. Tam bağlantılı katmanda sinir ağlarıyla öğrenme işlemi gerçekleştirilir. CNN modellerinin, bilgisayarlı görü alanında uygulamaları yaygın olarak kullanılmasının yanı

Tablo 1. Modellerin eğitim, doğrulama ve test başarıları
(Training, validation and test accuracy of models)

Model	Evrişim Katmanı Sayısı	En Yüksek Doğrulama Başarısı Tur Sayısı	Eğitim Başarısı	Doğrulama Başarısı	Test Başarısı	En Düşük Doğrulama Kaybı Tur Sayısı	Eğitim Başarısı	Doğrulama Başarısı	Test Başarısı
Model 1	1	149 (Şekil 2 (a))	0.918	0.782	0.364	61 (Şekil 2 (d))	0.858	0.775	0.542
Model 2	2	134 (Şekil 2 (b))	0.923	0.789	0.453	90 (Şekil 2 (e))	0.887	0.778	0.622
Model 3	3	83 (Şekil 2 (c))	0.898	0.785	0.524	55 (Şekil 2 (f))	0.861	0.773	0.694

sıra ses ve sinyal verileri üzerinde de etkili uygulamalar geliştirilmiştir [12-15].

Çalışmada veri seti olarak kullandığımız AdresGezini A.Ş. bünyesinde gerçekleştirilen çağrı merkezi görüşme kayıtlarından duyguyu tanımlamamıza yardımcı olabilecek daha derin kalıpları ortaya çıkarmak amacıyla MFCC öznitelikleri çıkarılmış olup 40x216 boyutundaki bu öznitelikler Şekil 1’de genel yapısı verilen CNN modelinin eğitim verisini oluşturmuştur.

Önerilen CNN mimarisinde, benzer şekilde yapılandırılmış üç evrişim katmanını iki tamamen bağlı katman izlemektedir. Tamamen bağlı katmandan gelen çıktı düzleştirme katmanı (flatten layer) ile tek boyutlu diziye çevrilir. Softmax aktivasyon fonksiyonlu sınıflandırma katmanı önceki katmalardan gelen girdilere bağlı olarak olumlu olumsuz olmak üzere iki sınıflı çıktı üretir. Her evrişim katmanının dolgu parametresi ‘same’, adım değeri 1, filtre boyutu (7,7) ve filtre sayısı 32 olarak belirlenmiştir. Evrişim katmanları boyunca ReLu aktivasyon fonksiyonu kullanılmıştır. Evrişim katmanlarını maksimum havuzlama katmanı takip etmektedir. Maksimum havuzlama katmanlarının çekirdek boyutu (kernel size) (5,5), dolgu ‘same’ şeklindedir. Düzleştirme katmanının bağlandığı Softmax katmanının olumlu ve olumsuz ses kayıtlarını sınıflandırmak için iki düğümü vardır. Önerilen modelin eğitim, doğrulama ve test verileri üzerindeki başarıları Bölüm 3’te açıklanmıştır.

3. SONUÇLAR VE TARTIŞMA (RESULT AND DISCUSSION)

Ses verisinden duyguyu tanımlamamıza yardımcı olabilecek daha derin kalıpları ortaya çıkarmak amacıyla MFCC öznitelikleri çıkarılarak 40x216 boyutundaki bu öznitelikler derin öğrenme mimarisinin eğitim verisi olarak kullanılmıştır. Az sayıdaki veri setiyle en yüksek doğruluktaki modeli elde etmek amacıyla model mimarisinde evrişim katmanlarının sayısı değiştirilerek oluşturulmuş farklı modeller eğitilmiştir. Deneysel çalışmaların gerçekleştirildiği bu modellerde sadece evrişim katmanlarının sayısı değişmekte olup model mimarisindeki tüm katmanlar ve parametreler sabit tutulmuştur. Model 1 tek evrişim katmanı, Model 2 iki evrişim katmanı, Model 3 üç evrişim katmanından oluşmakta olup bu katmanları maksimum havuzlama katmanları takip etmektedir. Her üç model MFCC

öznitelikleriyle eğitilmiş olup veri setinin %80’i eğitim %20’si doğrulama verisi olarak ayrılmıştır. Model eğitim parametreleri, eğitim tur sayısı (epoch) 200, öğrenme oranı (learning rate) 0,001, batch boyutu 32 ve Adam optimizasyon algoritması olarak belirlenmiştir. Ayrıca Tablo 1’de verilen üç model dışında dört ve beş evrişim katmanından oluşan modellerde eğitilmiş ve performansları değerlendirilmiştir. Modellerin eğitim süreçlerinin başlangıcından itibaren aşırı öğrenme (overfitting) gösterdiği gözlemlenmiştir. Veri setindeki örnek sayısının az olması nedeniyle dört ve beş evrişim katmanından oluşan modellerin veri setine göre karmaşık yapıda olduğu sonucuna varılmıştır.

Çalışmada CNN modeli ile çağrı merkezi kayıtlarının olumsuz ve olumlu olarak sınıflandırması önerilmekte olup modellerin bu sınıflandırma problemindeki performansları sınıflandırma doğruluğu (Denklem 1), hassasiyet (Denklem 2), duyarlılık (Denklem 3) ve F1-puanı (Denklem 4) ile değerlendirilmiştir.

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

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


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

$$\text{F1 Puanı} = 2x \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4)$$

DP (Doğru-Pozitif) ve DN (Doğru-Negatif) sırasıyla doğru tahmin edilen doğru pozitif ve doğru negatif çıktıların miktarını tanımlarken, YP (Yanlış-Pozitif) ve YN (Yanlış-Negatif) sırasıyla yanlış tahmin edilen yanlış pozitif ve yanlış negatif çıktılarının sayısıdır. Hassasiyet, duyarlılık ve F1-puanı, tahmin edilen pozitif ve negatif çıktılarının oranını hesaplayarak bir sınıflandırıcının performansını istatistiksel olarak değerlendirir. Hassasiyet, doğru tahmin edilen pozitiflerin toplam pozitif tahminlere oranıdır, duyarlılık ise doğru tahmin edilen pozitiflerin toplam gerçek pozitiflere ve yanlış negatiflere oranıdır. Son olarak, hassasiyet ve geri çağırmanın harmonik ortalaması, 1 en iyi ve 0 en kötü

olmak üzere $[0,1]$ arasında bir değere sahip F1-puanı verir.

Her üç modelin eğitim ve doğrulama başarısı 200 eğitim tur sayısı boyunca izlenmiş olup modellerin en yüksek doğrulama başarısı ve en düşük doğrulama kaybı gösterdiği tur sayısı, Şekil 2'de verilen eğitim, doğrulama başarısı ve kayıp grafiklerinde siyah nokta ile işaretlenmiştir. Eğitilen modellerin 200 eğitim tur sayısı boyunca en yüksek doğrulama başarısı ve en düşük doğrulama kaybının elde edildiği tur sayısındaki doğrulama başarıları Tablo 1'de verilmiş ve aynı katman sayısındaki modellerin farklı tur sayılarında kaydedilen başarıları karşılaştırılmıştır. Tablo 1'de görüldüğü üzere en yüksek doğrulama başarısının elde edildiği turdaki başarı değerleri ve en düşük doğrulama kaybının elde edildiği tur sayısındaki doğrulama başarılarının benzer olduğu gözlemlenmektedir. Fakat modellerin gerçek hayat problemlerindeki başarılarının karşılaştırılması için eğitim ve doğrulama veri setinde bulunmayan çağrı merkezi kayıtları ile test edilmiştir. Test veri seti 7 farklı çağrı merkezi kaydının üçer saniyelik kayıtlara bölünmesiyle elde edilmiş 3600 ses kaydı içermektedir. Test verisiyle gerçekleştirilen başarı değerlendirmesi sonucunda en düşük doğrulama kaybının elde edildiği tur sayısında kaydedilen modellerin test verisi üzerindeki sınıflandırma başarısının daha yüksek olduğu görülmüştür. Modellerin evrişim katmanı sayısına bağlı performansı incelendiğinde evrişim katmanı sayısındaki artış ile modelin test başarısının arttığı gözlemlenmiştir. Test verileri üzerinde gerçekleştirilen deneyler sonucunda üç evrişim katmanı içeren Model 3, 55 eğitim tur sayısında %69,4 ile en yüksek test başarısını vermiştir.



Şekil 3. Model 3 karmaşıklık matrisi
(Confusion matrix of Model 3)

Tablo 2'de Model 3'ün hassasiyet, duyarlılık, F1-puanı performans metrikleri ile değerlendirilmesi verilmiştir. Hassasiyet, duyarlılık ve F1-puan için ortalama 0.77 olmasına rağmen olumsuz ve olumlu sonuçları için değerler farklılık göstermektedir. Modelin sınıf bazında değerlendirilmesi Şekil 3'te verilen karmaşıklık matrisi ile açıklanmıştır. Karışıklık matrisi, doğru etiket ve tahmin etiketleri arasındaki ilişkiyi göstermektedir. Modelin doğrulama verisi üzerinden oluşturulmuş Şekil

3'teki karmaşıklık matrisinde Model 3'ün 1118 olumsuz olarak sınıflandırılan çağrı merkezi kayıtlarından 909 tanesini olumsuz olarak doğru bir şekilde sınıflandırdığı olumlu sınıftaki 1031 veriden ise 753'ünü olumlu olarak doğru bir şekilde sınıflandırdığı gözlenmektedir.

Tablo 2. Model 3'ün sınıflandırma başarısının hassasiyet, duyarlılık ve F1-puanı ile değerlendirilmesi (Evaluation of the Model 3 classification performance in terms of precision, recall and F1-score)

Sınıflar	Hassasiyet	Duyarlılık	F1-puanı
Olumsuz	0.76	0.81	0.79
Olumlu	0.78	0.73	0.76
Ağırlık Ortalama	0.78	0.78	0.78

Önerilen sistem Python programlama diliyle Tensorflow kütüphanesi için Keras arayüzü kullanılarak oluşturulmuştur. Verilerin düzenlenmesi için Numpy ve Pandas kütüphaneleri verilerin görselleştirmeleri için ise Matplotlib kütüphaneleri kullanılmıştır. Model eğitimleri, 16 çekirdekli 3.70GHz Intel(R) Xeon(R) W-2145 CPU, 64 GB 2666 MHz DDR4 RAM ve GeForce RTX 2080 8GB GPU'ya sahip bir Dell Precision 5820 iş istasyonunda gerçekleştirildi.

4. SONUÇ (CONCLUSION)

Gerçekleştirilen çalışma ile yoğun telefon görüşmelerinin gerçekleştirildiği çağrı merkezlerinde kayıt altına alınan telefon görüşmelerinin otomatik olarak analizi yapılarak, müşteri ve müşteri temsilcisi, arasında gerçekleşen görüşmelerde, müşteri memnuniyeti için çok büyük bir sorun teşkil eden olası münakaşa veya münakaşa benzeri duygu değişimlerinin otomatik olarak tespiti sağlanmaktadır. Münakaşa içeren görüşmelerin otomatik olarak tespiti yapıp kalite yöneticilerine bilgi verilerek anında duruma müdahale şansı oluşturulacak sistemin yapay zeka modelinin oluşturulması çalışmanın önemli bir özelliğidir. Çalışmanın başarısı literatürdeki [3, 5, 8] çalışmalarla kıyaslandığında çok yakın [5] veya daha yüksek [3, 8] başarı gösterdiği görülmektedir. Çağrı merkezi kayıtlarından oluşturulan veri seti ile eğitilmiş CNN modelinin doğrulama başarısının %77,3 olması ve eğitim sonuçlarına ek olarak çağrı merkezi görüşmeleri üzerinde yapılan testlerde sistemin başarısının kullanılan az sayıda veriye rağmen %69,4 olması sistemin kullanılabilirliği açısından önem arz etmektedir. Ayrıca çağrı merkezi kayıtlarından oluşturulan özel Türkçe veri seti de çalışmanın özgünlüğünü göstermektedir. Veri seti büyüklüğü ile başarı oranı genellikle artma eğiliminde olduğu göz önünde bulundurularak ilerleyen çalışmada kullanılan veri setinin çağrı merkezi kayıtları ile genişletilmesiyle başarının artırılması ve konuşmacı tanıma çalışması gerçekleştirilerek konuşmadaki olumsuzluğun müşteri veya çağrı merkezi çalışanından mı kaynaklı olduğunun belirlenmesi hedeflenmektedir.

5. TEŞEKKÜR (ACKNOWLEDGEMENT)



Çalışma TÜBİTAK TEYDEB 1501 programıyla desteklenmekte olan 3200788 numaralı “Olumsuz Çağrı Merkezi Görüşmelerinin Derin Yapay Sinir Ağları Tabanlı Sınıflandırma Algoritmaları ile Otomatik Tespitini Sağlayan Sistemin Geliştirilmesi” adlı proje kapsamında geliştirilmiştir.

KAYNAKLAR (REFERENCES)

- [1] B. Özlan, A. Haznedaroğlu, L. M. Arslan. "Automatic fraud detection in call center conversations", **Signal Processing and Communications Applications Conference (SIU)**, Sivas, Türkiye, 27, 2019.
- [2] L. O. İheme, Ş. Ozan, "A novel semi-supervised framework for call center agent malpractice detection via neural feature learning", *Expert Systems with Applications*, 118173, 2022.
- [3] D. Pappas, I. Androusoyopoulos, H. Papageorgiou, "Anger Detection in Call Center Dialogues", **6th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)**, Macaristan, 139-144, 2015.
- [4] Ş. Ozan, "Classification of Audio Segments in Call Center Recordings using Convolutional Recurrent Neural Networks", *arXiv preprint arXiv:2106.02422*, 2021.
- [5] D. Turnbull, C. Elkan, "Fast Recognition of Musical Genres Using RBF Networks", *IEEE Transactions on Knowledge and Data Engineering*, 17(4), 580-584, 2005.
- [6] L. O. İheme, Ş. Ozan, "Multiclass Digital Audio Segmentation with MFCC Features using Naive Bayes and SVM Classifiers", **Innovations in Intelligent Systems and Applications Conference (ASYU)**, İzmir, Türkiye, 1-5, 2019.
- [7] M. S. Likitha, S. S. R. Gupta, K. Hasitha, A. U. Raju, "Speech Based Human Emotion Recognition using MFCC", **International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)**, Hindistan, 2257-2260, 2017.
- [8] A. Milton, S. S. Roy, S. T. Selvi, "SVM Scheme for Speech Emotion Recognition using MFCC Feature", *International Journal of Computer Applications*, 69(9),34-39, 2013.
- [9] V. B. Waghmare, R. R. Deshmukh, P. P. Shrishrimal, G. B. Janvale, "Emotion Recognition System from Artificial Marathi Speech using MFCC and LDA Techniques", **Fifth International Conference on Advances in Communication, Network, and Computing-CNC**, Hindistan, 2014.
- [10] S. Demircan, H. Kahramanlı, "Feature Extraction from Speech Data for Emotion Recognition", *Journal of Advances in Computer Networks*, 28-30, 2014
- [11] N. J. Nalini, S. Palanivel, "Music emotion recognition: The combined evidence of MFCC and residual phase", *Egyptian Informatics Journal*, 17(1), 1-10, 2016.
- [12] W. Lim, D. Jang, T. Lee. "Speech Emotion Recognition using Convolutional and Recurrent Neural Networks", **Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)**, Kore 1-4, 2016.
- [13] J. Zhao, X. Mao, L. Chen, "Speech Emotion Recognition using Deep 1D & 2D CNN LSTM Networks", *Biomedical Signal Processing and Control*, 47, 312-323, 2019.
- [14] S. Latif, R. Rana, S. Khalifa, R. Jurdak, J. Epps, "Direct Modelling of Speech Emotion from Raw Speech", *arXiv preprint ArXiv:1904.03833*, 2019.
- [15] J. Wang, M. Xue, R. Culhane, E. Diao, J. Ding, V. Tarokh, "Speech Emotion Recognition with Dual-Sequence LSTM Architecture", **ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**, 6474-6478, 2020.
- [16] S. K. Pandey, H. S. Shekhawat, S. R. M. Prasanna, "Deep Learning Techniques for Speech Emotion Recognition: A Review", **29th International Conference Radioelektronika (RADIOELEKTRONIKA)**, Çek Cumhuriyeti, 1-6, 2019.
- [17] F. Burkhardt, A. Paeschke, M. Rolfes, W. Sendlmeier, B. Weiss "A Database of German Emotional Speech", *Interspeech*, 1517-1520, 2005.
- [18] S. Wu, T. H. Falk, W. Y. Chan, "Automatic Speech Emotion Recognition using Modulation Spectral Features", *Speech Communication*, 53(5), 768-785, 2011.
- [19] M. Grimm, K. Kroschel, S. Narayanan, "The Vera am Mittag German Audio-Visual Emotional Speech Database", **IEEE International Conference on Multimedia and Expo**, Almanya, 865-868, 2008.
- [20] M. Yıldırım, "MFCC Yöntemi ve Önerilen Derin Model ile Çevresel Seslerin Otomatik Olarak Sınıflandırılması", *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 449-457, 2022.
- [21] M. Scarpiniti, D. Comminiello, A. Uncini, Y. C. Lee" Deep Recurrent Neural Networks for Audio Classification in Construction Sites" **28th European Signal Processing Conference (EUSIPCO)**, Hollanda, 810- 814, 2020.
- [22] S. K. Roy, G. Krishna, S. R. Dubey, B. B. Chaudhuri, "HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification", *IEEE Geoscience and Remote Sensing Letters*, 17(2), 277-281, 2019.
- [23] H. Wang, J. Zhou, C. Gu, H. Lin, "Design of Activation Function in CNN for Image Classification", *Journal of Zhejiang University (Engineering Science)*, 53(7), 1363-1373, 2019.
- [24] Y. Wang, Y. Li, Y. Song, X. Rong, "The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition", *Applied Sciences*, 10(5), 1897, 2020.
- [25] M. A. Kızrak, B. Bolat, "Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma", *Bilişim Teknolojileri Dergisi*, 11(3), 263-286, 2018.

Konvolüsyonel Sinir Ağları Tabanlı Türkçe Metin Sınıflandırma

Araştırma Makalesi/Research Article

 Güler ALPARSLAN¹,  Mahir DURSUN²

¹Bilişim Enstitüsü, Gazi Üniversitesi, Ankara, Türkiye

²Teknoloji Fakültesi, Gazi Üniversitesi, Ankara, Türkiye

guler.alparslan@gazi.edu.tr, mdursun@gazi.edu.tr

(Geliş/Received:22.08.2022; Kabul/Accepted:09.12.2022)

DOI: 10.17671/gazibtd.1165291

Özet— Bu çalışmada makine öğrenmesi teknikleri ve konvolüsyonel sinir ağları (KSA) tabanlı bir derin öğrenme modeli kullanılarak iki farklı Türkçe metin veri kümesi sınıflandırılmıştır. Metin sınıflandırma çalışmasında Rastgele Orman (RO), Naive Bayes (NB), Destek Vektör Makineleri (DVM), K-En Yakın Komşu (KNN) Algoritmaları ve geliştirilen KSA tabanlı derin öğrenme modeli seçilen veri kümelerine uygulanmıştır. Türkçe dilinde seçilen veri kümeleri, metin ve sınıf adedi olarak birbirinden farklı yapıda tercih edilmiş böylece kelime vektör boyutunun aynı deney ortamında sınıflandırma başarısına etkisi araştırılmıştır. Kelime temsil yöntemi olarak Terim Frekansı-Ters Doküman Frekansı (TF-IDF) belirlenmiş olup, sınıflandırma işlemi öncesi veri kümelerine uygulanan durdurma kelimeleri filtreleme ve kök bulma işlemlerinin de sınıflandırma sonuçlarına katkısı değerlendirilmiştir. Ayrıca kelime temsil vektörlerine öznitelik seçimi uygulanarak boyutları düşürülmüş, böylece nihai vektör boyutunun da sonuçlara etkisi araştırılmıştır. Bahsedilen tüm ön işlemlerin farklı birleşimleri uygulanarak ortaya çıkan kelime vektörlerinin sınıflandırması sonucunda doğruluk ve F1-skor değerleri karşılaştırılmıştır. Karşılaştırmalar her bir sınıflandırma algoritması özelinde ayrı tablolar halinde sunulmuştur. Ayrıca tüm algoritmaların birbiri ile karşılaştırmasını içeren tablolar oluşturularak sonuçlar analiz edilmiştir.

Anahtar Kelimeler: metin sınıflandırma, makine öğrenmesi, derin öğrenme, konvolüsyonel sinir ağları

Convolutional Neural Networks Based Turkish Text Classification

Abstract— In this study, a text classification has been carried out on two different Turkish datasets using machine learning techniques and a deep learning model based on convolutional neural networks (CNN). In the text classification study, Random Forest, Naive Bayes, Support Vector Machines, K-Nearest Neighbor algorithms and a CNN based deep learning model were used. The datasets selected in Turkish are different from each other in terms of the number of texts and the number of classes. In this way, the effect of word embedding size on classification success was investigated. As a word embedding method, we preferred Term Frequency-Inverse Document Frequency (TF-IDF). The effects of the stopwords eliminating and lemmatizing pre-processes applied before the classification study, on the classification success was also evaluated. In addition, the size of the word embeddings was reduced by applying feature selection, and the effect of the final vector size on the results was investigated. The accuracy and F1-score values were compared as a result of the classification of the feature vectors by applying different combinations of the pre-processes. The comparisons are represented in separate tables for each classification algorithm used. In addition, F1-score comparison tables of the algorithms with each other are presented and the values were analyzed.

Keywords: text classification, machine learning, deep learning, convolutional neural networks

1. GİRİŞ (INTRODUCTION)

Otomatik metin sınıflandırma haber yazılarının etiketlenmesinde, doküman yazarının tespitinde, e-posta sınıflandırma, istenmeyen e-posta tespiti gibi alanlarda yaygın olarak kullanılmaktadır. Metnin içeriğindeki kelimeler ve bunların kullanılma sıklığına göre sınıfının belirlenme işlemi olarak tanımlanan metin sınıflandırma, günümüz teknolojisinde artan veri boyutuyla birlikte manuel olarak yapılması zor bir işlem haline gelmiştir. Bu durum metin sınıflandırma işleminin otomatik yapılmasını gerekli kılmıştır.

Metin sınıflandırma konusunda yapılmış birçok çalışma mevcuttur. Yaygın olarak kullanılan sınıflandırma yöntemleri; Destek Vektör Makineleri, Naive Bayes, Karar Ağaçları, K-En Yakın Komşu Modeli, Yapay Sinir Ağları, Maksimum Entropi Modelleri, Bulanık Mantık Teorisi Yaklaşımları ve Derin Öğrenme algoritmalarıdır [1].

Makine öğrenmesi, sınıflandırma, modelleme ve tahmin gibi günlük hayattaki birçok problemin çözümünde başarılı sonuç veren yöntemler içerir. Destek Vektör Makineleri, Naive Bayes ve K-En Yakın Komşu algoritmaları ile yapılmış sınıflandırma karşılaştırmaları içeren birçok çalışma bulunmaktadır. Makine öğrenmesi yöntemlerinden denetimli bir öğrenme algoritması olan Rastgele Orman (RO), metin sınıflandırmadaki gibi yüksek boyutlu verilerin sınıflandırması için uygun bir algoritmadır. Liu ve arkadaşları, yaptıkları çalışmada metin sınıflandırma için Semantiğe Duyarlı Rastgele Orman (SARF) sınıflandırıcı önermişlerdir. SARF'ın sınıflandırma performansını 30 adet metin veri kümesi üzerinde değerlendirerek güncel sınıflandırma yöntemleriyle karşılaştırmış, önerilen yaklaşımın üstün performansını gözlemlemişlerdir [2, 3].

Üzerinde çalışılan veri kümesine uygulanan ön işlemler sınıflandırma başarısını büyük ölçüde etkilemektedir. Bu amaçla yapılmış birçok çalışma mevcuttur. Sınıflandırma sırasındaki hesaplama karmaşıklığını azaltmak ve analitik performansı artırmak amacıyla, sınıflandırma başarısına en çok katkı sağlayan özniteliklerin belirlenmesi gerekmektedir. Bu amaçla genetik algoritma optimizasyonu ile öznitelik seçimi yöntemi uygulayan çalışmalar, metindeki tüm özniteliklerin kullanıldığı çalışmalardan daha yüksek bir sınıflandırma başarısı göstermişlerdir [2, 3]. Veri kümesinin alt uzay boyutunu azaltma amacıyla tasarlanan kaotik optimizasyon algoritmasına dayalı metin sınıflandırma modelleri ile, az sayıda öznitelikle daha iyi sınıflandırma performansı elde eden çalışmalar da mevcuttur [4, 5].

Metin sınıflandırmada en önemli çalışma alanlarından ikisi istenmeyen e-posta tespiti ve doküman yazar tespitidir. Makine öğrenmesi algoritmaları ile e-posta sınıflandırma yapan birçok çalışma bulunmaktadır. E-posta içerisinde geçen ve birden fazla anlama gelen kelimeler/cümleler istenmeyen e-posta tespitini oldukça zorlaştırmakta, bu zorlukla mücadele etmek için Naive

Bayes algoritması kullanılabilir [6]. Benzer şekilde doküman/metin yazarı tespitinde de Naive Bayes algoritması oldukça etkindir. Özellikle sosyal medya hesaplarından paylaşılan yazıların sahibinin tespitinde önemli bir role sahiptir [7].

Bu çalışmada ise klasik makine öğrenmesi algoritmaları ile konvolüsyonel sinir ağları (KSA) tabanlı bir derin öğrenme modeli kullanılarak iki farklı veri kümesinde sınıflandırma yapılmıştır. Türkçe dilinde seçilen veri kümeleri, metin ve sınıf adedi olarak birbirinden farklı yapıda tercih edilmiş böylece kelime vektörü boyutunun aynı deney ortamında sınıflandırma başarısına etkisi gözlemlenebilmiştir. Ayrıca bu çalışma, sınıflandırma işlemi öncesi veri kümelerine uygulanan üç farklı ön işlemin de başarıya katkısını değerlendirmek adına önemli bir çalışmadır. Kelime vektörlerine öznitelik seçimi uygulanarak boyut azaltılmış, nihai vektör boyutunun da sonuçlara etkisi böylece gözlemlenebilmiştir. Bahsedilen tüm ön işlemlerin farklı birleşimleri ile ortaya çıkan kelime vektörlerine; Rastgele Orman, Naive Bayes, Destek Vektör Makineleri, K-En Yakın Komşu Algoritmaları ve KSA tabanlı derin öğrenme modeli uygulanarak sınıflandırma doğruluk oranları ve F1-skor değerleri karşılaştırılmıştır.

Çalışmanın devamı şu şekilde düzenlenmiştir. İkinci bölümde ilgili çalışmalar sunulmuş, üçüncü bölümde metin sınıflandırma ana hatları ile anlatılarak başlıca metin sınıflandırma ön işlemleri açıklanmıştır. Dördüncü bölümde metin sınıflandırmada kullanılan makine öğrenmesi ve derin öğrenme algoritmaları tanıtılmış, beşinci bölümde sınıflandırma ölçütleri tanımlanmıştır. Altıncı bölümde tasarlanan KSA tabanlı derin öğrenme modeli açıklanmış, yedinci bölümde çalışmada kullanılan veri kümesi tanıtılmıştır. Sekizinci bölümde deneysel sonuçlara, dokuzuncu bölümde ise çalışmanın sonuçlarına yer verilmiştir.

2. İLGİLİ ÇALIŞMALAR (RELATED WORK)

Türkçe metinlerin sınıflandırılması konusunda literatürde kısıtlı sayıda çalışma bulunmaktadır. Türkçe'nin morfolojik yapısı itibarıyla diğer dillerden farklı olması, eş sesli kelimelerin fazla miktarda bulunması, anlam darlıkları, özel karakterler, özellikle de sondan eklemeli diller kategorisinde olması sebebiyle metin sınıflandırmada bazı zorluklara sebep olmaktadır. Bir başka problem ise, sonuna eklenen ekler sebebiyle aynı kelimelerin farklı birer öznitelik gibi algılanması, böylece kelime temsil vektörünün boyutunun çok yükselmesidir. Bu da sınıflandırma performansını ve başarısı önemli ölçüde düşürmektedir. Yine de bu zorlukları veri madenciliği ön işlemleri ile aşan, farklı sınıflandırma modelleri ile destekleyen Türkçe metin sınıflandırma konusunda değerli çalışmalar bulunmaktadır.

Acı ve Çırak, Word2Vec metodu ile zenginleştirerek kullandıkları Konvolüsyonel Sinir Ağları (KSA) modelinden elde ettikleri sonuçları, Kılınc ve arkadaşları [8] tarafından yapılmış olan klasik istatistiksel ve makine

öğrenmesine dayalı sınıflandırma çalışması sonuçları ile karşılaştırmışlardır. Karşılaştırma sonucunda daha yüksek doğruluk oranıyla (%93,3) Türkçe haber metinlerinin sınıflandırmasını gerçekleştirmişlerdir [9].

Uçan ve arkadaşları ise yapmış oldukları çalışmada Türkçe sosyal medya metinlerini içerdikleri duyguya göre sınıflandırmışlardır. Deneysel çalışma sonuçlarına göre, önerdikleri ön eğitilmiş duygu modelinin önceki çalışmalarda kullanılan yöntemlere göre en yüksek başarı oranına sahip olduğu görülmüştür [10].

Aydoğan ve Karıcı, eğitim ve sınıflandırma işlemlerinde kullanılmak üzere iki büyük Türkçe veri kümesi oluşturmuş, çeşitli derin öğrenme yöntemleri ile yaptıkları sınıflandırma işlemlerinin sonuçlarını karşılaştırmışlardır. Deneysel sonuçlara göre GRU ve LSTM yöntemlerinin diğer derin öğrenme modellerinden daha başarılı olduğu görülmüştür. Ayrıca ön eğitilmiş kelime vektörlerinin sınıflandırma doğruluk oranını %5-%7 oranında arttırdığı tespit edilmiştir [11].

Toroslu ve Karagöz ise çalışmalarında bireylerin sosyal medya mesajları ile beş büyük kişilik özelliği arasındaki ilişkiyi denetimli bir öğrenme problemi olarak modellemeyi amaçlamışlardır. Türkçe ve İngilizce iki ayrı veri kümesi üzerinde yaptıkları deneysel sonuçlarda, yapay sinir ağları yaklaşımının kişilik tahmini için başarılı bir şekilde kullanılabileceğini, vektör tabanlı sınıflandırma modellerine benzer bir performansla çalıştığını göstermişlerdir [12].

Yıldırım ve Yıldız, Türkçe haber metinleri üzerinde yaptıkları sınıflandırma çalışmasında, geleneksel kelime torbası yöntemi ile sinir ağı temelli kelime temsil yöntemlerinin başarı oranlarını karşılaştırmışlardır. Deneysel sonuçlarda kelime temsil vektörlerinin oluşturulmasında kullanılan geleneksel yöntemlerin hala yeni nesil yöntemlerle yarışacak düzeyde sınıflandırma başarısı sağladığını göstermişlerdir [13].

Köksal ve Yılmaz, literatürde yaygın şekilde kullanılan iki Türkçe haber veri kümesi üzerinde hem klasik makine öğrenme algoritmaları hem de güncel ön eğitilmiş dil modellerini kullanarak metin sınıflandırma çalışması yapmışlardır. Yapmış oldukları çalışmada sınıflandırma modellerinin parametre seçimi ve optimizasyonu üzerine yoğunlaşarak başarılı sonuçlar elde etmişlerdir. Ön eğitilmiş dil modelleri ile yapılan sınıflandırma sonuçları, aynı veri kümesini kullanan benzer çalışmalardan daha yüksek F1 skoru elde etmiştir [14].

3. METİN SINIFLANDIRMA (TEXT CLASSIFICATION)

Metin sınıflandırma araştırmasında kullanılabilecek veriler haber siteleri, online alışveriş platformları, sanal olarak yayınlanan dergiler gibi birçok kaynaktan elde edilebilir. Yapılacak araştırmanın doğruluğunu test

edebilmek için metnin kategorisinin etiketler, anahtar kelimeler ile belirtilmiş olması gereklidir.

Metinler ham veri olarak doğrudan sınıflandırma algoritmasında kullanılmamakta, belirli ön işlemlerden geçirilerek öznitelik vektörüne dönüştürülmektedir. Metinlerin öznitelik vektörüne dönüştürülmesinin başarısı doğrudan sınıflandırma başarısını etkilemektedir.

Metin sınıflandırma alanındaki veri kümeleri diğer birçok veri kümesi ile karşılaştırıldığında öznitelik vektör boyutunun çok yüksek (binler mertebesinde) olduğu görülmektedir. Metinlerde geçen her bir kelime birer öznitelik olarak kullanılırsa ortaya sınıflandırma algoritmasının performansını önemli ölçüde düşürecek, hesaplama karmaşıklığına sebep olacak kadar fazla sayıda öznitelik çıkacaktır. Öznitelik vektör boyutu optimum seviyeye çekilerek hesaplama performansının ve sınıflandırma başarısının artırılması amacıyla birçok yöntem kullanılabilmektedir. Sıklıkla kullanılan metin sınıflandırma ön işlemleri aşağıda açıklanmaktadır.

3.1. Kök Bulma (Stemming)

Kök bulma (stemming) işlemi, metinde geçen kelimelerin kelime köklerini bularak kullanılması ön işlemidir. Bu sayede birbirinden farklı ekler ile farklı bir kelimeymiş gibi görünen kelimelerin aynı sayılması sağlanmaktadır. Özellikle sondan eklemeli bir dil olan Türkçe metinlerde düşünülecek olursa, öznitelik vektör boyutunun azaltılması ve daha anlamlı vektör ortaya çıkarılması açısından kritik bir ön işlemdir. Otomatik kök bulma işleminde dilin özelliklerine göre Zemberek doğal dil işleme kütüphanesi, sözcük eklerini sondan başa doğru sıyrarak çıkarma (affix stripping) ve sözcüklerin ilk n karakterinin kelime kökü olduğunu kabul etme (fixed prefix stemming) yaklaşımlarıyla geliştirilmiş kütüphaneler kullanılabilmektedir.

3.2. Durdurma Kelimeleri Filtreleme (Stopword Filtering)

Durdurma kelimeleri (DK) filtreleme işlemi, metnin sınıflandırmasında etkisiz olan, genellikle tek başın anlamsız ancak çok sık kullanıldığı için frekansı yüksek "ve", "ile", "ya da" vb. kelimelerin işlem dışı bırakılmasıdır. Durdurma kelimeleri her sınıftaki metinde çok sayıda ve benzer sıklıkta kullanıldığı için sınıf belirlenmesinde etkin bir rol oynamadığı gibi öznitelik vektör boyutunu da gereksiz yere büyütülmektedir. Bu sebeple durdurma kelimelerinin filtrelenmesi yaygın şekilde kullanılan ön işlemlerden biridir.

3.3. Terim Frekansı-Ters Doküman Frekansı (Term Frequency-Inverse Document Frequency)

Terim frekansı (term frequency-TF), metinde geçen her bir kelimenin metindeki kullanılma sıklığının bulunması ön işlemidir. Dokümandaki her bir terimin o dokümanda geçme adedi ile dokümandaki bütün terimlerin toplam adedine oranı şeklinde hesaplanmaktadır.

$$TF = \frac{\text{Terimin dokümanda geçme adedi}}{\text{Dokümandaki toplam terim adedi}} \quad (1)$$

Ters doküman frekansı değeri, bir terimin arandığı tüm dokümanların sayısının, o terimin bulunduğu dokümanların sayısına oranıdır. Terim ne kadar az dokümanda tekrar ediyor ise IDF değeri o kadar büyük çıkar.

$$IDF = \frac{\text{Toplam doküman sayısı}}{\text{Terimin geçtiği doküman sayısı}} \quad (2)$$

Doküman sınıflandırmada sık kullanılan önışlemlerden biri olan Terim Frekansı-Ters Doküman Frekansı (TF-IDF), her bir terim için terim frekansı ile ters doküman frekansının çarpımından elde edilir. Bir terimin bulunduğu dokümanın sınıflandırmasına katkı sağlamadaki önemini gösterir.

$$TF-IDF = TF * IDF \quad (3)$$

3.4. Word2Vec (Word2Vec)

Word2Vec, Yapay Sinir Ağları (YSA) tabanlı bir kelime vektörü temsil yöntemidir. Bu yöntem sayesinde kelimeler vektörlere dönüştürülerek aralarındaki uzaklıklar hesaplanıp kelimeler arasında analogi kurulabilmektedir. Word2Vec yöntemi son yıllarda metin sınıflaması konusunda oldukça popüler olmuştur. Birçok çalışmada sınıflama yöntemleri uygulanmadan önce Word2Vec kullanılarak veri kümesi zenginleştirilmiş ve metin verileri vektörel hale getirilmiştir [9].

Word2vec yönteminde, Continuous Bag of Words (CBOW) ve Skip-Gram olmak üzere iki alt yöntem kullanılmaktadır. CBOW modelinde her bir kelime, komşu kelimeleri girdi alınarak tahmin edilmeye çalışılır. Skip-Gram modelinde ise her bir kelime girdi alınarak ilgili kelimenin komşu kelimeleri tahmin edilir.

3.5. N-Grams (N-Grams)

Metin sınıflandırma önışlemi olarak kullanılan bir diğer yöntem olan N-Grams yöntemi, incelenen metinde geçen kelimeleri belirlenen pencere boyutunda birlikte gruplandırarak sınıflandırma işlemine girdi sağlar. Unigram 1 kelimelik grupları, bigrams 2 kelimelik grupları, trigrams 3 kelimelik grupları, n-grams ise 3'ten fazla belirlenen n sayısına kelimelik grupları ifade eder.

Örnek olarak “beğenmedim çünkü çalışırken çok gürültü çıkarıyor” cümlesi bigram olarak bölünmek istenirse aşağıdaki vektör elde edilecektir.

“beğenmedim çünkü çalışırken çok gürültü çıkarıyor”:
[“beğenmedim çünkü”, “çünkü çalışırken”, “çalışırken çok”, “çok gürültü”, “gürültü çıkarıyor”]

3.6. Öznitelik Seçimi (Feature Selection)

Öznitelik seçimi, kullanılan veri kümesinin özniteliklerinden sınıflandırma başarısına en fazla katkı sağlayanların tespit edilip seçilmesi işlemidir. Öznitelik seçimindeki amaç, sınıflandırma başarısını yükseltmek veya eğitim süresini kısaltarak çalışma performansını arttırmaktır. Metin veri kümelerinin öznitelik sayısının yüksek olması sebebiyle, metin sınıflandırmada kritik bir önışlem olarak sıklıkla kullanılmaktadır.

Öznitelik seçimi işleminde; filtreleme, sarmalama ve gömülü yöntemler kategorilerinde çeşitli algoritmalar bulunmaktadır. Bunlardan öznitelik ve sınıf değışken tiplerine uygun olacak şekilde en yaygın kullanılan yöntemler; Pearson korelasyonu, Ki-kare testi, Anova testi ve Bilgi kazanımı yöntemleridir.

4. METİN SINIFLANDIRMADA KULLANILAN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME ALGORİTMALARI (MACHINE LEARNING AND DEEP LEARNING ALGORITHMS USED IN TEXT CLASSIFICATION)


Metin sınıflandırma çalışmalarında sık uygulanan makine öğrenmesi tekniklerinden bazıları: Rastgele Orman, Naive Bayes, Destek Vektör Makineleri, K-En Yakın Komşu Algoritması ve Derin Öğrenme modelleridir.

4.1. Naive Bayes

Hızlı ve kolay uygulanabilir olduğu için metin sınıflandırması işleminde tercih edilen Naive Bayes algoritması, olasılıkçı yaklaşımla sınıflandırma yapan makine öğrenmesi yöntemlerinden biridir [2]. Bu yöntemde tüm özniteliklerin ait olduğu sınıfa göre koşullu olasılığı bulunarak test verisinin sınıfı en yakın olasılıkla tespit edilmektedir.

4.2. K-En Yakın Komşu Modeli (K-Nearest Neighbor Model)


K-En Yakın Komşu (KNN) algoritmasında test örneklerinden biri seçilip, k değerine göre o örneğe en yakın örnek veya örneklerdeki sınıf belirlenerek sınıflandırma işlemi yapılmaktadır. En yakın komşu veya komşuların tespit edilebilmesi için seçilen test örneğinin tüm diğer örneklere uzaklığı hesaplanmalıdır [15]. Örneğin k=5 değeri kullanılarak uygulanan K-En Yakın Komşu Algoritması Şekil 1'de görülmektedir [16]. En yakın 5 örnekten 4'ü A sınıfına ait olduğu için bilinmeyen örneğin sınıfı A olarak tespit edilir.



Şekil 1. k=5 için k-en yakın komşu algoritması
(K-nearest neighbor algorithm with k=5)

4.3. Destek Vektör Makineleri (Support Vector Machines)

1992 yılında tanıtılan destek vektör makineleri (DVM), istatistiksel bilgi teorisine ve yapısal risk minimizasyonuna dayalı denetimli bir sınıflandırma algoritmasıdır [8].



Şekil 2. Destek vektör makineleri
(Support vector machines)

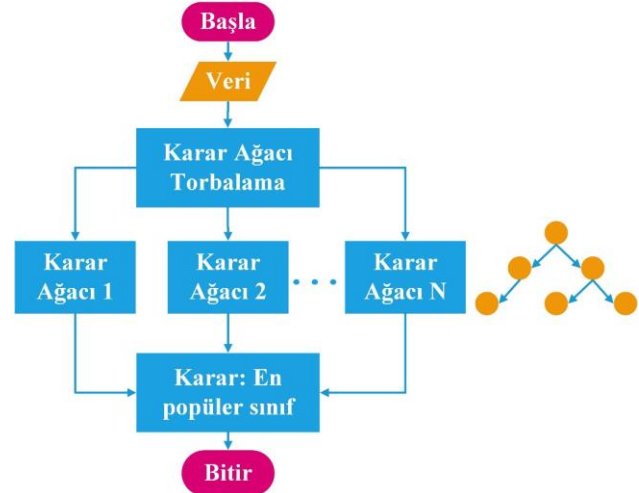
Veri kümesindeki sınıflar arasındaki ayrımı en iyi belirten doğru veya hiper düzlemlerin belirlenmesi yoluyla DVM modeli uygulanır. Örnek bir DVM gösterimi Şekil 2'de görülmektedir.

4.4. Rastgele Orman Algoritması (Random Forest Algorithm)

Rastgele Orman (RO) algoritması karar ağacı sınıflandırıcılarından biri olarak kabul edilen denetimli bir makine öğrenmesi algoritmasıdır. Breiman tarafından bulunan sınıflandırma algoritması birden fazla karar

ağacını birlikte kullanıp bunları oylayarak en uygun çözümü bulmayı hedefler [17]. Algoritmik basitliği ve yüksek boyutlu veriler için belirgin sınıflandırma performansı nedeniyle, rastgele orman, metin sınıflandırması için popüler bir yöntem haline gelmiştir [5].

Rastgele orman, torbalama ve karar ağacı algoritmalarının birleşimi olarak tanımlanabilir. Rastgele orman algoritması işleyişi Şekil 3'te görülmektedir [18].




Şekil 3. Rastgele orman algoritması
(Random forest algorithm)

4.5. Derin Öğrenme Modelleri (Deep Learning Models)

Yapay sinir ağları, beyindeki nöronların bağlantılarını ve fonksiyonunu benzetme yoluyla geliştirilen, test kategorisindeki en gelişmiş sınıflandırıcılardan biridir. Yapay sinir ağı; giriş katmanı, gizli/ara katman ve çıktı katmanı olarak üç katmandan oluşur [19]. Yapılandırılmamış veriyi girdi olarak alır, nöronlardan oluşan katmanlarda işleyerek çıktı verir. Katman ve nöron sayısı arttıkça daha karmaşık problemleri çözebilir. Yapay sinir ağları işleyişi Şekil 4'te görülmektedir.

Yapay sinir ağları katmanlarında birden fazla gizli katman kullanıldığında derin öğrenme modeli oluşturulmuş olur. Derin öğrenme modelleri üç ana başlıkta toplanabilir: Çok Katmanlı Algılayıcılar (MLP-Multilayer Perceptrons), Konvolüsyonel Sinir Ağı (CNN-Convolutional Neural Networks) ve Tekrarlayan Sinir Ağı (RNN-Recurrent Neural Networks).



Şekil 4. Yapay sinir ağları katmanları
(Artificial neural networks layers)

5. SINIFLANDIRMA ÖLÇÜTLERİ (CLASSIFICATION METRICS)

Sınıflandırma modellerinin yapmış olduğu tahminlerin başarısını ölçmek için çeşitli sınıflandırma ölçütleri kullanılmaktadır. Sınıflandırma başarısını ölçen sınıflandırma ölçütleri karışıklık matrisindeki değerlerden hesaplanır ve sıklıkla kullanılanlar doğruluk, kesinlik, duyarlılık ve F1-skoru değerleridir.

5.1. Karışıklık Matrisi (Confusion Matrix)

Karışıklık matrisi, bir sınıflandırma işlemindeki tüm doğru ve yanlış tahminlerin sınıflara sayısal dağılımını gösteren matris gösterimidir. “Pozitif” ve “Negatif” sınıflarından oluşan bir sınıflandırma işlemi sonucu örnek bir karışıklık matrisi Tablo 1’de görülmektedir.

Tablo 1. Örnek karışıklık matrisi
(Confusion matrix sample)

Pozitif	Negatif	Tahmin Sınıf
DP	YN	Pozitif
YP	DN	Negatif

Karışıklık matrisinde, DP doğru tahmin edilen “Pozitif” sayısını, DN doğru tahmin edilen “Negatif” sayısını, YP yanlış tahmin edilen “Pozitif” sayısını ve YN yanlış tahmin edilen “Negatif” sayısını göstermektedir. Diğer sınıflandırma ölçütleri bu değerler kullanılarak hesaplanmaktadır.

5.2. Doğruluk (Accuracy)

Doğruluk, sınıflandırma işlemi sonucundaki bütün tahminlerdeki doğru tahmin oranı olarak tanımlanmaktadır. Doğruluk değerinin matematiksel hesabı aşağıdaki eşitlikte görülmektedir.

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

5.3. Kesinlik (Precision)

Kesinlik, sınıflandırma işlemi sonucundaki “Pozitif” olarak tahmin edilenlerin hangi oranda gerçekten “Pozitif” sınıfına ait olduğunu gösteren sınıflandırma ölçütüdür. Kesinlik değerinin matematiksel hesabı aşağıdaki eşitlikte görülmektedir.

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

5.4. Duyarlılık (Recall)

Duyarlılık, “Pozitif” sınıftaki örneklerin hangi oranda “Pozitif” olarak tahmin edildiğini gösteren sınıflandırma ölçütüdür. Duyarlılık değerinin matematiksel hesabı aşağıdaki eşitlikte görülmektedir.

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

5.5. F-1 Skoru (F-1 Score)

F1-Skor ölçütü değeri, kesinlik ve duyarlılık değerlerinin harmonik ortalaması sonucu elde edilmektedir. F1-Skor değerinin matematiksel hesabı aşağıdaki eşitlikte görülmektedir.

$$\text{F1-Skor} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (2.4)$$

6. KONVOLÜSYONEL SİNİR AĞLARI İLE METİN SINIFLANDIRMA (TEXT CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORKS)

Geliştirilen derin öğrenme modelinde Konvolüsyonel Sinir Ağları (Convolutional Neural Networks-CNN) ve Tam Bağlantılı/Yoğun (Fully Connected/Dense) katmanları kullanılmıştır.


KSA, insan görme sisteminden esinlenerek tasarlanmış, çok katmanlı algılayıcı (Multi Layer Perceptron-MLP) sınıfından olan bir derin öğrenme mimarisidir. Genellikle görüntü işleme çalışmalarında önerilen bir derin öğrenme algoritması olmakla beraber, günümüzde doğal dil işleme alanlarında da etkin bir şekilde kullanılmaktadır [11].

Dense katmanı, derin öğrenme mimarilerinde yaygın ve sık kullanılan bir sinir ağı katmanıdır. Her nöron bir önceki katmandan girdi aldığı için tam bağlantılı (Fully Connected) katman olarak da bilinir [20].

Deneysel çalışmalarda, konvolüsyonel sinir ağları odağında kalmak kaydıyla çeşitli ek katmanlar ve hiper parametreler kullanarak elde edilen birçok farklı modelle sınıflandırma yapılmıştır. Sonuçlar göz önüne alındığında yüksek sınıflandırma başarısı gösteren, aynı zamanda eğitim süresi açısından çalışma performansı optimum olan bir modelde karar kılınmıştır. Yapılan deneysel çalışmalar neticesinde, Conv1D + Flatten + Dense + Dropout + Dense

katmanlarından oluşan derin öğrenme mimarisi modellenmiştir. Conv1D ve Dense katmanlarında, Doğrultulmuş Doğrusal Ünite (Rectified Linear Unit,

ReLU) aktivasyon fonksiyonu uygulanmıştır. Uygulanan KSA tabanlı derin öğrenme modeli Şekil 5'te görülmektedir.



Şekil 5. KSA Tabanlı Derin Öğrenme Modeli, (ÖA): öznelik adedi
(CNN based deep learning model, (ÖA): number of features)

7. VERİ KÜMESİ (DATASET)

Çalışmada Türkçe dilinde iki farklı veri kümesi kullanılmıştır: Türkçe haber metinlerinden oluşan TTC-4900[13] ve e-ticaret platformlarında yer alan ürünlere yapılmış olan Türkçe müşteri yorumlarından oluşan, çalışmada kullanacağımız kısaltmasıyla, MY-15130.

TTC-4900 veri kümesi, RSS aracılığıyla 6 farklı Türk haber portalinden toplanan haber metinlerinden hazırlanmıştır. Dünya, ekonomi, kültür, sağlık, siyaset, spor ve teknoloji olmak üzere 7 kategoriden 700'er haber içeren toplam 4900 metinden oluşmaktadır. Türkçe haber veri kümeleri arasında kullanımı kolay ve iyi belgelenmiş bir veri kümesi olan TTC-4900, erişime açıktır [21].

MY-15130 veri kümesi ise e-ticaret platformlarından çeşitli ürün yorumları çekilerek hazırlanmış, 6799 olumlu, 6978 olumsuz ve 1393 nötr, toplamda 15170 yorumdan oluşmaktadır. Kaggle platformunda erişime açık şekilde sunulmaktadır [22]. Bu çalışmada MY-15130 sınıf dağılımının dengeli olmaması sebebiyle nötr yorumlardan ayıklanmış, olumlu ve olumsuz yorumlar aynı sayıda olacak şekilde düzenlenmiştir.

Çalışmada “.csv” formatında sunulmuş olan her iki veri kümesine de sırasıyla TF-IDF dönüştürme, durdurma kelimeleri filtreleme, kök bulma ve öznelik seçimi ön işlemleri uygulanmıştır. Ön işlemler uygulamaları Python dilinde kodlanmıştır. Kök bulma uygulaması yerel bilgisayarda, diğer ön işlemler uygulamaları Google Colab platformu üzerinde çalıştırılmıştır.

TF-IDF dönüştürümünde `sklearn.feature_extraction.text` kütüphanesinde sunulan `TfidfVectorizer` sınıfı kullanılmıştır. Kullanılan veri kümelerinin boyutlarının farklı olması sebebiyle, TF-IDF dönüştürümü sonucunda birbirinden farklı boyutta çıktı oluşmuştur. TTC-4900 için 4900×110917 boyutlu, MY-15130 için 15130×17681 boyutlu vektörler elde edilmiştir.

Durdurma kelimeleri filtreleme ön işleminde ise doğal dil işleme kütüphanesi olan `Natural Language Toolkit`'in sunmuş olduğu Türkçe durdurma kelimeleri kullanılmıştır. Veri kümeleri baştan sona taranarak durdurma kelimelerinden arındırılmıştır. Sonuçta TTC-4900 için 4900×110865 boyutlu, MY-15130 için 15130×17657 boyutlu vektörler elde edilmiştir.

Kök bulma ön işleminde Türkçe'nin morfolojik yapısına uygun olarak tasarlanmış `Zemberek` doğal dil işleme kütüphanesi kullanılmıştır. Java dilinde geliştirilmiş açık kaynak kodlu `Zemberek` kütüphanesinin Python uygulamasında kullanılabilmesi için `JPy` kütüphanesinden faydalanılmıştır. Veri kümeleri baştan sona taranarak tüm kelimeler kelime köküne indirgenmiştir. Sonuçta TTC-4900 için 4900×34710 boyutlu, MY-15130 için 15130×8130 boyutlu vektörler elde edilmiştir.

Son olarak iki farklı boyutta çıktı almak üzere, öznelik seçimi ön işlemleri uygulanmış, uygulamada `sklearn.feature_selection` kütüphanesinden sunulan `SelectKBest` sınıfı kullanılmıştır. `SelectKBest` sınıfı `Anova`, `ki-kare`, `bilgi kazanımı` gibi birçok skor fonksiyonuna destek vermektedir. `Girdi` ve `çıkışı`

kategorik veri tipinde olan veri kümelerine uyumlu olması sebebiyle bu çalışmada ki-kare skor fonksiyonu tercih edilmiştir. Tüm önışlemlerden sonra her iki veri kümesinin

8. DENEYSEL SONUÇLAR (THE EXPERIMENTAL RESULTS)

Klasik makine öğrenmesi algoritmaları ve uygulanan KSA tabanlı derin öğrenme modeli ile sınıflandırma çalışması Google Colab platformu üzerinde “Sklearn” ve “Tensorflow.Keras” kütüphaneleri kullanılarak geliştirilmiştir. Bu çalışmada veri kümesi eğitim ve test olarak bölünmemiş katlama(folds-k) değeri 10 verilerek çapraz doğrulama(cross-validation) yöntemi kullanılmıştır. Bu teknik sayesinde veri kümesinin tamamı parçalar halinde dönüşümlü olarak öğrenmede kullanılabilmekte, her bir parçadaki sınıflandırma çıktılarının ortalaması alınarak daha doğru sonuçlar elde edilebilmektedir.

Deneysel çalışma sonucunda, karşılaştırması yapılan tüm sınıflandırma algoritmalarının beklendiği şekilde MY-15130 veri kümesinde daha yüksek sınıflandırma başarısı gösterdiği görülmüştür. Yapısal olarak birbirinden farklı olan veri kümelerinden MY-15130’un iki sınıflı, TTC-4900’ün ise çok sınıflı olması bu sonucu ortaya çıkardığı düşünülmektedir. Sınıf sayısı azaldıkça, sınıf tahmininin doğru olma ihtimali yükselmektedir.

8.1. Multinomial Naive Bayes Uygulaması (Classification with Multinomial Naive Bayes Algorithm)

Uygulamada Naive Bayes algoritması çeşitlerinden metin sınıflandırmasına daha uygun olan Multinomial Naive Bayes modeli kullanılmış, sklearn.naive_bayes kütüphanesi MultinomialNB metodu ile geliştirme yapılmıştır. Çalışma sonucunda elde edilen sınıflandırma doğruluk değerleri Tablo 2’de görülmektedir.

Tablo 2. Naive bayes sınıflandırması doğruluk sonuçları

(Accuracy of Naive Bayes classifications)

	Öznitelik seçimi	TTC-4900	MY-15130
TF-IDF	2000	%88,6	%95,7
	5000	%90,0	%96,0
TF-IDF + DK filtre	2000	%88,6	%95,7
	5000	%90,3	%96,2
TF-IDF + DK filtre + Kök bulma	2000	%89,1	%93,8
	5000	%89,2	%93,9

Sonuçlara göre Naive Bayes sınıflandırmasında her iki veri kümesinde de en yüksek başarı sağlayan ön işlemler TF-IDF + DK filtre + 5000 öznitelik seçimi olarak görülmektedir.

boyutu düşürülerek 2000 ve 5000 adet öznitelik seçilmiş, bu farklı boyutlardaki verilerle sınıflandırma yapılarak sonuçlar kayıt altına alınmıştır.

8.2. K-En Yakın Komşu Uygulaması (Classification with K-Nearest Neighbor Algorithm)

K-En Yakın Komşu algoritması sınıflandırma çalışması sklearn.neighbors kütüphanesi KNeighborsClassifier metodu ile gerçekleştirilmiştir. Algoritmadaki k değerinin tek sayı olduğu sınıflandırmalarda yüksek başarı sağlaması sebebiyle k=5 olarak belirlenmiştir. Çalışma sonucunda elde edilen sınıflandırma doğruluk değerleri Tablo 3’te görülmektedir. Sonuçlara göre KNN sınıflandırmasında, her iki veri kümesinde öznitelik sayısı arttıkça sınıflandırma doğruluk oranının belirgin şekilde düştüğü görülmektedir.

Tablo 3. KNN sınıflandırması doğruluk sonuçları

(Accuracy of KNN classifications)

	Öznitelik seçimi	TTC-4900	MY-15130
TF-IDF	2000	%64,1	%84,2
	5000	%55,4	%71,9
TF-IDF + DK filtre	2000	%64,9	%86,0
	5000	%54,7	%74,3
TF-IDF + DK filtre + Kök bulma	2000	%69,0	%82,7
	5000	%66,3	%70,3

8.3. Destek Vektör Makineleri (DVM) Uygulaması (Classification with Support Vector Machines (SVM) Algorithm)

Destek Vektör Makineleri algoritması sınıflandırma çalışması sklearn.svm kütüphanesi SVC metodu ile gerçekleştirilmiştir. Çalışma sonucunda elde edilen sınıflandırma doğruluk değerleri Tablo 4’te görülmektedir. Sonuçlara göre DVM sınıflandırmasında, TTC-4900 veri kümesinde beklendiği üzere tüm önışlemler başarıya katkı sağlamıştır. Ancak MY-15130 veri kümesinde durdurma kelimeleri filtreleme ve kök bulma önışlemlerinin beklendiğinin aksine sınıflandırma başarısını düşürdüğü görülmektedir. MY-15130 veri kümesinde TTC-4900’a göre kelime çeşitliliğinin az olması sebebiyle bu sonucu ortaya koyduğu düşünülmektedir.

Tablo 4. DVM sınıflandırması doğruluk sonuçları

(Accuracy of SVM classifications)

	Öznitelik seçimi	TTC-4900	MY-15130
TF-IDF	2000	%89,0	%95,8
	5000	%90,8	%96,2
TF-IDF + DK filtre	2000	%88,8	%95,5
	5000	%91,1	%96,1
TF-IDF + DK filtre + Kök bulma	2000	%90,3	%94,1
	5000	%91,2	%94,1

8.4. Rastgele Orman (RO) Uygulaması (Classification with Random Forests(RF) Algorithm)

Rastgele Orman algoritması sınıflandırma çalışması sklearn.ensemble kütüphanesi RandomForestClassifier metodu ile gerçekleştirilmiştir. Çalışma sonucunda elde edilen sınıflandırma doğruluk değerleri Tablo 5'te görülmektedir. Sonuçlara göre, RO sınıflandırması başarı oranının uygulanan ön işlemlerden DVM'e benzer şekilde etkilendiği görülmektedir. Ek olarak öznelik seçiminde öznelik sayısının yüksek tutulması başarıyı arttırmıştır.

Tablo 5. RO sınıflandırması doğruluk sonuçları
(Accuracy of RF classifications)

	Öznelik seçimi	TTC-4900	MY-15130
TF-IDF	2000	%85,9	%93,6
	5000	%86,7	%93,7
TF-IDF + DK filtre	2000	%85,7	%93,5
	5000	%86,6	%94,2
TF-IDF + DK filtre + Kök bulma	2000	%87,9	%93,0
	5000	%88,0	%93,0

8.5. KSA Tabanlı Derin Öğrenme Modeli Uygulaması (Classification with CNN Based Deep Learning Model)

Derin öğrenme modellerinin eğitim aşaması diğer makine öğrenmesi tekniklerine göre oldukça uzun sürmekte, algoritmanın çalışması sırasında ise yüksek kaynak tüketimine sebep olmaktadır. Seçim işlemi yapılmadan tüm özneliklerin bulunduğu bir veri kümesi ile yapılan sınıflandırma çalışması, Google Colab platformu gibi yüksek GPU (grafik işlemci ünitesi) kaynağı sağlayan ortamlarda bile saatlerce sürebilmektedir. Bu anlamda öznelik seçimi işleminin çalışma performansını önemli ölçüde yükselttiği gözlemlenmiştir.

Geliştirilen KSA tabanlı derin öğrenme modeli ile yapılan çalışma sonucu elde edilen sınıflandırma doğruluk değerleri Tablo 6'da görülmektedir. Sonuçlara göre öznelik seçiminde öznelik sayısının yüksek tutulması başarıyı arttırmıştır. Ayrıca kullanılan durdurma kelimeleri filtreleme ve kök bulma ön işlemlerinin başarıyı bir miktar arttırdığı görülmüştür.

Tablo 6. KSA tabanlı derin öğrenme modeli sınıflandırma doğruluk sonuçları
(Accuracy of CNN based deep learning model classifications)

	Öznelik seçimi	TTC-4900	MY-15130
TF-IDF	2000	%90,4	%95,6
	5000	%91,2	%95,6
TF-IDF + DK filtre	2000	%90,4	%95,6
	5000	%91,5	%95,7
TF-IDF + DK filtre + Kök bulma	2000	%90,3	%94,3
	5000	%91,7	%94,0

Çalışmada kullanılan makine öğrenmesi algoritmaları ve geliştirilen KSA tabanlı derin öğrenme modeli ile yapılan sınıflandırma işlemleri sonucunda elde edilen F1-skoru (f-score) değerleri, her bir veri kümesi için Tablo 7'de ve Tablo 8'de görülmektedir.

Sonuçlara göre aynı sınıflandırma algoritması ve ön işlemler bütününe uygulandığı iki veri kümesinde birbirinden farklı F1-skorumları elde edilmiştir. Uygulanan kök bulma ve durdurma kelimeleri filtreleme ön işlemlerinin, KNN sınıflandırıcısı hariç diğer sınıflandırma algoritmalarıyla yapılan sınıflandırma işlemlerinde, elde edilen doğruluk oranlarına en yüksek katkısının yaklaşık %2 olduğu görülmüştür.

KNN algoritmasının, öznelik sayısı yüksek olan veri kümelerinde sınıflandırma başarısının düşük olduğu bilinmektedir. Sonuçlara göre her iki veri kümesinde de en düşük F1-skoru veren algoritmanın KNN olduğu görülmektedir. TTC-4900 veri kümesinde yapılan sınıflandırma çalışmasında baskın bir şekilde en yüksek F1-skoru veren algoritma **%91,7** ile KSA tabanlı derin öğrenme modeli olmuştur. MY-15130 veri kümesinde ise **%96,2** ile DVM ve Naive Bayes aynı F1-skorumu vermiştir. Sonuçlar genel olarak değerlendirildiğinde ise kelime çeşitliliği az ancak metin adedi fazla olan MY-15130 veri kümesinde yapılan tüm sınıflandırma işlemlerinin, kelime çeşitliliği fazla ancak metin adedi daha az olan TTC-4900'de yapılan sınıflandırmalardan daha başarılı olduğu ortaya çıkmıştır.

Tablo 7. TTC-4900 veri kümesi F1-skor(%) karşılaştırması, (Öİ): ön işlem, (ÖA): öznelik adedi (TTC-4900 data set F1-score(%) comparison, (Öİ): pre-process, (ÖA): number of features)

Öİ	TF-IDF		TF-IDF + DK filtre		TF-IDF + DK filtre + Kök bulma	
	2K	5K	2K	5K	2K	5K
ÖA	2K	5K	2K	5K	2K	5K
KNN	64,8	56,6	65,0	55,7	69,9	67,5
RO	85,8	86,7	85,7	86,5	87,8	87,9
DVM	89,0	90,8	88,8	91,0	90,3	91,2
NB	88,5	90,0	88,5	90,2	89,0	89,1
KSA	90,4	91,2	90,4	91,6	90,2	91,7

Tablo 8. MY-15130 veri kümesi F1-skor(%) karşılaştırması, (Öİ): ön işlem, (ÖA): öznelik adedi (MY-15130 data set F1-score(%) comparison, (Öİ): pre-process, (ÖA): number of features)

Öİ	TF-IDF		TF-IDF + DK filtre		TF-IDF + DK filtre + Kök bulma	
	2K	5K	2K	5K	2K	5K
ÖA	2K	5K	2K	5K	2K	5K
KNN	84,1	70,8	86,0	73,5	82,6	68,5
RO	93,6	93,7	93,5	94,2	93,0	93,0
DVM	95,8	96,2	95,5	96,1	94,1	94,1
NB	95,7	96,1	95,7	96,2	93,8	93,9
KSA	95,7	95,6	95,6	95,7	94,3	94,0

Tablo 9. İlişkili çalışmalarla karşılaştırma
(Comparison of related works)

Yıl	Çalışma	Model	F1-skor
2018	Çalışma1[13]	Naive Bayes + Kelime Torbası + Öznitelik seçimi	%90,0
2021	Çalışma2[14]	DVM + DK filtre	%91,8
2022	Bu çalışma	KSA + TF-IDF + DK filtre + Kök bulma	%91,7

TTC-4900 veri kümesini kullanan ilişkili çalışmaların sınıflandırma yöntemleri ve elde edilen F1-skoru değerleri Tablo 9'da karşılaştırılmıştır. Karşılaştırma sonucuna göre, geliştirmiş olduğumuz KSA tabanlı derin öğrenme modeli ve kullanmış olduğumuz önışlemler neticesinde; Çalışma2 ile oldukça yakın, Çalışma1'den ise daha yüksek F1-skor değeri elde edilmiştir.

9. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, iki farklı Türkçe metin veri kümesi makine öğrenmesi teknikleri ve KSA tabanlı bir derin öğrenme modeli kullanılarak sınıflandırılmıştır. Seçilen veri kümelerine Rastgele Orman, Naive Bayes, Destek Vektör Makineleri, K-En Yakın Komşu Algoritmaları ve geliştirilen KSA tabanlı derin öğrenme modeli uygulanmıştır. Metin ve sınıf adedi olarak birbirinden farklı yapıda tercih edilen Türkçe veri kümeleri sınıflandırılarak veri kümesi boyutlarının sınıflandırma başarısına etkisi gözlemlenmiştir. Veri madenciliği önışlemleri olarak uygulanan durdurma kelimeleri filtreleme ve kök bulma önışlemlerinin de başarıya katkısı değerlendirilmiştir. Önışlemler neticesinde ortaya çıkan kelime temsi vektörlerine öznitelik seçimi uygulanarak boyutları düşürülmüş, böylece nihai vektör boyutunun da sınıflandırma sonuçlarına etkisi böylece gözlemlenmiştir. Kullanılan tüm ön işlemlerin farklı birleşimleri ile ortaya çıkan kelime temsil vektörlerinin sınıflandırması sonucunda doğruluk oranları ve F1-skor değerleri karşılaştırılmıştır. İlerleyen çalışmalarda farklı veri madenciliği önışlemleri ve kelime temsil yöntemleri uygulamaya alınarak daha etkili öznitelik çözümü sağlanabilir. Bu şekilde daha kıymetli bilgi içeren düşük boyutlu öznitelik vektörü elde edilerek hem uygulamanın çalışma performansını hem de sınıflandırma başarısını arttırmak hedeflenmektedir.

KAYNAKLAR (REFERENCES)

- [1] R. Aşlıyan, K. Günel, "Metin İçerikli Türkçe Dokümanların Sınıflandırılması", *Akademik Bilişim Konferansı*, 529-535, 2010.
- [2] Y. F. Muliono, F. Tanzil, "A Comparison of Text Classification Methods k-NN, Naive Bayes, and Support Vector Machine for News Classification", *Jurnal Informatika: Jurnal Pengembangan IT*, 3(2), 157-160, 2018.
- [3] J. Liu, J. Li, L. Liu, W. Kang, "A Semantics Aware Random Forest for Text Classification", *28th ACM International Conference*, 1061-1070, 2019.
- [4] H. Chen, W. Jiang, C. Li, R. Li, "A Heuristic Feature Selection Approach for Text Categorization by Using Chaos Optimization and Genetic Algorithm", *Hindawi Publishing Corporation Mathematical Problems in Engineering*, 2013(1), 1-6, 2013.
- [5] B. Xu, X. Guo, Y. Ye, J. Cheng, "An Improved Random Forest Classifier for Text Categorization", *Journal of Computers*, 7(12), 2913-2920, 2012.
- [6] S. Venkatraman, B. Surendiran, P. Arun Raj Kumar, "Spam e-mail classification for the Internet of Things environment using semantic similarity approach", *The Journal of Supercomputing*, 76(2), 756-776, 2020.
- [7] R. Abascal-Mena, E. Lopez-Ornelas, "Author detection: Analyzing tweets by using a Naive Bayes classifier", *Journal of Intelligent & Fuzzy Systems*, 39(2), 2331-2339, 2020.
- [8] D. Kılınc, A. Özçift, F. Bozyigit, P. Yıldırım, F. Yücalar, E. Borandag, "TTC-3600: A New Benchmark Dataset For Turkish Text Categorization", *Journal of Information Science*, 43(2), 174-185, 2017.
- [9] Ç. İnan Acı, A. Çırak, "Türkçe Haber Metinlerinin Konvolüsyonel Sinir Ağları ve Word2Vec Kullanılarak Sınıflandırılması", *Bilişim Teknolojileri Dergisi*, 12(3), 219-228, 2019.
- [10] A. Uçan, M. Dörterler, E. A. Sezer, "A study of Turkish emotion classification with pretrained language models", *Journal of Information Science*, 48(6), 857-865, 2022.
- [11] M. Aydoğan, A. Karcı, "Improving the accuracy using pre-trained word embeddings on deep neural networks for Turkish text classification", *Physica A: Statistical Mechanics and its Applications*, 541, 123288, 2019.
- [12] İ. H. Toroslu, P. Karagöz, "Personality Analysis Using Classification on Turkish Tweets", *International journal of cognitive informatics & natural intelligence*, 15(4), DOI: 10.4018/IJCNIN.287596, 2021.
- [13] Ş. Yıldırım, T. Yıldız, "A comparative analysis of text classification for Turkish language", *Pamukkale University Journal of Engineering Science*, 24(5), 879-886, 2018.
- [14] Ö. Köksal, E. H. Yılmaz, "Improving automated Turkish text classification with learning-based algorithms", *Concurrency and Computation*, 34(11), e6874, 2022.
- [15] Z. Deng, X. Zhu, D. Cheng, M. Zong, S. Zhang, "Efficient kNN Classification Algorithm for Big Data", *Neurocomputing*, 195, 143-148, 2016.
- [16] İnternet: File:Knn sample plot.png, http://www.scholarpedia.org/w/images/1/13/Knn_sample_plot.png, 27.01.2021.
- [17] L. Breiman, "Random forests" *Machine Learning*, 45(1), 5-32, 2001.
- [18] L. Xin, "A New Text Classifier Based on Random Forests", *Proceedings of the 2016 2nd International Conference on Materials Engineering and Information Technology Applications (MEITA 2016)*, Qingdao, China, 290-293, 24-25 Aralık, 2016.

- [19] P. L. Prasanna, D. R. Rao, "Text Classification Using Artificial Neural Networks", *International Journal of Engineering & Technology*, 7(1), 603-606, 2018.
- [20] D. Jha, A. Yazidi, M. A. Riegler, D. Jonansen, H. D. Johansen, P. Halvorsen, "LightLayers: Parameter Efficient Dense and Convolutional Layers for Image Classification", **PDCAT**, Shenzhen, China, 285-296, 28-30 Aralık, 2020.
- [21] Internet: S. Yıldırım, A Benchmark Data for Turkish Text Categorization, <https://www.kaggle.com/datasets/savasy/ttc4900>, 18.11.2022.
- [22] Internet: M. Çabuk, E-Ticaret Ürün Yorumları, <https://www.kaggle.com/datasets/mujdatcabuk/eticaret-urun-yorumlari/>, 18.11.2022.

Bireylerin Kovid-19 Riskinin Uzay-zamansal Olarak Belirlenmesi

Araştırma Makalesi/Research Article

 Hayri Volkan AGUN

Department of Computer Engineering, Bursa Technical University, Bursa, Turkey

hayri.agun@btu.edu.tr

(Geliş/Received:23.06.2022; Kabul/Accepted:07.01.2023)

DOI: 10.17671/gazibtd.1135014

Özet— Mevcut çalışmalar örneğin şüpheli-bulaş-eksiltme modeli ve makine öğrenmesi modelleri her bir kişi ve alan için bulaş riskinin hesaplanmasına uygun değildir. Bu çalışmada mevcut yaklaşımların eksik yönlerinin giderilmesi için toplanan verilerin uzaysal ve zamansal tahminleme modeli olarak bir araya getirildiği bir dönüt işleme tasarımı önerilmektedir. Önerilen tasarım üç ana işleme aşaması içermektedir. Bunlar verinin üretilmesi, geri dönüş analizi ve gerçek zamanlı uzaysal ve zamansal değerlendirme süreçleridir. Verilerin üretilmesi aşamasında her bir bireyin Kovid-19 durumunun Markov olasılık işlemi kullanılarak üretildiği süreç yer alır. Bu aşamada hastalığın çoğalma parametreleri, semptomlu hastaların ve semptomsuz hastaların görülme sıklığı, toplam nüfus, hastalığı geçirmekte olan nüfus, ve hareket halinde olan nüfus sayıları kullanılarak her bir hasta için Kovid durumu ve hareket halinde olma durumu rastsal olarak güncellenir. Hareket verisi ise rastsal olarak belirlenen özel alanlar için oluşturulur. Bu veride kişilerin belirli bir alan içerisindeki etkileşimleri rastsal olarak hesaplanır. Geri dönüş analizi aşamasında toplanan istatistikler ve yerel olay verileri birleştirilerek doğrusal bir model yardımıyla her bir bireyin Kovid-19 riski tahmin edilir. Bu bağlamda yerel istatistiklerin elde edilmesinde olasılıksal bir yakınsama yaklaşımı kullanılabilir. Değerlendirme aşamasında, geri dönüş analizinden elde edilen tüm etkileşimler kişilerin periyodik olarak güncel Kovid-19 riskinin hesaplanmasında kullanılır. Daha sonra her bir kişinin üretilen verideki Kovid-19 bilgisi kullanılarak tamin başarısı o zaman aralığı için hesaplanır. Popülasyon sayısı, yer/zaman ve hareketlilik oranında bağımsız olarak her bir birey etkileşimi için hesaplanan Kappa önerilen tasarımın etkisinin önemli olduğunu göstermiştir.

Anahtar Kelimeler— pandemi yayılma tahmini, uzay-zamansal analiz, akış işleme, risk hesaplama

A Spatio-Temporal Approach For Determining Individual's Covid-19 Risks

Abstract— Current state of art approaches such as the susceptible-infected-removed model and machine learning models are not optimized for modeling the risks of individuals and modeling the effects of local restrictions. To improve the drawback of these approaches, the feedback processing framework is proposed where previously accumulated global statistics and the model estimates generated from the spatial-temporal data are combined to improve the performance of the local prediction. The proposed framework is evaluated in three processing stages: generation of the simulation dataset, feedback analysis, and evaluation for the spatial-temporal and real-time pandemic analysis. In the data generation stage, the corresponding state of the illness for each person is modeled by a Markov stochastic process. In this stage, the parameters such as the reproduction rate, symptomatic rate, asymptomatic rate, population count, infected count, and the average mobility rate are used to update the individual's Covid-19 status and the individual's movements. The movement data of each person is generated randomly for several places of interest. In the feedback analysis stage, both the aggregated statistics and the local event data are combined in a linear model to infer a score for the Covid-19 probability of the person. In this respect, a stochastic model can be used to approximate the local statistics. In the evaluation stage, the result of the feedback analysis for all the interactions is used to classify the state of the individuals periodically. Later the accuracy of the evaluation for each person is obtained by comparing the individual's prediction with the real data generated in the same time interval. The Kappa scores independent from different populations, locations, and mobility rates obtained for every interaction indicate a significant difference from the random statistics.

Keywords— pandemic spread prediction, spatial-temporal analysis, stream processing, risk computation

1. INTRODUCTION

Pandemic analysis models have been frequently used to assess the risks of the Covid-19 spread. Common methods use the parametric models to estimate the number of patients for each stage of the illness [1-3]. Prediction of the state of the pandemic is done through aggregating the statistics and using those statistics in models. These models are used to track the state of the Covid-19 pandemic for a short time [4]. In general, aggregated statistics work very well for predicting the cases even if the data is noisy. However, these parameters may become inaccurate when the dynamics of seasonal, and locational changes of the pandemic are considered. The common mathematical model of the spread analysis is known as the susceptible infected recovered (SIR) model where the number of cases is predicted based on the infection rates. This spread model has been modified to overcome different challenges in Covid-19 prediction [5].

The mathematical models use the rates of the change of the variables of the pandemic [6]. These variables include the number of infected people, the reproduction number, the number of symptomatic patients, and the number of deads. Each of these variables is linked to each other by the constants obtained from the real cases. The linking of the variables creates a dynamic mathematical model known as susceptible, exposed, and asymptomatic (SIR) model [6]. During the Covid-19 several variations of the SIR model have been proposed. For example, in the SEAIR model the variables S, E, A, I, and R are used to denote the fraction of individuals which are respectively susceptible, exposed, asymptomatic, infectious, and recovered [7]. Similar extensions of the SIR model have been successfully applied on the Covid-19 data [8].

The previously mentioned SIR models and their derivations use only the parameters of global spread rates of the pandemic. On the other hand, the mobility pattern tracking approaches use both global parameters and the parameters of the spatial rates obtained through spatially linked cases and spatial clustering methods. These approaches have been successfully applied in the analysis of HIV transmission in Kenya [9], and Covid-19 in Oman [10], and in United States of America [11, 12]. All of these approaches have the capability of modeling different areas through mobility patterns and connections between these locations. Since a lockdown in the local area, creates a difference in the connections and the mobility patterns, thus use of the location information may improve the prediction score of the SIR approach.

To overcome the limitations of the SIR model, machine learning (ML) methods have been applied to pandemic datasets. During the Covid-19 pandemic, ML methods become one of the most studied prediction approaches. ARIMA time series forecasting [13], linear regression models such as Support Vector Regression [13], Gaussian mixture models [2], and random forest classification [14, 15] has been applied in prediction. Similarly, recurrent

deep learning models such as GRU and LSTM [12, 16] have been successfully model the parameters of the Covid-19 pandemic. The main advantage of deep learning approaches is the ability to model long-range interactions and the ability to use a wide range of feature sets including the parameters of the SIR model. These parameters are the number of interactions, temporal patterns, census features, and reproduction numbers [17]. In [17], a neural network model has been demonstrated as a successful combination of time-series data, cross-country specific features, and local features such as the number of hospitals, healthcare workers, and percentages in a neural representation.

Machine learning methods can model recent trends in time series data of the Covid-19 pandemic. In this respect, deep learning methods such as LSTM have been successful. A deep learning study proposed the mean percentage error measure in the prediction of the number of patients according to each social determinant of health (SDH) such as age group, education, etc [18]. In this approach, a convolution neural network classifier is trained for each region by using the SDH parameters. The prediction accuracy of Covid-19 is not the single contribution of the deep learning models. In a deep LSTM approach [17], the representative vector is modeled from the interaction of the features used in the prediction of the Covid-19 cases. The findings of this study suggest that the census features such as age/sex, race, ethnicity, household/family type, school enrollment, poverty status, income, etc. are correlated with all the other features such as mobility, transportation rate, mortality rate, and the Covid-19 reproduction numbers. Embedding the interactions of such features in the pandemic analysis is an effective generalization ability that can be used in other pandemic cases [19].

Spatial-temporal dynamics in spread models are very important for tracking the virus spread. Especially hot-spot analysis approaches are used to track the pandemic cases. In [20], the number of Covid-19 cases is computed in a distance-based correlation index for identifying the hotspots. In [21], the reproduction numbers are used in geospatial clustering to model the interactions of the Covid-19 cases based on the locations. In [22], a center of gravity model is proposed to localize the hubs and flow effect in pandemic parameters. Similarly, kernel-based spatial-temporal clustering methods have been applied for analysis of epidemiological diseases such as childhood leukemia and asthma [23]. Along with kernel density estimates, a Poisson- and Bernoulli-based prospective space-time scan is proposed to find the dense and highly probable spread clusters [24]. Moreover, in [10, 20, 25], a SIR model and the mobility network analysis is combined to estimate the recent reproduction numbers.

2. RISK ANALYSIS

In the Covid-19 pandemic, several mathematical models are proposed to predict the rate of the spread. The susceptible exposed-infectious resistant-susceptible (SEIRs) and susceptible exposed infectious recovery models (SEIR) are used for estimating the infection or

reinfection rates in a population [7]. These models are the extended versions of the susceptible-infected-removed (SIR) model which is used for modeling the parameters of the virus spread [25]. The SIR model with a time delay function for reinfection is demonstrated by Equation (1) [26]. In Equation (1), $S(t)$, $I(t)$, $R(t)$, and $C(t)$ are the rate of susceptible, infected, recovered, and cross-immune people respectively at a given time t , and the population size $N(t)$.

$$\begin{aligned} N(t) &= S(t) + I(t) + R(t) + C(t) \\ S(t) &= \sigma(1 - S(t)) - \epsilon S(t)I(t - \tau) + \beta C(t) \\ I(t) &= \xi S(t)I(t - \tau) + \sigma \xi C(t)I(t) - (\eta + \alpha)I(t) \\ R(t) &= (1 - \sigma)\xi C(t)I(t) + \alpha I(t) - (\eta + \gamma)R(t) \\ C(t) &= \gamma R(t) - \xi C(t)I(t) - (\eta + \beta)C(t) \end{aligned} \quad (1)$$

The reproduction parameters of the pandemic described in the SIR model are found by disease-free equilibrium (DFE) [8]. DFE proposes that the change in the number of infected people is dependent on other parameters. The prediction searches the time or the iteration when the changes in these parameters get fixed and the system gets to an equilibrium state. The SIR model uses the statistics gathered from the pandemic to determine these parameters. In Equation (1), these parameters are denoted by the symbols of eta, beta, alpha, tau and sigma.

In Covid-19, the SIR model is applied in certain intervals especially during the initial outbreak. In Figure 1, the periods are shown for describing the application of training and testing phases. The model is constructed from aggregated statistics gathered in the stages of Training 1 and Training 2. Later this model is verified through the validation time-frame and applied to predict the state of the pandemic in evaluation. The features such as the average number of mobility, the number of active cases, the number of symptomatic cases are accumulated through the training period and used to obtain the model parameters so that the number of active patients, symptomatic patients, and serious cases for the evaluation period can be predicted. The regulations and local restrictions enforce the time range of the prediction to be kept minimum and reduce the prediction performance of the model. The stochastic SIR model, the Markovian model, and the machine learning model have been used in the prediction of the aggregated statistics of the Covid-19 pandemic.

3. DATA GENERATION

In general, the pandemic datasets contain the statistics such as the percentages of active patients, serious cases, and the deaths on a weekly basis for each location [27]. The parameters such as the time and the number of visits of each census block group (CBG) to a place of interest (POI) are not given [12] in those datasets. There are also mobility tracking datasets such as SafeGraph [29] where the tracking information for the individuals including the visited locations are available. However, none of these datasets contain GPS tracking information of the individuals thus they don't pinpoint the location of the

violations of the social distance rules. Similarly, the datasets collected by the companies such as Google and Facebook do not include the tracking information. It can be claimed that the performance limitations of the previous analytic models are occurred not only because of the complexity of the Covid-19 pandemic but also the details of the gathered information. In this study, in order to overcome these limitations, a simulation approach based on a Markov chain model is proposed. This model approximates the true statistics by tracking the states of each individual and also by approximating the actual statistics of the pandemic.

A Markov chain is a random process model constructed from the finite (discrete) state Markov stochastic process. Markov property is the fundamental assumption of the Markov chain where the probability of an event in a given state is conditionally dependent on the previous state. In a Markov chain, the conditional property is used to determine the transitions from one state to another. In order to generate a dataset, we used weekly aggregated data of Covid-19 pandemic such as the number of tested patients, the number of infected and the number of serious cases. These numbers are used to create the transition probability matrix of the Markov chain. An example Markov chain transition diagram for 1st week of April 2020 is given in Figure 1.




Figure 1. Markov transition diagram

In Figure 1, the number of checkups, the number of patients, and the number of healthy individuals are used to compute the transition probabilities for the disease-detected (positive) and disease-undetected (negative) cases. For example, if 100 people have been checked-up for the virus, and 80 people have not been infected then the transition probability to the state of disease undetected becomes 0.8. In order to generate a dataset, the transition matrix is used to approximate true posterior probability. In this case, there are three parameters are used to create a dataset, the number of weeks starting from a given date, the population size, total number of healthy people, total number of infected people, the percentage of the mobility in population, the probability of getting the disease from an infected person and the number of different permitted locations. These numbers and also the Markov chain matrix is used to decide whether a person can travel through the permitted location in a randomly determined time range. The person gets infected or not based on the transition matrix and the interactions of the person. In this respect, if the person is close enough to another person then

his/her getting an infection becomes more likely. Similar to the SIR model, a person might get infected again and shows either signs of illness (symptomatic) or not (asymptomatic). If the person is symptomatic then he/she is in isolation and by no chance, he/she can infect others. However, if the person is asymptomatic then he/she might infect others. The Markov network shown in Figure 1, is represented by a transition matrix given in the Equation (2). The element-wise multiplication of the transition matrix gives the estimate of the current transition probabilities at time h for a given person.

$$p^h = \begin{pmatrix} p_{11}^h & \dots & p_{1n}^h \\ \vdots & \ddots & \vdots \\ p_{n1}^h & \dots & p_{nn}^h \end{pmatrix} \quad (2)$$

h - times
 $P^h = P \times P \times P \dots P$

The probability of the transition from state i to state j is given in the ith row and jth column of the matrix. If the ith state is not connected to the jth state then the probability value is 0.0. The decision for each person is computed according to Equation (3).

$$\begin{aligned} V &= \text{Normal}(\mu, \alpha) \\ S &= [1.0, 0.0, 0.0, 0.0] \\ S_{next} &= S \times P^h \\ S_{next} &= [0.05, 0.8, 0.2, 0.3] \\ S_{next} &= \text{Random}(S_{next}) \\ S_{next} &= [0.0, 1.0, 0.0, 0.0] \end{aligned} \quad (3)$$

In Equation (3), the state probabilities are given in the S vector for a person. If there is not any state vector (S) for a person then the first state vector is determined by a normal distribution where the mean is the average number of check-ups and the standard deviation is the deviation from the mean for the current month. In this case, whether a person get a check-up or not is determined by randomly tossing a bias coin where heads are sampled from a normal distribution of checkups in the current month. After the S vector is constructed than the next S vector is computed via multiplication of the transition matrix. The multiplication creates another state vector. The state vector is used to determine the next vector by random selection. In this case, if the probability of the state is higher than any other state probability then it is more probable to be selected as the next state.

The states of each person are updated daily. So if a person got infected during the day, then he/she can infect others as well during the day. If he/she is tested positive then he/she cannot infect others. Each person is selected for a check-up by pure chance driven from the normal distribution. A step by step example is given in the Table 1. The theory for the above calculations is given in [28]. The algorithm of the data generation is given in Figure 2.

Table 1. Example calculations

Name	Operation	Example
V	A vector of values where checkups are stored with 1's and no checkup with 0's.	A population size of 4 with a mean of 3 and standard deviation of 0.25 V=[1, 1, 1, 0]
S	A state vector where a non zero value positioned at the index represent the probability of being at that state for the person	Person is in 0th state where it is represented by a checkup. S=[1.0, 0.0, 0.0]
S_{next}	State vector is multiplied with the state probability matrix so that the next state is calculated.	State vector now indicate greater than 0 values for the possible states S = [0.05, 0.8, ..., 0.3]
S_{next}	The next state index is determined by randomly selecting the state index by using the probabilities in the state vector	The state vector is now becomes a one hot vector such as [0.0, 1.0, 0.0, ...0.0]. It is computed and stored for each person separately.
p^h	The new transition matrix is calculated by expanding the current transition matrix with multiplication from left.	The next transition matrix is calculated from the previous one. Now the transition probabilities becomes modified.




Figure 2. Data generation

In Figure 2, the statistics such as the population size, the percentage of mobility, the percentage of Covid-19 patients, and the number of different locations are used to generate the geo-coordinates (latitude and longitude) and the movement between these coordinates. All the data is generated through a Gaussian random number generator. At first, the number of locations, healthy people, symptomatic patients, and asymptomatic patients are determined. Later, the interaction between the location and the person is created by a random number generator and represented by a matrix. The contents of the matrix

represent the percentage of the time which is spent by a person in the location. Through using the matrix, the movement coordinates and the Covid-19 interactions are generated. If two-person violates the social distance rule then the maximum of the Covid-19 probability of the location and the Covid-19 probability of the interacted people is entered as the new Covid-19 probability of two-person. For example, if a person is tested Covid-19 positive then his/her interactions have the Covid-19 probability score of 1.0. If the person tested positive or the person gets Covid-19 then based on the stored and memorized stage of the person in the Markov chain, he/she gets the symptomatic or asymptomatic stage. A person exits the illness according to the time, and according to the next random probable state determined by the approximations in the transition states of the Markov chain.

In the data generation not only the states of the people are simulated but also the coordinates of their movement are modeled. In this case, a person either moves or waits according to the randomly determined degree. If a person is waiting then he/she can move backward or forwards. The backward movement happens only once in a one-time step. The time step is determined as 1 second, and the step size of the movement is 1 meter. These parameters are constant for every individual. There are two constraints: two people can not be in the same coordinate at the same time and the area boundary can not be cross passed so that all the people move freely in a closed area.

Based on the constraints described above the dataset is created by the Markov transition diagram is given in Figure 1. and the calculations are given in Equation (3) randomly. The state of each individual is stored by the state vector. At every time-step a movement data is created by moving an individual by a random direction in a closed area. The probability of the movement may create a collision. If a collision occurs the movement changes the direction by certain degree at random angles and continuous until no collision occurs. At every time-step the interactions are computed, if the movement yield an interaction then the state vector is updated based on the infectiousness of the interaction randomly. Approximately half of the interactions are assumed to be infectious if any of the two person is infected otherwise both person's states stays the same. In the final phase of data generation, each movement is recorded for each place of interest and person in the form of latitude and longitude. An example movement sequence is given in Table 2.

In Table 2. The small fragment of the generated dataset is shown. The dataset contains rows which represent a step. The rows are generated sequentially by updating the states of the individuals. The dataset contains latitude and longitude of the movement of a person inside a given place. The movement is determined randomly for each person. Each movement is done approximately in 1 meter diameter circle. The POI is the identifier of the place. The person is identified by CBG number. The Covid-19 status is defined

in C19 column where the infections are marked by 1. In this dataset, there are two person. The second person is infected by Covid-19. The movement data is collected in a 11 seconds step range and the first person get close to the infected person at second 9. After this stage, the person becomes infected. When he/she gets infected the infection state is updated immediately and it is represented by the C19 column of the following step.

Table 2. An example movement data

Latitude	Longitude	POI	CBG	T	C19
50.0001	29.32001	122	001	1	0
50.0001	29.32001	122	001	2	0
50.0001	29.32002	122	001	3	0
50.0001	29.32003	122	001	4	0
50.0001	29.32004	122	001	5	0
50.0001	29.32005	122	001	6	0
50.0001	29.32006	122	001	7	0
50.0001	29.32007	122	001	8	0
50.0001	29.32008	122	001	9	1
50.0001	29.32009	122	001	1	1
50.0001	29.320010	122	002	2	1
50.0001	29.320011	122	002	3	1
50.0001	29.320012	122	001	4	1
50.0001	29.320013	122	001	5	1
50.0001	29.320013	122	001	6	1
50.0001	29.320012	122	001	7	1
50.0001	29.320011	122	001	8	1
50.0001	29.320009	122	001	9	1
50.0001	29.320008	122	001	10	1
50.0001	29.320009	122	001	11	1

The dataset contains the coordinates, place, time and Covid-19 status of each individual. During the evaluation only the information about the interactions are classified. In this respect, first the interactions are found, second the interaction states are determined based on the individuals. In this respect, only the new states of the individuals are predicted. The new state represents the state of an unknown, and previously undetected person. The evaluation of these new states gives a more reliable prediction accuracy since the interactions between two known Covid-19 patients do not contain any state changes and it can be easily said that they are already patients.

4. FEEDBACK INFERENCE MODEL

The feedback model is built on the stream analyzing framework where the probability of an individual having a disease inferred through geospatial analysis of the previously generated statistics as in Figure 3. The feedback model estimates the Covid-19 probability of every individual through using the mobility patterns such as individuals' connections, the global and the local statistics of the previous time frame such as a day, or a week. The local and global statistics extracted from previous time frames are used to approximate the true probability score for the infections of the individuals.




Figure 3. Feedback modelling

In Figure 3, the feedback modeling is depicted. The local and global statistics for the first 9 days is combined to predict Covid-19 risks for the 10th day. The local statistics are represented by the interaction risks of the individuals in a given specific location and in a given time frame. The global statistics represent the reproduction constants. For instance, if two person interacts the probability of getting an infection from each other is determined by these constants. This probability for each individual is calculated according to the equation given in Equation (4) and Equation (5).

$$score_i^h = \vec{\mu}_{local} \times \begin{bmatrix} 0.9 & \dots & 0.1 \\ \vdots & \ddots & \vdots \\ 0.5 & \dots & 0.4 \end{bmatrix} + \vec{\mu}_{global} \quad (4)$$

Person-Location Matrix

In Equation (4), the Covid-19 score of an individual becoming infected is calculated by multiplying the local parameters with the person-location matrix and adding to the global constants. The person-location matrix is the probability of getting infections in the specified location by a person. In this matrix, the rows represent the people and the columns represent the locations. Each element of this matrix represents the person's probability of infection in the specified location. For example, if the first person visits the second and third locations then the first row of this matrix will contain a zero value for the first location and the infection probability for the second and third locations. If there is not any data for the person-location matrix, then the probability of infection for the visited locations can be assumed as one. The Covid-19 score is not only dependent on the person-location matrix. It is also dependent on the interaction vector ($\vec{\mu}_{local}$). In Equation (4), $\vec{\mu}_{local}$ represents the interaction risks of the i th person with the other three people in the h 'th iteration. These risks can be estimated according to the time and distance proximity and the probability of being the Covid-19 patient. Through multiplication of the $\vec{\mu}_{local}$ vector with the person location matrix, only the interactions of the people on the same location will be accumulated. Also, there are base conditions related to the rate of the Covid-19. These are given as a global estimate vector represented by $\vec{\mu}_{global}$. The final result (probability) is the score of being a Covid-19 patient for a person in the specified location. There cannot be any conclusion drawn for the majority of the risk without knowing the local vector because the location-specific risk is assumed to be not only dependent on the

locations but also the interaction with the people in those locations.

$$\vec{\mu}_{local}[j] = maximum\left(\frac{score_j + score_i}{2.0}, score_i\right) \quad (5)$$




Figure 4. The Stream processing steps

Having an infection or not is determined by maximum averaging. The maximum averaging is given in Equation (5). In this equation, $score_i$ and $score_j$ represent the Covid-19 risk of the i th and j th person respectively. The equation assigns the maximum score of two person to the j th local index of the i th person. Thus, in the final decision the magnitude/norm of the $\vec{\mu}_{local}$ vector is used to calculate the total Covid-19 risk of the i th person. Each element of the vector represents the Covid-19 infection of the current person from the j th person. The infection risk is not only dependent on the Covid-19 risk of the other person but also the risks of the individual. Thus, taking the maximum of the average risk and the current person's risk is more appropriate than only considering the current interaction risk. Also, it should be noted that if a person has Covid-19 and his/her state is known. The risk of this patient is not updated by maximum averaging but his/her risk is used in both the person-location matrix in Equation (4) and maximum averaging in Equation (5). In this study, the global scores ($\vec{\mu}_{global}$) are not used. However, in general the global scores can be drawn from the total risk for every individual. The risk of an individual given by $score_i^h$ is the vector, which represents the total risks in each location. In order to find individual's final risk score, the norm of the vector is used.

In Figure 4, the stream processing framework is shown. All the theoretical model described in this paper is implemented by the tools in Apache Big Data Ecosystem. In order to process the streaming data, Apache Flume and Apache Spark stream processing frameworks are used. The data is generated for each person and location by using the Covid-19 states of the people and places. Information about the people and places is stored in Apache HBase. The generated data is pushed to the Apache Flume streaming engine and the data is fetched from Apache Spark for processing. During the processing, the Apache Hbase is used for storing the latest Covid-19 probability of individuals, the interactions, and the main statistics about the places. The Covid-19 probability and the place averages are computed in the Apache Spark streaming engine every 2 minutes. During the stream processing, the person and location identifiers are used to load/save the latest Covid-19 states and status from Apache HBase.

The stream processing framework (Apache Spark) is used to capture the interactions of geo-spatial events. These events contain the time and the coordinate of each mobile individual. To capture the interactions of individuals, the event data is indexed by geospatial hashing. Each coordinate is converted to 45 bit (1/0) geohash where any changes in the last bit correspond to approximately a 2.3-meter difference. The geocode of the event is hashed with the minute window of the time of the event so that the geospatial index can represent the time and the location of the event. Using geospatial indexing the events are clustered into bins. All the events in the same bin are sorted and approximate locations for as most as 6 seconds occurred one another are accepted as interactions. Later all the interactions are processed as explained above.

5. EVALUATIONS

The main concern in the evaluation of the pandemic model is the accuracy of the predictions. In many applications, the predictions include the number of patients, the number of hospitalized patients, and the number of deads for the next day or the next week. The number of deads is a major concern in pandemic analysis. So the prediction of the risks and applying the isolation procedures on time is very affective in reduction of the number of Covid-19 patients as well as the number of deads. For this reason, the evaluation interval for the streamed data is chosen as 2 minutes. Apache Flume and Apache Spark processing framework is used to capture the streamed data. The streamed data contains the person identifier, the coordinates of each person, the time, infected information, and the location id. The infected information denote whether a person is infected or not. This information is used for only evaluation.

In the data generation and evaluation stages several parameters are used. In Table 3, these parameters are given. The population size is denoted by CBG and the number of places is denoted by POI respectively. The population size is the total number of people who visited all the places. The maximum steps in the maximum amount of step taken by

each individual. The number of steps are determined randomly in between the 300 steps and maximum steps. An individual takes a step in each second so that the step size of an individual is equal to the time spend in the place. In every step or second an individual moves by one meter. The social distance constant is the safe distance for every individual. A virus transmission may occur when any two individual get closer than the social distance. Thus, increasing the social distance increases the risk of infection by assuming that two person are not safe with-in a large social distance. Batch frame constant is the window-sampling time for all the events in the dataset. Using two minute window, we can group more events in the same window bucket. If the events of two individuals gets in the same window than these events may contain an interaction. The time constant is the maximum duration for the interaction. If any two events in the same location have occurred in 6 seconds gap than these events are assumed to be an interaction. Increasing the time constant will eventually increase the number of interactions.

Table 3. Parameters for data generation and evaluation

Parameter Name	Parameter Type	Parameter Value
Population size	Variable	100, 400, 1600
Location size	Variable	1, 4, 16
Patients	Percentage	70
Asymptomatic Cases	Percentage	30
Sumptomatic Cases	Percentage	70
Maximum Seconds	Range	600, 1800, 5400
Social Distance	Constant	2 meters
Covid-19 Threshold	Constant	0.88
Batch Frame Time	Constant	2 Minutes
Time Constant	Constant	6 seconds
Data Range	Constant	10 days
Isolation Range	Constant	7 days

The date range is the number of days that is used for generating the data. The date range is inversely proportional to the density of the mobility. If the date range is large then the possibility of an interaction is low, else vice-versa. The isolation range is the number of days in isolation. If a person is known to be a patient then he/she gets isolated for 7 days. The Covid-19 threshold is the value to accept whether a person is infected or not. The Covid-19 value is determined based on the number of positive interactions. If the calculation of the Equation (5) is above the Covid threshold then it is assumed to be an infection. The threshold is chosen as 0.88 because it is assumed that the number of interactions with more than three Covid-19 patients (same or different) infects the healthy individual.

Each person also has a Covid-19 probability value which is continuously updated in each interaction and each person also has a true Covid-19 state which is generated and updated during the generation stage. The batch frame time is used to predict the Covid-19 probability of the person. Every 2 minutes, the evaluation for the event dataset occurs. If the person has a Covid-19 value greater than the

threshold then he/she is accepted as positive otherwise he/she is accepted as negative. The prediction for each person of having a Covid-19 positive or negative is compared with the true state of the person. The predictions are measured according to the positive and negative cases separately. The average scores such as true-positive, true-negative, false-positive, and false-negative are calculated.

The Covid-19 prediction of each person is computed by measuring the maximum Covid-19 probability of the interaction. An interaction contains two people and a place. The person and the place are represented by a unique identifier and a Covid-19 score. The estimate of the current Covid-19 risk for a person is the person's score and the average Covid-19 score of the people during visiting the place is the place's score. If the interaction doesn't contain any risks then the person gets the global constant score based on the calculation given in the feedback inference model. If the person has a high Covid-19 probability then his interactions get the same Covid-19 score too. If the probability of Covid-19 is greater than the threshold then he/she is accepted as Covid-19 positive and his/her interactions would have an above-average Covid-19 score. So, a person's having an infection is conditioned on his/her interactions, the location visits, and the average number of people infected in these places. In the calculations, the global constant vector is discarded, and the person-location risk matrix is computed by the average number of interaction scores in the location. For the initial value of the person-location matrix, the values are set to the percentage of visits to the location. In this case, if a person visits 3 locations the row values of this person will be 1/3. So both the global constant vector and the person-location matrix are chosen as same for every individual.

6. RESULTS AND DISCUSSION

In this study, the datasets are created randomly. Kappa statistics are used to measure the significance of the proposed method according to the random prediction [30]. To measure the Kappa statistics, the confusion matrix of the predictions is used. A Kappa score above 0.5 implies that the proposed approach is significantly better than random chance. In the evaluations, along with the Kappa score, the F-measure is used. These evaluation measures are given in Table 4 and Table 5 where true positive (tp), false positive (fp), true negative (tn), and false negative (fn) rates are used for f-score and Kappa score calculations. In Table 6, these scores are given for each population size, place of interest, and day range.

Table 4. Confusion matrix

	Actual Positive	Actual Negative	Total
Positive	tp	fp	m1
Negative	fn	tn	m0
Total	n1	n0	n

Table 5. Evaluation measures

	Formulations
$n0$	$fp + tn$
$m1$	$tp + fp$
$precision$	$tp/(tp + fp)$
$recall$	$tp/(tp + fn)$
$p0$	$(tp + tn)/n$
pe	$((tp + tn) * (tp + fn) + (fn + tn) * (fp + tn))/n^2$
$Kappa$	$(p0 - pe)/(1 - pe)$
$f-score$	$2 * precision * recall / (precision + recall)$

In Table 5, the calculation of evaluation measures are given. In Kappa score, the $p0$ indicate the accuracy of the proposed framework and pe is the random prediction accuracy based on the ratio of the most probable cases. The measures of F-Measure and Kappa for different datasets are given in Table 6. In Table 6, 18 different datasets are given. These datasets are randomly generated where individual's steps are determined randomly. Each row of the dataset corresponds to geographic location of a person in a given POI at each time step. The step size corresponds to minimum number of steps for an individual to randomly take. Increasing the step size increases the mobility density. For example, the dataset with a 200 step size has a lower mobility density than the dataset with 5400 steps. The mobility density is also proportional to CBG size. Oppositely, the mobility density is inversely proportional to POI size. Along with POI size, each dataset has a random number of interactions. Because the interaction size is dependent on the movement coordinates and the movement of individuals is randomly generated. The number of interactions is given in interaction size.

Table 6. Evaluation results

POI Size	CBG Size	Step Size	Interaction Size	F-Score	Kappa
1	100	600	480	84.197	72.66
1	100	1800	825	86.019	75.492
1	100	5400	1718	85.466	74.610
1	400	600	2020	80.575	73.251
1	400	1800	7450	82.255	77.023
1	400	5400	8215	84.615	71.962
4	100	600	3483	83.172	71.259
4	100	1800	41632	84.538	73.245
4	100	5400	45712	75.061	83.962
4	400	600	10243	77.544	64.664
4	400	1800	11798	84.718	73.621
4	400	5400	49347	84.895	73.787
16	100	600	34604	84.620	73.101
16	100	1800	35769	85.284	74.379
16	100	5400	39872	85.284	74.379
16	400	600	51304	84.673	73.452
16	400	1800	111349	84.538	73.245
16	400	5400	84895	84.538	73.245

The performance measures are obtained by comparing the predicted Covid-19 status with the generated case for every new interaction. According to these results, increasing the number of interactions between people neither has a negative impact on the prediction performance nor on the Kappa score. Thus, it can be said that determining the individuals Covid-19 risk through other individuals risks, location risks and the interactions is done independently from the mobility density. On the contrary, if the risks are computed by assuming that each interaction with a Covid-19 patient infects the other person, we can not observe Kappa scores above 0.5 because every person would be infected and the prediction performance will be close to 1. From the Kappa scores, it can be said that the increased number of interactions increases the possibility of getting an infection and the model prediction approximates this change appropriately.

In Table 6. the scores indicate that the performance of the Covid-19 infection for each persons' interaction is better than determining the persons getting infected from a Covid-19 patient by pure chance. The performance scores are significant according to the Kappa scores. Kappa scores indicate that the prediction is reliable.

The final remarks for the dataset is the baseline performance. The baseline performance of pure chance can be calculated by selecting whether a person infected or not by 0.5 chance. Then for half of the interactions may emit an infection if one of the person is a Covid-19 patient. In this case, let's say mobility size and population size increased to a hypothetical limit where all the interactions are infectious. Then the accuracy will be approximately 50%. So, the question is how the proposed framework perform better than 50%. Because the model uses the total number of interactions of a person as well as the location risk. In this case, whether the person get infected is dynamically calculated based on these priors. If the density increases the possibility of getting infection increases. The proposed framework approximates this possibility appropriately.

7. CONCLUSION

In this study, a geo-spatial analyzing framework is proposed for simulating the pandemic conditions of every person. First, the movement and status data for each individual is generated, then the mobility of each person is aggregated in an interval and the probability of his/her infection is estimated using his/her interactions, and the visited places. The framework consists of three stages; the data generation stage, the processing stage, and the evaluation stage. Four variables are used in the data generation stage; these are the population size, the number of places, the maximum step size, and the time interval. Along with these variables, the data generation of each individual consists of the geospatial movement patterns, and the Covid-19 state of the individual. The Covid-19 states of the individuals are derived from the Markov chain where the probability estimates of the global Covid-19 rates are modelled. During the data generation, the chance

of getting infected and the paths of the infection are determined randomly by using the transition probabilities of the Covid-19 in the Markov chain.

For varying set of parameters, the performance of the proposed framework is evaluated through the Kappa and F-Measure of Covid-19 status of every interaction. Only the interactions of the individuals having unknown Covid-19 status are considered in evaluations. Based on the Kappa statistics, the proposed framework is significantly better than random guesses and the F-measure scores indicate that the event/location based interaction statistics is an effective measure for Covid-19 prediction of individuals.


REFERENCES

- [1] Y. Zeng, X. Guo, Q. Deng, S. Luo, H. Zhang, "Forecasting of COVID-19: spread with dynamic transmission rate", *Journal of Safety Science and Resilience*, 1(2), 91–96, 2020.
- [2] A. Singhal, P. Singh, B. Lall, S. Joshi, "Modeling and prediction of COVID-19 pandemic using Gaussian mixture model", *Chaos, Solitons and Fractals*, 138, 2020.
- [3] L. Basnarkov, "SEAIR Epidemic spreading model of COVID-19", *Chaos, Solitons and Fractals*, 142, 110394, 2021.
- [4] A. Şenol, Y. Canbay, M. Kaya, "Trends in Outbreak Detection in Early Stage by Using Machine Learning Approaches", *Bilişim Teknolojileri Dergisi*, 14 (4), 355-366, 2021.
- [5] W. Getz, R. Salter, O. Muellerklein, H. Yoon, K. Tallam, "Modeling epidemics: A primer and Numerus Model Builder implementation", *Epidemics*, 25, 9-19, 2018.
- [6] Adiga, A, Dubhashi, D, Lewis, B, Marathe, M, Venkatramanan, S, Vullikanti, A. "Mathematical Models for COVID-19 Pandemic: A Comparative Analysis", *Journal of the Indian Institute of Science*, 100(4), 793–807, 2020.
- [7] O. Bjørnstad, K. Shea, M. Krzywinski, N. Altman, "Modeling infectious epidemics", *Nature methods*, 17(5), 455–456, 2020.
- [8] S. Olaniyi, O. Obabiyi, K. Okosun, A. Oladipo, S. Adewale, "Mathematical modelling and optimal cost-effective control of COVID-19 transmission dynamics", *European Physical Journal Plus*, 135(11), 938, 2020.
- [9] A. Isdory, E. Mureithi, D. Sumpter, "The impact of human mobility on HIV transmission in Kenya", *PLoS ONE*, 10(11), 2015.
- [10] K. Al-Kindi, A. Alkharusi, D. Alshukaili, N. Al Nasiri, T. Al-Awadhi, Y. Charabi, A. El Kenawy, "Spatiotemporal Assessment of COVID-19 Spread over Oman Using GIS Techniques", *Earth Systems and Environment*, 4(4), 797–811, 2020.
- [11] H. Unwin, S. Mishra, V. Bradley, A. Gandy, T. Mellan, et. al. "State-level tracking of COVID-19 in the United States". *Nature Communications*, 11(1), 1–9, 2020.
- [12] J. Sousa, J. Barata, "Tracking the Wings of Covid-19 by Modeling Adaptability with Open Mobility Data", *Applied Artificial Intelligence*, 35(1), 41–62, 2021.
- [13] F. Shahid, A. Zameer, M. Muneeb, "Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM", *Chaos, Solitons and Fractals*, 140, 110212, 2020.

- [14] C. Yeşilkanat, "Spatio-temporal estimation of the daily cases of COVID-19 in worldwide using random forest machine learning algorithm", *Chaos, Solitons and Fractals*, 140, 2020.
- [15] N. Punn, S. Sonbhadra, S. Agarwal, "COVID-19 epidemic analysis using machine learning and deep learning algorithms", *medRxiv* 2020.04.08.20057679, 2021.
- [16] V. Chimmula, L. Zhang, "Time series forecasting of COVID-19 transmission in Canada using LSTM networks", *Chaos, Solitons and Fractals*, 135, 2020.
- [17] A. Ramchandani, C. Fan, A. Mostafavi, "DeepCOVIDNet: An Interpretable Deep Learning Model for Predictive Surveillance of COVID-19 Using Heterogeneous Features and Their Interactions", *IEEE Access*, 8, 159915–159930, 2020.
- [18] Kafieh, R, Saeedzadeh, N, Arian, R, Amini, Z, Serej, N, Vaezi, A, Javanmard, S. "Isfahan and Covid-19: Deep spatiotemporal representation", *Chaos, Solitons and Fractals*, 141, 110339, 2020.
- [19] A. Rodriguez, N. Muralidhar, B. Adhikari, A. Tabassum, N. Ramakrishnan, B. Prakash, "Steering a historical disease forecasting model under a Pandemic: Case of Flu and COVID-19", 2020.
- [20] S. Chang, E. Pierson, P. Koh, J. Gerardin, B. Redbird, D. Grusky, J. Leskovec, "Mobility network models of COVID-19 explain inequities and inform reopening", *Nature*, 589 (7840), 82–87, 2021.
- [21] Y. Chen, Q. Li, H. Karimian, X. Chen, X. Li. "Spatio-temporal distribution characteristics and influencing factors of COVID-19 in China", *Scientific Reports*, 11(1):3717. PMID: 33580113, 2021.
- [22] D. Balcan, V. Colizza, B. Gonçalves, H. Hud, J. Ramasco, A. Vespignani, "Multiscale mobility networks and the spatial spreading of infectious diseases", *Proceedings of the National Academy of Sciences of the United States of America*, 106 (51), 21484–21489, 2009.
- [23] A. Gatrell, T. Bailey, P. Diggle, B. Rowlingson, "Spatial Point Pattern Analysis and Its Application in Geographical Epidemiology", *Transactions of the Institute of British Geographers*, 21 (1), 256, 1996.
- [24] M. Kulldorff, R. Heffernan, J. Hartman, R. Assunção, F. Mostashari, "A space-time permutation scan statistic for disease outbreak detection", *PLoS Medicine*, 2 (3), 0216–0224, 2005.
- [25] T. Ng, T. Wen, "Spatially Adjusted Time-varying Reproductive Numbers: Understanding the Geographical Expansion of Urban Dengue Outbreaks", *Scientific Reports*, 9 (1), 1–12, 2019.
- [26] F. Rihan, H. Alsakaji, C. Rajivganthi, "Stochastic SIRC epidemic model with time-delay for COVID-19", *Advances in Difference Equations*, 2020(1), 502, 2019.
- [27] A. Arenas, W. Cota, J. Gómez-Gardeñes, S. Gómez, C. Granell, J. T. Matamalas, D. Soriano-Paños, and B. Steinegger, "Modeling the spatiotemporal epidemic spreading of COVID-19 and the impact of mobility and social distancing interventions." *Physical Review X*, 10(4), 041055, 2020.
- [28] M. Pinsky, and K. Samuel, **An introduction to stochastic modeling**, Elsevier Inc, 2010.
- [29] Internet: Census Block Group Data, SafeGraph Data. <https://docs.safegraph.com/docs/open-census-data>, 05.17.2022.
- [30] A. Viera, J. Garrett, "Understanding Interobserver Agreement :The Kappa Statistic", *Fam med*, 37(5), 360–363, 2005.

İşlem Hacmi ve Mevsimsel Değerler Dikkate Alınarak Derin Yapay Sinir Ağı ile Türk Hava Yolları BIST Hisse Fiyatı Tahmini

Araştırma Makalesi/Research Article

 Muhammer İLKÇAR

Fethiye Faculty of Business Administration Muğla Sıtkı Koçman University, Muğla, Türkiye

muhammerilkucar@mu.edu.tr

(Geliş/Received:26.09.2022; Kabul/Accepted:13.01.2023)

DOI: 10.17671/gazibtd.1180350

Özet— Bilişim çağının getirdiği veri birikimi, bunların analiz edilerek farklı alanlarda kullanılmasını da beraberinde getirmiştir. Veriler, geçmişe dönük bilgi edinme, raporlama, analiz, yapay zekâ ve makine öğrenimi gibi farklı amaçlar için kullanılabilir. Yapay zekâ mühendislik, sağlık, sanayi, üretim, ulaşım, borsa, eğitim, sosyal bilimler gibi farklı disiplinlerde farklı amaçlarla kullanılmaktadır. Bu çalışmada, makine öğrenmesi ile Türk Hava Yolları hisse senedi fiyat tahmini yapılmıştır. Makine öğrenmesi olarak FNN, LSTM ve GRU gibi farklı yapay sinir ağı derin öğrenme yöntemleri kullanılmıştır. Veri seti, Türk Hava Yolları'nın 4 Ocak 2010 ile 31 Ocak 2022 tarihleri arasında BİST' teki günlük borsa endeks bilgilerinden oluşmaktadır. Sistemin eğitimi sırasında olası spekülasyon davranışlarının etkisini azaltmak için işlem hacmi verileri ile birlikte değerlendirilmiştir. Yolcu taşıyan havayollarının gelirleri mevsimsel olarak etkileneceğinden mevsimsel veriler de dikkate alınmıştır. Sistem, farklı kısa-uzun süreli bellek tabanlı yapay sinir ağı modelleri ile eğitilmiş ve test edilmiştir. Modellerin performans göstergeleri olarak R-kare, MSE, RMSE ve MAE kullanılmıştır. Test R-kare performans değerlerine göre sistem FNN' de %97, LSTM ve GRU' da ise %99 başarı göstermiştir. Pandemi nedeniyle aşırı fiyat dalgalanmalarına ve ekonomik krize rağmen yüksek bir performans sergilediği söylenebilir. Bu sonuçlara göre, makine öğrenmesi, sıralı veri seti tahmini için bir karar destek sistemi olarak kullanılabilir. Çalışma ile FNN, LSTM ve türevleri makine öğrenme metodlarının hava yolu taşımacılık sektörü endeks tahmininde başarılı bir şekilde kullanılabileceği sonucuna varılabilir.

Anahtar Kelimeler—ANN, LSTM, GRU, BIST, THYAO, borsa endeks tahmini

Prediction Turkish Airlines BIST Stock Price Through Deep Artificial Neural Network Considering Transaction Volume and Seasonal Values

Abstract— The collection of data in the information age has led to its analysis and use in different fields. Data can be used for different purposes, such as historical information, reporting, analysis, artificial intelligence, and machine learning. Artificial intelligence is used for different purposes in different disciplines such as engineering, health, industry, production, transportation, the stock market, education, and the social sciences. In this study, Turkish Airlines' stock price prediction was made using machine learning. Different artificial neural network methods were used, such as an FNN, LSTM, and GRU. The data set consists of daily stock market index information for Turkish Airlines in BIST between the dates of January 4, 2010, and January 31, 2022. During the training of the system, it was assessed together with the transaction volume data to reduce the effect of possible speculative behavior. Since the income of airlines carrying passengers is seasonally affected, seasonal data are also considered. The system has been trained and tested with different short-long term memory-based artificial neural network models. The performance indicators of the models were used as R-Square MSE, RMSE, and MAE. According to the R-Square, performance score of the test, the success rate of system was 97% in FNN, and 99% in LSTM and GRU. It performed well despite extreme price fluctuations due to the pandemic and economic crisis. According to these results, machine learning can be used as a decision support system for sequential data set prediction. In this study, it can be concluded that FNN, LSTM, and its derivative machine learning methods can be successfully used in air transport sector index prediction.

Keywords—ANN, LSTM, GRU, BIST, THYAO, stock index predict

1. INTRODUCTION

Today, with digitalization, users, electronic devices, sensors, and computer software constantly generates data, which is stored on digital media. This collection of data has led to the creation and development of many new disciplines such as big data, data science, data analysis, machine learning, and artificial intelligence. By organizing the data and using artificial intelligence methods, they are used for many processes such as determining consumer behavior, fraud detection, trends, investment advice, text analysis, anomaly detection, forecasting, classification, clustering, pattern recognition, detecting possible relationships, customer analysis, marketing, sentiment analysis, translation from language to language, smart assistants, etc. Therefore, data has become a strategic weapon today. Data has led the way for companies investing in data science and artificial intelligence to become the world's largest and most competitive businesses Johnston [1]. Data can be of different types and structures depending on the source they are obtained from. The data are grouped as graphs and sequential Tan, Steinbach, and Kumar [2]. Sequential data consist of operations performed by humans or machines. Sequential data are arranged according to a certain quality and order. For example, the stock market index is data arranged according to time, and genome data is data arranged according to a certain rule. Time-dependent data has a temporal dimension, and it should be considered a temporal chronology. This type of data is called a time series or sequential data. Time series can be used in processes such as creating an institutional memory, accessing historical information, reporting, noticing trends, completing missing data, detecting extraordinary situations, and making predictions. A time series of data can consist of components such as trends, seasonal or situational fluctuations, and random movements Duru [3]. Forecasting by using time series can be done with the help of statistical methods or machine learning. As a statistical method for time series prediction methods such as the exponential moving average (EMA: Exponential Moving Average) Hansun [4], non-stationary linear stochastic models (ARIMA: autoregressive integrated moving average) Hyndman and Athanasopoulos, [5] are often used.

Torres et al. [6] studied the use, advantages, disadvantages, and the role of hyperparameters in the time series of popular deep machine- learning algorithms.

Kaynar and Taştan [7] compared the monthly and daily exchange rate data of the T.R. Central Bank with the ARIMA statistical method and ANN.

Bayraktar and Badur [8] predict the index value of the Istanbul Stock Exchange (ISE) by using an artificial neural network, taking into account the index, exchange rate, and overnight interest data.

Aygören, Sarıtaş, and Moralı [9] made the same predictions with traditional methods (ARMA and Newton) and ANN uses approximately 4000 data points belonging

to instruments such as the ISE 100 index, gold prices, exchange rates, interest rates, and the results were compared. They showed that ANN obtained more successful results than traditional methods.

Sami, Tavakoli, and Namin [10] made index predictions using ARIMA and LSTM methods using different financial time series data such as the Nikkei 225 Index, the NASDAQ Composite Index (IXIC), the Hang Seng Index (HSI), and the Dow Jones Index (DJ). The performances of these two methods were compared. According to the results they obtained, they showed that the LSTM method was more successful than ARIMA.

Yücesan [11] made a price prediction in the white goods sector using methods such as ARIMA and artificial neural networks (ANN), taking into account different parameters such as the producer price index, house sales, and an exchange rate.

Kalyoncu et al. [12] made predictions by using LSTM as the learning algorithm of the lesson and by using the 2014-2019 indexes of Akbank, Arçelik, Aselsan, Garanti, and Turkish Airlines companies, according to the BIST 30 and stated that the stock market prediction can be made successfully.

Çınaroğlu and Avcı [13] used the dollar rate, oil price, BIST 100 index, and BIST 100 transportation index data as inputs and estimated the THY market value by using the ANN machine learning method.

Güleryüz, Özden, and Gülhan [14] estimated the BIST 30 index with ARIMA and LSTM and stated that LSTM was 26% more successful than the ARIMA method.

Ranjan, Kayal, and Saraf [15] made bitcoin price predictions using the daily price and daily high price frequency information by using Logistic Regression and XBoost machine learning methods. Daily prediction accuracy with Logistic Regression accuracy is %64.8 and XBoost, 5-minute interval prediction accuracy is %59.4.

Solgi, Lo'aiciga, and Kram [16] used the data obtained from past groundwater levels to make groundwater level predictions with the help of LSTM and NN with different scenarios from one day to three months. In their study, they showed the superiority of LSTM over simple NN machine learning methods in water level estimation based on groundwater data only.

Lindemann et al. [17] have made an overview of LSTM and its derivative machine learning methods. They have compared of these methods in nonlinear time series prediction.

Demirel, Cam, and Unlu [18] predicted the BIST 100 index with MLP, SVM, and LSTM methods. They showed that ANN-based methods are more advantageous than classical methods. In their study, THYAO index prediction found

the best performance to be 97% in the LSTM method, according to the R-square value.

As we have seen in the literature review, ANN and LSTM machine learning methods are used successfully in time series in different sectors. In this study predicted the stock price of Turkish Airlines (THAYO) using several artificial neural network (ANN) machine learning techniques. THYAO is among the world's best airlines and is publicly traded on the Borsa Istanbul (BIST). The daily average trading volume is 84 million [19]. Consequently, it is selected for this study. As used in the data set, THYAO's daily transaction values were recorded in BIST between January 4, 2010, and January 31, 2022. In the data set, we also considered seasonal effects and transaction volume.

2. ARTIFICIAL NEURAL NETWORK

ANN is a machine learning algorithm developed by imitating the biological learning model of the brain Zou, Han, So; Yang and Yang [20,21]. Especially in recent years, it has shown great development with its success in data processing. It has become one of the most preferred and successful algorithms in artificial intelligence and machine learning due to its success in solving many problems such as image processing, text processing, prediction, classification, and clustering. Therefore, ANN is used for different purposes in different disciplines such as health, engineering, social sciences, industry, and education Zarzycki and Lawrynczuk; Er and Işık [22,23]. An ANN network architecture can be seen in Figure 1, and an ANN perceptron (node) can be seen in Figure 2.

In this study different types of ANN models were used, such as feed-forward backpropagation neural networks (FNN), long-short-term memory (LSTM) units, and gated recurrent units (GRU).

2. 1. ANN Architecture

An ANN architecture is shown in Figure 1. According to figure, an ANN consists of one input layer, one or more hidden layers, and one output layer. The input layer is the layer where data is entered from external sources. Since the input layer is the layer where the data is accepted, the number of nodes is equal to the number of attributes in the input data set. The hidden layer prepares data for the next layer by passing the information coming to its input through the mathematical function as in equation 1. Output layering exporting the calculated values (Equation 1). The number of output layer nodes is arranged in a way that can best express the output value of the network. For example, for a price prediction will be made in the study, a single node is enough in the output layer. All layers are fully connected. These links have weight values (w_i). These parameters pertain to the learning of artificial neural networks. The ANN training is the process of optimizing

the network weight values that give the appropriate output against the input data. Although there is no rule about the number of hidden layer nodes, initially it can be determined to be 1.5 times the number of input layer nodes. However, different hidden layer node number architectures should be created and the training and test performances should be compared and the ANN architecture that will give the best performance should be tried to be found.




Figure 1. Fundamental three layers an ANN architecture.




Figure 2. An ANN perceptron (node) structure.

Figure 2 shows the ANN perceptron structure. The perceptron collects the product of its input data (x_i), and the weights (w_i) and obtained a value (z) pass through an activation function ($f(z)$) to produce an output (Equation 1). The b value is the threshold value in the Figure 2 and equation (1). The threshold value ensures that the system works above a certain threshold and is used as an input data attribute.

$$y = f \left(b + \sum x_i w_i \right) \quad (1)$$

The activation function ($f(z)$) ensures that the node output is drawn to a certain range. Thus, the negative effect of excessive data on the performance of the network is minimized by suppressing other data. At the same time, weak data are eliminated if the activation function is below a certain threshold, preventing it from affecting the system. Generally, sigmoid, tangent hyperbolic (\tanh), and rectified linear unit (ReLU) functions are preferred as activation functions in the literature because they are easy to derive and calculate (Figure 3. a, b, and c). The sigmoid activation function (Figure 3.a) compresses the perceptron output to the $[0, 1]$ range and the tangent hyperbolic function (Figure 3.b) to the $[-1, 1]$ range. ReLU function (Figure 3.c); If $z \leq 0$ for the node sum (z), the output value is 0; otherwise, the output value is z .




Figure 3.a. Sigmoid




Figure 3.b. Tangent hyperbolic




Figure 3.c. ReLU.

Figure 3. a, b, c. Activation functions

2.2. Recurrent Memory-Based Artificial Neural Network

Figure 4 shows the recurrent artificial neural network (RNN) structure. As seen in the figure, a node output is given as an input to itself, thus creating a short-term memory, and it is possible to evaluate the data at time t together with the data at the previous ($t-1$) time. When RNN has short-term memory, although it shows a certain success in sequential operations such as text processing, linguistic translation, and time series, it is insufficient. Hochreiter and Schmidhuber [24] developed the RNN to overcome the inadequacies of the RNN node in sequential operations and created a long-short-term memory (LSTM) unit. The LSTM unit enables the previous and subsequent data to be evaluated together by performing operations such as storing and transferring the data for a longer period of time. It is predicted since it is more successful with data sets in sequence, such as text processing and time series Le et al. [25], and Tanışman et al. [26].

An LSTM unit is shown in Figure 5. The LSTM unit consists of four parts; forget, input, state, and output. In this figure, forget gate, data input gate, state gate, and LSTM output gate is in four ANN structures with two layers each. These ANN inputs, $h_{(t-1)}$ and x_t , are combined into a single data set in the form of a heap and form the

ANN network input data. The network outputs are in the form of sigmoid and tangent hyperbolic activation functions.




Figure 4. An RNN unit structure

S : Sigmoid function,

t_h : Tangent hyperbolic function,

x_t : Data input,

h_t : LSTM unit output value/short-term memory of network,
 $h_{(t-1)}$: Previous LSTM unit output information short-term memory,

$C_{(t-1)}$: Previous state (long-term memory),

C_t : Long-term memory for the next cell,

(.) : dot refers to multiplication as a matrix.

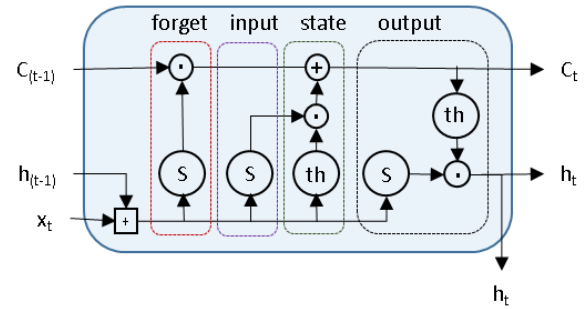


Figure 5. An LSTM unit

Forget Gate (f_t): With the previous output ($h_{(t-1)}$). The input data (x_t) from the forget gate becomes the input to the ANN, and the output layer of the ANN produces a result in the range of [0-1] with the help of the sigmoid activation function (f) (Equation 2). This result is multiplied by the value of the previous state ($C_{(t-1)}$) as a dot product (.). If the forget gate output value is 0, the result will be 0, and the $C_{(t-1)}$ state will be forgotten; otherwise, the forget gate output is 1; the $C_{(t-1)}$ state will remain.

Input & state gate (I_t, \check{C}_t): These two gates decide whether to update the status value $C_{(t-1)}$. Since the input gate output is a sigmoid function, it produces a result in the range of [0-1]. This value is multiplied by the state gate output, and the new state (C_t) is obtained by adding up to the $C_{(t-1)}$ value. If the input gate output value is 0, the result of the multiplication operation will be 0, so the status will not be updated. If 1, then the state gate output value and $C_{(t-1)}$ will be added together to form the new state (Equations 3, 4, and 5).

Output gate (O_t): x_t and $h_{(t-1)}$ data together are given as input to an ANN whose output activation function is sigmoid. The result obtained is multiplied by the result obtained by passing the C_t value through the tangent

hyperbolic function; this will be the unit output (h_t) (Equations 5, 6, and 7).

$$f_t = \text{Sig}(W_f \cdot [X_t, h_{(t-1)}] + b_f) \quad (2)$$

$$I_t = \text{Sig}(W_i \cdot [X_t, h_{(t-1)}] + b_i) \quad (3)$$

$$\check{C}_t = \text{Tanh}(W_c \cdot [X_t, h_{(t-1)}] + b_c) \quad (4)$$

$$C_t = f_t \cdot C_{(t-1)} + I_t \cdot \check{C}_t \quad (5)$$

$$O_t = \text{Sig}(W_o \cdot [X_t, h_{(t-1)}] + b_o) \quad (6)$$

$$h_t = O_t \cdot \text{Tanh}(C_t) \quad (7)$$

Sig : Sigmoid activation function

Tanh : Tangent hyperbolic activation function

b_i : Threshold

Gated Recurrent Unit (GRU) is another variant of RNN. Its developed by Cho et al. [27, 28]. The GRU architecture has short-term memory like LSTM (Figure 6). As can be seen in the figure, it has a simpler structure than an LSTM unit. Therefore, since it will contain fewer parameters, it will use fewer resources than the LSTM unit. The GRU has a reset port (R) and a status-update port (U), which determine the short-term memory. In Figure 6, the previous state/memory $h_{(t-1)}$ and x_t data are passed through an ANN network with an activation function sigmoid (S) to produce a value in the range of [0-1] (R_t) (Equation 8). In the update gate (U_t), just like in the reset gate, $h_{(t-1)}$ and x_t data are passed through an ANN network whose output is sigmoid (S) and generates a value in the range of [0-1] (Equation 9). The candidate (\tilde{h}_t) output is produced by passing the x_t data in equation (10) through the tangent hyperbolic ANN, together with the result of the multiplication of [0-1] with R_t and $h_{(t-1)}$ (Equation 10). For the new long-term memory (h_t) update; $(1-U_t)$ is multiplied by $h_{(t-1)}$ plus the product of U_t and \tilde{h}_t (Equation 11).

$$R_t = \text{Sig}(W_r [h_{(t-1)} + X_t] + b_r) \quad (8)$$

$$U_t = \text{Sig}(W_u [h_{(t-1)} + X_t] + b_u) \quad (9)$$

$$\tilde{h}_t = \text{Tanh}(W_h [R_t \cdot h_{(t-1)} + X_t] + b_h) \quad (10)$$

$$h_t = (1-U_t) \cdot h_{(t-1)} + U_t \cdot \tilde{h}_t \quad (11)$$

h_t : Long-term memory

W_r : Rest port ANN weight values

W_u : Update port ANN weight values

W_h : Output port ANN weight values

R_t : Reset port

U_t : Update port outcome

\tilde{h}_t : Candidate memory




Figure 6. A GRU unit

3. THYAO BIST DATA SET

THYAO's 3036 daily BIST transaction data between January 4, 2010, and January 31, 2022, were obtained from <https://tr.investing.com> THYAO [19] in .csv (Comma Separated Values) format [29]. As seen in Table 1, the raw data set has transaction date, closing, opening, highest, lowest index, and trading volume indices.

The average price index was calculated by taking the arithmetic average of the opening and closing indexes. The price index change graph by date can be seen in Figure 7. The raw data were transformed into basic data, which consists of price, volume, and season values (Table 1). Season information is also obtained from the transaction date. Attention should be paid to the temporal sequence in time series. It is not appropriate to sort the data according to any other feature other than the time dimension. As seen in Figures 7, and 8 training and test data in time series should not be mixed. It should be separated in a certain order. A certain number of data can be separated from the beginning as training data and the rest as test data. Supervised machine learning methods were used for the prediction of time series. The data set consists of attributes and label values (Table 2).

A supervised learning method was used for the prediction of time series with machine learning. For this purpose, the sequential dataset must be transformed into the supervised machine learning data set. After transformation, the data set consists of attribute values and label values in supervised machine learning (Table 2). Table 2 shows the example transformation for 10 window range. In the table, the window range defines the attributes (x_i), while the first data after the window range represents the label. The volume value was also added as an attribute (x_{11}) in the transformed data set. This attribute consists of the arithmetic means of the volume data. The seasonal effect was added to the transformed data set as an x_{12} . Thus, the dataset will consist of 12 attributes (x_1, x_2, \dots, x_{12} and one label (y).




Figure 7. Price graphic of THYAO between 4th of January 2010 and 31th of January 2022




Figure 8. Divided data as training and testing

Table 1. THYAO daily transactions data, volume, and the calculating transaction price

Date	Closed	Open	Highest	Lowest	Volume		Price	Volume	Season
2010.01.18	3,49	3,46	3,49	3,43	5,80M	→	3.48	5,80M	1
2010.01.19	3,56	3,52	3,56	3,46	11,50M	→	3.54	11,50M	1
2010.01.20	3,46	3,52	3,52	3,43	16,12M	→	3.49	16,12M	1
2010.01.21	3,46	3,48	3,49	3,40	13,09M	→	3.46	13,09M	1
2010.01.22	3,40	3,43	3,46	3,34	10,54M	→	3.42	10,54M	1
...	Transforming
2010.01.28	3,46	3,46	3,49	3,40	8,66M	→	3.46	8,66M	1
2022.01.29	3,43	3,43	3,46	3,40	7,61M	→	3.43	7,61M	1
2022.02.01	3,49	3,43	3,49	3,40	7,35M	→	3.46	13,99M	1
2022.02.02	3,46	3,49	3,49	3,40	8,23M	→	3.48	8,23M	1

Table 2. Transformation of time series into supervised machine learning data set

Daily transaction dataset				Transforming to a supervised learning data set							
				Date	Price				Volume	Season	Label
Date	Price	Volume	Season		X ₁	X ₂	...	X ₁₀	X ₁₁	X ₁₂	Y
2010.01.18	3.48	5,80M	1	2010.01.08	3.48	3.54	...	3.43	10.12	1	3.46
2010.01.19	3.54	11,50M	1	2010.01.09	3.54	3.49	...	3.46	10.31	1	3.48
2010.01.20	3.49	16,12M	1	2010.01.20	3.49	3.46	...	3.48	9.98	1	3.48
2010.01.21	3.46	13,09M	1	2010.01.21	3.46	3.42	...	3.48	9.18	1	3.43
2010.01.22	3.42	10,54M	1	2010.01.22	3.42	3.39	...	3.43	10.43	1	3.29
...
2010.01.28	3.46	8,66M	1	2010.01.28	3.46	3.43	...	3.20	12.15	1	3.21
2022.01.29	3.43	7,61M	1	2022.01.29	3.43	3.46	...	3.21	12.14	1	3.23
2022.02.01	3.46	13,99M	1	2022.02.01	3.46	3.48	...	3.23	12.79	1	3.31
2022.02.02	3.48	8,23M	1	2022.02.02	3.48	3.48	...	3.31	13.56	1.	3.39

Some statistical information about the data is given in Table 3. According to the table, the count of dataset samples is 3036, the standard deviation is 4.81, the arithmetic mean is 8.61, the minimum value is 1.74, and the maximum value is 28.76. Since the skew value is between 0.5 and +1 (0.72) the distribution is moderately skewed, and the kurtosis coefficient is positive (0.33), the probability distribution is leptokurtic.

Table 3. Data set statistical values

Statistical Item	Value
Data count	3036
Mean	8.61
Standard deviation	4.82
Min. value	1.74
Max. value	28.76
Skewness	0.72
Kurtosis	0.33




Figure 9: The box graph of the dataset

Figure 9 shows the box plot of the distribution of the data set. According to the graph, the density of the data is between 4 and 13. As can be seen in Figures 7, and 8, while it followed a low profile up and down until 2018 (in 8 years), it showed a rapid increase over 2018, especially in 2022.

4. THYAO STOCK PRICE PREDICTION

In this study, training and prediction processes were carried out by the ANN machine learning algorithm by taking the time series of THYAO's index data in BIST for the last 12 years. In addition to the daily stock market average price index, daily trading volume and seasonal information are also taken into account. For this purpose, the arithmetic average of the trading volume data in the window range and the seasonal information were also added to the data set features. The machine learning process flow chart of the system is given in Figure 10.

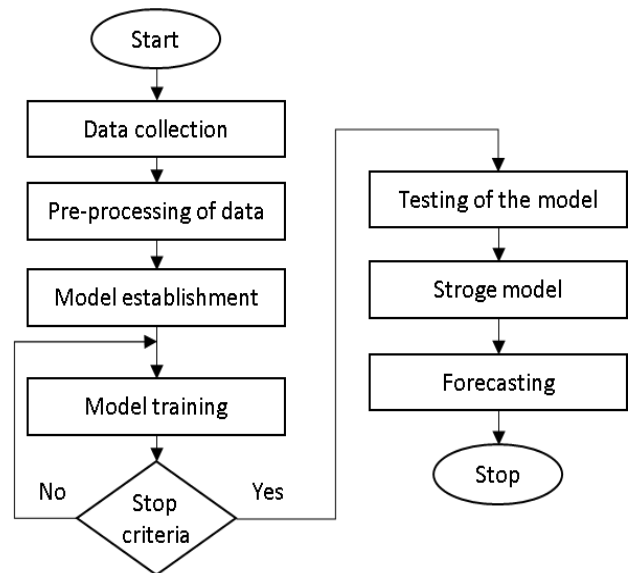


Figure 10. System flow chart

According to Figure 10;

First step; The process starts with data gathering. THYAO daily stock market index data between 04 January 2010 and 31 January 2022 was retrieved from tr.investing.com in csv (comma separated values) format.

The second step is data pre-processing. At this stage, completing and/or deleting missing data in the data set, transforming categorical data, and removing unnecessary features were conducted. As the preprocess in this study:

- A new price feature was created from the arithmetic average of the daily opening and closing indexes of the time series raw data set.
- Transaction volume and season information were added to the data set as a new feature, taking into account the window range.
- By preserving the time dimension of the data, the first 70% of the data was reserved for training, and the remaining 30% was reserved for test data.
- The training and test datasets are shown in Figure 8 supervised machine learning dataset transformations were performed in the form of the attribute (x_i) and label (y) (Table 2).

The third step is the setup of the model. In this step, the selection of the model and its parameters were determined. For example, regarding the ANN model, hyperparameters such as hidden and output layers, the number of nodes, activation functions, loss function, optimization algorithms, learning rate, batch size, the number of iterations, etc. were determined. The model used in the study and the parameters of the model are given in Tables 3, 4, and 5.

In the fourth step; the model was trained using the training data set until the stop criteria were met. The stopping criterion was taken as the point at which the training and validation error values began to differ.

Fifth step; the model was tested with the test data set. In the test process; The model is given a test dataset and is to make a prediction. The difference between the prediction and the actual data shows the amount of error. The average of all test data set error amounts shows the test performance of the system. This value is closer to zero the better the performance of the system. If the test performance is very low or there is a large difference between the training performance and the test performance, there may be cases of memorization or poor learning. For this, all processes in the workflow should be reviewed from the first step, and if necessary, the workflow should be operated again by making corrections.

In the study, the mean of the squared sum of the errors (Equation 12) and the square root of the mean of the squared sum of the errors (Equation 13), the mean absolute error (Equation 14), and the R-square scale (Equation 15) were used as training and tested performance score, and the results were shown in tables 4,5 and 6.

$$MSE = \frac{1}{n} \sum (z_i - y_i)^2 \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (z_i - y_i)^2} \quad (13)$$

$$MAE = \frac{1}{n} \sum |z_i - y_i| \quad (14)$$

$$R^2 = 1 - \frac{\sum (z_i - \bar{y}_i)^2}{\sum (z_i - \bar{y}_i)^2} \quad (15)$$

y_i : Actual value

z_i : Value predicted by the system

\bar{y} : Average actual value

n : Number of samples

After successfully testing the model, it can be stored for later use. Estimation can be done by using a model that has been successful in training and testing. The estimation information obtained assists in decision-making processes. Many factors affect the price index in the real world. Therefore, the prediction information to be obtained from the model can only be used to provide an idea in the decision-making process. This cannot be considered a recommendation. The steps up to the model- building stage in the flowchart are valid for all different models. In this study, training and test performance results of the RNN, LSTM, and GRU models were compared.

4. 1. Feed Forward and Back Propagation FNN Model

FNN is a basic feedforward, backpropagation network model consisting of input, hidden, and output layers. In the study, while making supervised data sets the window interval was taken as 10, and with volume and seasonal data, the total number of features is 12 (Table 2). Therefore, the number of FNN input layer nodes is 12. A single perceptron is sufficient in the output layer, as the model makes price estimations. A single hidden layer with different perceptron numbers was used in the study.

Table 4. ANN hyperparameters

Parameter	Value
Batch size	30
Learning algorithm	adam
Delta	0.001
Loss function	MSE
Hidden layers transfer function	ReLU
Output layer transfer function	ReLU

The FNN model hyperparameters are shown in Table 4. The model runs at 100 epochs and doesn't use dropout. The model was run with a different FNN architecture; its effects on the performance of the system were observed, and the obtained data were transferred to Table 5. The table includes the training and test performances. As can be seen from Table 5, performances in all FNN architectures are high and close to each other. If evaluated according to test performance, the lowest MSE error amount was 0.317 and the highest R-square score was 0.966 in the 2nd model, 12-6-1 architecture. Figures 11, and 12 demonstrate these results. Figure 11 shows that the amount of error decreased as the training progressed. In Figure 11 we see that the training and validation error rates decreased together. This indicates that normal learning takes place. In Figure 12, the data predicted by the trained model as a result of the test and the actual data it should have been shown in the same graph. It is seen that they are very close to each other and almost overlap. It represents the high test performance of this model.




Figure 11. FNN Model Training error change graph




Figure 12. FNN actual value and predicted value.

Table 5. FNN model architecture, optimization parameters, training, and test performance

#	Network Architecture	Training Performance				Test Performance			
	Input-Hidden-Output	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
1	12-3-1	0.042	0.204	0.149	0.994	0.464	0.681	0.495	0.950
2	12-6-1	0.048	0.220	0.172	0.995	0.317	0.563	0.366	0.966
3	12-12-1	0.052	0.229	0.167	0.994	0.406	0.637	0.474	0.951
4	12-15-1	0.043	0.208	0.154	0.992	0.322	0.567	0.465	0.965
5	12-20-1	0.039	0.197	0.146	0.996	0.747	0.864	0.652	0.920

4. 2. LSTM Model

The THYAO stock price was predicted through a different structural LSTM model, and its result was compared. The LSTM model hyperparameters are shown in Table 6. In any of the layers, no dropout was used.

Table 6. LSTM and GRU model hyperparameters

Parameter	Value
Epoch	100
Batch size	30
Learning algorithm	adam
Delta	0.001
Loss function	MSE
Hidden layer transfer function	ReLU
Output layer transfer function	ReLU

The system learning process was carried out by creating different architectures for different LSTM units and output (ANN) units, and the results were transferred to Table 7. As can be seen in the table, the training and test performances of all models are very successful and close to each other. If evaluated according to the test performance, the best model 1 and 5 architectures are more successful than the others with 99% R-square value. Figure 13 shows the LSTM architecture training and validation loss graph. According to the graph, it is seen that the training error and validation values decrease together with the value of errors as the iteration progresses. The fact that the loss and validity error values decrease together and are very close to zero can be considered an indication of a successful and normal training process. Figure 13 seen that there is no overfitting or underfitting. In Figure 14, the test data and the actual values, and the predicted values are plotted together. As can be seen in the figure, the actual value and the predicted value are very close to each other

and almost overlap. This show that system performance is good. This study also used a bidirectional LSTM model.

The bidirectional LSTM is a kind of LSTM. It consists of two LSTMs that perform bidirectional computation. One LSTM computes the array in the forward direction, and the other in the reverse direction. This boosts the efficiency of sequential problems such as time series, and text processing.




Figure 13. LSTM training error change graph




Figure 14. LSTM test comparison of actual and predicted values

Table 7. LSTM model machine learning network architecture, optimization parameters, training, and test performance

#	Network Architecture	Training Performance				Test Performance			
	LSTM-LSTM-Dense-Dense	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
1	64 - - - 1	0.014	0.120	0.084	0.998	0.143	0.378	0.258	0.985
2	64 - 64 - - 1	0.013	0.116	0.082	0.998	0.152	0.390	0.260	0.984
3	64 - - - 32 - 1	0.013	0.113	0.080	0.998	0.199	0.446	0.291	0.979
4	64 - 64 - 32 - 1	0.013	0.115	0.080	0.998	0.159	0.399	0.260	0.983
5	64 unit BiLSTM- Dense(1)	0.012	0.109	0.076	0.998	0.130	0.361	0.246	0.986

4.3. GRU Model

System training and tests were performed using the parameters used in the LSTM for the GRU model, and the results were transferred to Table 8. As seen in the table, the R-square performances of all models are very close to each other (0.981 to 0.987). The best performance was the 2nd model with a value of 0.987. The change graph of the training loss and validity values of the system with repetition is given in Figure 15. In Figure 16, the test prediction values obtained from the trained system and the expected actual values are drawn together, and it is seen that they almost overlap with each other. This figure supports the success of training and testing numerical performance values.




Figure 15. GRU model training error and validation error graph depended on the iteration




Figure 16. GRU model tests prediction values and actual values in displaying in the same figure

5. CONCLUSION

In this study, by using THYAO's 3036-day BIST data between the years 2010-2022, the prediction process was carried out by using different types of artificial neural networks, FNN, LSTM, and GRU machine learning methods. The data set was taken from tr.investing.com to csv format and preprocessed and turned into a supervised machine learning data set in the form of input and label. Used stock index values in the data set, the arithmetic average of the opening and closing index. Also, transaction volume values were added to the data set as an attribute to minimize possible speculative effects. To take into account the seasonal effects, seasonal information was added to the data set as an attribute. The first 70% of the data set was split for training and the remaining 30% for testing. The training and test datasets were transformed into supervised machine-learning datasets. During the transformation used 10 window sizes, so the data set has 10 attributes and a label. No scaling was done in the data set. Hence, the training and test MSE error amounts are in the range of 0.317 to 0.464. These values may be smaller when the data is scaled to a certain range. This does not affect the performance of the system. Considering R-Square and the test performance scale, it was seen that there was no significant difference between the FNN, LSTM, and GRU architectures. However, LSTM and GRU performed better, with 99% R-square. The change in LSTM and GRU architectures showed no significant change in the R-square performance value. But a performance difference of 92% to 97% was observed in the R-squared scale of the FNN architecture change. Hence, it can be concluded that the network architecture affects the system performance in FNN. When looking at the data set graph in Figure 7, it is seen that there is a big fluctuation, especially in the last data. Although this fluctuation is test data, the test R-square performance of the system has a very high value of 99%. This means that the system has been well-trained. The taught machine (software) can generate a forecast for the next days by using the data from the previous days. This will provide significant support to the investor while investing in a decision. However, many predictable/unpredictable factors affect the stock market index. While creating the data set, different factors that will affect the index can also be considered.

Table 8. GRU model machine architecture, optimization parameters, training, and test performance

#	Network Architecture	Training Performance				Test Performance			
	GRU- GRU- Dense- Dense	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
1	64 - - - 1	0.011	0.105	0.073	0.997	0.133	0.365	0.228	0.986
2	64 - 64 - - 1	0.011	0.106	0.073	0.998	0.126	0.355	0.236	0.987
3	64 - - 32 - 1	0.010	0.101	0.074	0.998	0.178	0.422	0.282	0.981
4	64 - 64 - 32 - 1	0.010	0.101	0.070	0.998	0.129	0.359	0.237	0.986
5	64 unit BiGRU-Dense(1)	0.011	0.104	0.072	0.995	0.174	0.417	0.295	0.981

In this study showed that machine learning can be an effective method for making forward projections based on the past data of the air transport sector. It can be concluded that LSTM and its derivative methods are more successful than the classical artificial neural network in the prediction index prediction of airport transportation sectors. ANN-based machine learning methods can be used successfully in the prediction of air transport and can provide long-term prescience to investors. In time series the structure of machine-learning methods and the effects of hyperparameters on the prediction performance were shown. More predictable forecasts can be made by taking into account unforeseen environmental factors such as economic policies, international relations, and interest rates.

REFERENCES

- [1] Internet: M. Johnston, Biggest Companies in the World by Market Cap, <https://www.investopedia.com/biggest-companies-in-the-world-by-market-cap-5212784>, 31.01.2022.
- [2] P.N. Tan, M. Steinbach, V. Kumar, **Introduction to Data Mining**, Pearson Education, Inc, 2006, ISBN 0-321-42052-2, 2006.
- [3] Ö. Duru, **Zaman Serileri Analizinde Arıma Modelleri ve Bir Uygulama**, Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, 2007.
- [4] S. Hansun, "A new approach of moving average method in time series analysis", **Conference on New Media Studies (CoNMedia)**, Tangerang, Indonesia, 2014.
- [5] R. J. Hyndman and G. Athanasopoulos, **Forecasting: Principles and Practice**. OTexts Publisher, 2018.
- [6] J. F. Torres, D. Hadjout, A. Sebaa, F. Martínez-Álvarez, and A. Troncoso, "Deep Learning for Time Series Forecasting: A Survey", *Big Data*, 9(1), 2011.
- [7] O. Kaynar and S. Taştan, "Comparasion of MLP Artifical Neural Network and Arıma Method in Time Series Analysis", *Erciyev Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161-172, 2009.
- [8] B. K. Bayraktar, and B. Badur B. "Yapay Sinir Ağları ile Borsa Endeksi Tahmini", *Yönetim*, 20(63), 2009.
- [9] H. Aygören, H. Sarıtaş, T. Moralı, "İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini", *International Journal of Alanya Faculty of Business*, 4(1), 73-88, 2012.
- [10] S. Siami-Namini, N. Tavakoli, A. S. Namin, "A Comparison of ARIMA and LSTM in Forecasting Time Series", **17th IEEE International Conference on Machine Learning and Applications**, IEEE, 1394-1401, 2018.
- [11] M. Yücesan, "Sales Forecast with YSA, ARIMA and ARIMAX Methods: An Application in the White Goods Sector", *Journal of Business Research-Türk*, DOI: 10.20491/isarder.2018.414, 2018.
- [12] S. Kalyoncu, A. Jamil, E. Karatas, J. Rasheed, C. Djeddi, "Stock Market Value Prediction using Deep Learning", **3rd International Conference on Data Science and Applications (ICONDATA'20)**, 2020.
- [13] E. Çımaroğlu, T. Avcı, "THY Hisse Senedi Değerinin Yapay Sinir Ağları İle Kestirimi", *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 34(1), 1-20, 2020.
- [14] D. Güleriyüz, E. Özden, Ü. Gülhan, "Predicting BIST 30 Index with ARIMA and RNN-LSTM Models", **24. Finans Sempozyumu**, 2021.
- [15] S. Ranjan, P. Kayal and M. Saraf, "Bitcoin Price Prediction: A Machine Learning Sample Dimension Approach", *Computational Economics*, DOI: 10.1007/s10614-022-10262-6, 2022.
- [16] R. Solgi, H. A. Lo' aiciga and M. Kram, "Long short-term memory neural network (LSTM-NN) for aquifer level time series forecasting using in-situ piezometric observations", *Journal of Hydrology*, 601, 2021.
- [17] B. Lindemann, T. Müller, H. Vietz, N. Jazdi, M. Weyrich, "A survey on long short-term memory networks for time series prediction", *Pocedia CIRP*, (99), 650-655, 2021.
- [18] U. Demirel, H. Cam, R. Unlu, "Predicting Stock Prices Using Machine Learning Methods and Deep Learning Algorithms: The Sample of the Istanbul Stock Exchange", *Gazi University Journal of Science*, 34 (1): 63-82, 2021.
- [19] Internet: THYAO, Türk Hava Yolları Anonim Ortaklığı, <https://tr.investing.com/equities/turk-hava-yollari-historical-data>, 02.05.2022.
- [20] J. Zou, Y. Han, S. S. So, Overview of Artificial Neural Networks. In: Livingstone D.J. (Eds.) *Artificial Neural Networks. Methods in Molecular Biology™*, 458, 14-22, Humana Press, 2008.
- [21] Z. R. Yang, and Z. Yang, **Artificial Neural Networks. Comprehensive Biomedical Physics**, Elsevier. Editor(s): Anders Brahme, 1-17, 2014.
- [22] K. Zarzycki, and M. Lawrynczuk, "LSTM and GRU Neural Networks as Models of Dynamical Processes Used in Predictive Control: A Comparison of Models Developed for Two Chemical Reactors", *Sensors*, 21(16), 2021.
- [23] M. B. Er, İ. Işık, "LSTM Tabanlı Derin Ağlar Kullanılarak Diyabet Hastalığı Tahmini", *Türk Doğa ve Fen Dergisi*, 10(1), 68-74, 2021.
- [24] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory", *Neural Computation*, 9 (8): 1735-1780, 1997.
- [25] X. H. Le, H. V. Ho, G. Lee, S. Jung, "Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting", *Water*, 11, 1387, 2019.
- [26] S. Tanışman, A. A. Karcioğlu, A. Uğur, H. Bulut, "LSTM Sinir Ağı ve ARIMA Zaman Serisi Modelleri Kullanılarak Bitcoin Fiyatının Tahminlenmesi ve Yöntemlerin Karşılaştırılması", *European Journal of Science and Technology*, 32, 514-520, 2021.
- [27] K. Cho, B. Merrienboer, D. Bahdanau, Y. Bengio, On the Properties of Neural Machine Translation: Encoder-Decoder Approaches, *arXiv:1409.1259*, 2014.
- [28] K. Cho, B. Merrienboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation", *arXiv:1406.107*, 8 (3) , 2014.

Merkez Bankası Dijital Para Birimi: Tasarım ve Protokol Mekanizmaları Bağlamında Karşılaştırmalı Bir Analiz

Literatür Makalesi/Review Article

 Emircan YILDIRIM,  Kerim Eser AFŞAR,  Ramazan BEKTAŞ

İktisat Bölümü, Dokuz Eylül Üniversitesi, İzmir, Türkiye
emircnyld@gmail.com, eser.afsar@deu.edu.tr, ramazanbektasdeu1@gmail.com
(Geliş/Received:18.06.2022; Kabul/Accepted:16.01.2023)
DOI: 10.17671/gazibtd.1132632

Özet— Bitcoin ile başlayan kripto para ekosistemi ve büyük teknoloji şirketlerinin kendi ödeme sistemlerini kurma girişimleri, merkez bankalarının para üzerindeki tekel haklarını tehdit etmeye başlamıştır. Merkez bankalarının bu gelişmelere olan nihai tepkisi merkez bankası dijital parasıdır (CBDC). Bu çalışmada blok zinciri ağlarında kullanılan alternatif protokol mekanizmalarının, verimlilik, güvenlik ve mahremiyet bağlamında karşılaştırması CBDC literatürünü kapsayacak şekilde yapılmıştır. Çalışmanın amacı protokol ve tasarım özelliklerinin “yeni finansal mimari” içindeki işlevini analiz etmektir. Bu bağlamda çalışmada, CBDC tasarımında bahsi geçen protokollerin işleyişini ayrıntılandırıyoruz. Araştırma kapsamında blok zinciri teknolojisi uzmanlarıyla yarı yapılandırılmış mülakat tekniği kullanılarak veriler toplanmış ve karşılaştırmalı analize tabi tutulmuştur. Karşılaştırmalı analiz yöntemiyle elde edilen bulgulara göre CBDC tasarımında Proof of Authority (POA) protokolünün kullanılması, merkez bankalarına finansal sistemin tümü bağlamında bir gözetim yapabilme şansı tanıyarak bireysel mahremiyeti tamamen ortadan kaldırabilir. Çevrim dışı ödeme (OPS) protokolünün kullanılmadığı durumlarda CBDC’nin amaçlarından biri olan finansal kapsayıcılık işlevsiz kalabilir. Proof of Work (PoW) ve Proof of Stake (PoS) protokollerinin varyasyonlarının kullanılması ise ölçekleme probleminin ortaya çıkmasına neden olabilir. CBDC tasarımlarında kullanılan protokollerin güçlü yönleri dikkate alınarak hibrit bir protokol oluşturulabilir. Protokol yapısının güçlü olması para politikası bağlamında CBDC’nin işlevselliğini arttırabilir. CBDC protokolleri literatürde çoğunlukla verimlilik ve güvenlik boyutlarıyla tartışılmaktadır. Tartışmaya mahremiyet boyutunun da dâhil edilmesi gerektiğini iddia ediyoruz.

Anahtar Kelimeler— CBDC, konsensüs protokolleri, verimlilik, blok zinciri

Central Bank Digital Currency: A Comparative Analysis in the Context of Design and Protocol Mechanisms

Abstract— The ecosystem of crypto money that started with Bitcoin and the attempts of big technology companies to establish their own payment systems began to threaten the monopoly rights of Central Banks on money. The ultimate response of the Central Bank towards these developments is the central bank digital currency (CBDC). In this study, a comparison of an alternative protocol used in blockchain networks with respect to efficiency, security, and privacy that is compatible with the CBDC literature will be provided. The intention of this study is to analyze the function of protocol and design features in the “new financial architecture”. In this context, we delve into the operation of the protocols mentioned in the CBDC design. Within the scope of this research, data were collected by using semi-structured interview technique with blockchain technology experts and subjected to comparative analysis. According to the findings obtained by the comparative analysis method, the use of the Proof of Authority (POA) protocol in the CBDC design can completely eliminate individual privacy by giving an opportunity to the central banks to oversee the entire financial system. In the absence of the offline payment (OPS) protocol, financial inclusion, one of the objectives of the CBDC, may become dysfunctional. Using variations of Proof of Work (PoW) and Proof of Stake (PoS) protocols might give rise to scaling problems. A hybrid protocol can be created by considering the strengths of the protocols used in CBDC designs. A strong protocol structure can significantly increase the functionality of the CBDC in the context of monetary policy. CBDC protocols are frequently discussed in the literature regarding their efficiency and security dimensions. We assume that the privacy dimension should also be included in the discussion.

Keywords— CBDC, consensus protocols, efficiency, blockchain

1. GİRİŞ (INTRODUCTION)

Dijital parayı madeni veya kâğıt paranın dijital hali olarak tanımlayabiliriz. 2008 yılında Bitcoin üçüncü bir taraf olmadan eşler arasında ödemeyi mümkün kılan yeni bir ödeme sistemi olarak tanıtılmıştır [1]. Kripto para, değişim aracı olarak, işlemlerin kriptografi temelinde güvence altına alındığı dijital paradır. Bitcoin'in alt yapısı olan blok zinciri teknolojisi ile eşler arasında işlemlerin mümkün kılınması, birçok alanda yeni projelerin ortaya çıkmasına neden olmuştur. Devletler başlarda kripto para birimlerine karşı yasaklayıcı bir tavır sergilerken blok zincirine yönelik araştırmalarını sürdürmeye devam etmektedir. Şimdilerde ise nakit kullanımının düşmesi ve dijitalleşme ile birlikte devletler blok zinciri teknolojisinin meydana getirdiği avantajlardan yararlanmak amacıyla CBDC¹'ye yönelik araştırmalarını arttırmakta ve pilot uygulamaları hayata geçirmektedir [2]. Bu bağlamda Çin, Nijerya ve Bahamalar'ın yaptıkları çalışmalar CBDC alanındaki gelişmelere yol göstermektedir [3-5].

Bankacılık sisteminde para transferi, göndericinin hesabından gönderilen miktarın düşülüp alıcının hesabına aktarılması ile gerçekleşmektedir. Herhangi bir aracının olmadığı internet gibi güvenin sağlanmasının zor olduğu bir ortamda kişiler arasında işlemlerin gerçekleştirilmesinde kayıt sistemi önem kazanmaktadır. Bu ortamda tutulan kayıt defterlerine yeni işlemler eklenebilmeli, değiştirilemez olmalı ve işlemler silinmemelidir. Kayıt defterinin özgünlüğünün sağlanması için hash (özüt) değerinin olması gerekmektedir. Bu değer ile defterde meydana gelebilecek bir değişikliği görmek mümkündür. Bitcoin'in temeli de bu defter fikriyle hareket etmektedir. Dijital ortamda tutulan defterin bir merkeze bağlı olmadan dağıtık bir şekilde var olmasının öncü çalışmaları Bitcoin'den önce hayata geçirilmiştir. Bağlantılı zaman damgası ile veri yapısının oluşturulmasında Haber ve Stornetta'nın [6] çalışması Bitcoin'in ortaya çıkışı için önem arz etmektedir. PoW sisteminin temelleri ise spam mailler ile gerçekleştirilen saldırıların önüne geçmek için tasarlanmıştır [7]. Bitcoin'in bir diğer temeli olan anonimlik ise Chaum [8] tarafından detaylandırılmıştır.

Bitcoin ve diğer kripto para birimleri paranın bir takım özelliklerini taşımaktadır, ancak bir merkezin kontrolünde olmaması ve devletler tarafından tanınmaması nedeniyle fiat paralardan ayrılmaktadır. Aynı zamanda Facebook'un Libra olarak başlayıp Diem olarak değişen kripto para

denemesi büyük şirketler tarafından devletlerin meşruiyetini sarstığı bir durumu ortaya çıkarmıştır. Facebook'un bu girişimi ile birlikte merkez bankaları dijital paralara yönelik araştırmalarını arttırmış ve pilot uygulamalarını hayata geçirmiştir. CBDC, finansal içerme, daha esnek bir ödeme sistemi, kamu mahremiyeti ve sınır ötesi ödemeleri daha etkin kılması gibi avantajları nedeniyle dijitalleşen dünyada merkez bankalarının geride kalmak istemediği yeni bir üründür. Uluslararası ödemelerde kullanılan SWIFT sistemi yavaş ve yüksek maliyete sahip olması nedeniyle kripto paralar ile birlikte kullanımı sarsılmaya başlamıştır. CBDC mimarisi bankaların kullandığı geleneksel yöntemlere yenilik getirerek daha hızlı ve daha düşük ödeme hizmeti sunabilir. Bununla birlikte kripto paraların yarattığı kaos ortamı CBDC ile kontrol edilebilir, geleneksel finans mimarisi için yeni bir alt yapı sunabilir, ödeme sistemlerini dengeleyebilir ve merkez bankalarının kendi meşruiyetlerini sağlayabileceği bir sistemi tekrar mümkün kılabilir.

CBDC'nin güvenli, hızlı ve daha düşük maliyetli bir ödeme sistemi sağlayabilmesi için tasarım içerisinde protokol tercihleri önem kazanmaktadır. Bashar vd. [9] blok zinciri teknolojisini destekleyen çeşitli konsensüs protokollerini ele almakta ve bunları hesaplama zorluğu, güvenlik açıkları, maliyet açısından nesnel olarak karşılaştırmaktadır. Blok zincirinde kullanılan protokollerin güvenlik ve performansı ile ilgili parametreler belirlenerek karşılaştırılması [10], PoW, PoS, DPoS, PBFT protokollerinin avantaj ve dezavantajlarının analizi [11], PoW, PoS, BFT, PoET ve FBFT protokolleri işlem kesinliği, işlem oranı, katılım maliyeti, blok zinciri, düşman saldırısı gibi parametreler ile karşılaştırılması [12], PBFT, PoW, DPoS, PoS ve Raft protokolleri verim, ölçeklenebilirlik ve doğrulama hızı üzerinden karşılaştırmalı olarak analizi [13] blok zinciri bağlamında literatürde yapılmıştır. Literatür içerisinde protokollerin karşılaştırılması blok zinciri teknolojisi üzerinden genel olarak güvenlik ve verimlilik üzerinden ele alınırken CBDC sisteminde kullanılan protokollerin karşılaştırılması literatürde henüz ele alınmamıştır. Ulusal literatürde ise yapılan çalışmalar genellikle CBDC'nin olası etkileri ve fırsatları üzerinden incelenmektedir [14-18]. Çalışmanın amacı blok zinciri teknolojisinde kullanılan protokollerin CBDC tasarımlarında verimlilik, güvenlik ve mahremiyet bağlamında karşılaştırmalı bir analizini yapmaktır. Çalışmada verimlilik, birim zamandaki işlem sayısına; güvenlik, protokollere yönelik siber saldırılara;

¹ İngiltere Merkez Bankası, Merkez Bankası Dijital Parasını ödeme sisteminde değer saklama aracı olarak kullanabilen, merkez bankasının elektronik fiat yükümlülüğü olarak tanımlamaktadır. Dar para arzı olarak belirlenmiş ve evrensel olarak erişilebilirdir. Bkz. J. Meaning, B. Dyson,

J. Barker, E. Clayton, "Broadening narrow money: monetary policy with a central bank digital currency", Staff Working Paper No. 724, (2018).

mahremiyet, merkez bankasının kullandığı protokol yapısı ve sistem tasarımına bağlı olarak kişilerin dijital adreslerine ulaşması ve işlemleri takip etmesine göre temellendirilmiştir.

Merkez bankası dijital parası oluşturulurken tasarlanan mimari ve teknik alt yapı önem kazanmaktadır. Geleneksel blok zinciri sisteminin ölçeklenebilirlik problemi yaratması ve enerji verimliliğinin düşük olması nedeniyle bu alanda yeni tasarımlara ihtiyaç duyulmaktadır. Özellikle PoW protokolünün düşük işlem sayısına ve yüksek enerji maliyetlerine sahip olması nedeniyle CBDC mimarilerinde tercih edilmeyen konsensüs mekanizmasıdır. CBDC oluşturulurken mevcut bankacılık sisteminin mimari içerisindeki konumu ve rolü ise bir diğer tartışma konusudur. Bu bağlamda çalışmada, CBDC'nin tasarımı ve teknik alt yapısı için protokol yapıları karşılaştırmalı olarak analiz edilmektedir. Çalışmanın birinci bölümünde, CBDC'nin önemi ve genel tasarımı incelenmektedir. İkinci bölümde, literatürde yer alan CBDC tasarımları; üçüncü bölümde ise CBDC literatüründe tartışılan protokoller ele alınmaktadır. Dördüncü bölümde bu protokollerin karşılaştırmalı analizi yapılmakta ve çalışma sonuç kısmı ile sonlanmaktadır.

2. BLOK ZİNCİRİ VE CBDC (BLOCKCHAIN AND CBDC)

Bitcoin'in alt yapısı veya başka bir deyişle temel teknolojisi olan blok zinciri, Bitcoin'in ardından bir çok kripto para birimi tarafından benimsenerek yeni projelerin ortaya çıkmasına neden olmuştur. Dijital dünyanın hızla gelişmesi ile birlikte fiat paraların kullanımlarının azalması ve blok zincirinin sunduğu faydalardan kaynaklı olarak merkez bankaları, kripto paralardan esinlenerek kendi dijital paralarını çıkarmaya yönelik araştırmalara yönelmiştir. Merkez bankalarının CBDC'ye olan ilgisini Gerçek Zamanlı Brüt Ödemelerde (RTGS) meydana getirdiği avantajlar üzerinden ele alan Calle ve Eidan [19] 1970 yılında toptan ödemenin ilk örneği olan Fedwire'in kurulmasından itibaren ödemelerin verimliliğini arttırmaya yönelik çalışmaların olduğunu, CBDC'yi de bu 50 yıllık sürecin son adımı olarak nitelendirmektedir. CBDC ile merkez bankaları daha güvenli ve verimli ödeme sistemlerine sahip olabilmektedir [20]. Elde bulunduran nakit para faizi içermemektedir. Faiz içeren bir CBDC tasarımı ile merkez bankaları, para politikasını kontrol etme kabiliyetini arttırabilmektedir. Dolayısıyla faiz getiren bir CBDC, kısa vadeli devlet tahvilleri gibi diğer risksiz varlıklarla uyumlu bir getiri oranı ile güvenli bir değer deposu sağlayabilir [21]. Bu bağlamda faiz içeren bir

CBDC para politikasının yürütülmesinde bir araç olarak kullanılabilir. Aynı zamanda CBDC sınır ötesi ödemelerde kolaylık, esneklik, erişilebilirlik, mahremiyet ve kullanım kolaylığı sunmalıdır [22]. Bununla birlikte CBDC'lerin ödeme sisteminde kullanılması nakit kullanımının yarattığı maliyetleri azaltabilir [23]. Merkez bankalarının dijital para birimleri yaygınlaştıkça artan dijitalleşmeye uyum sağlama süreçleri gelişecek ve meşruiyetini korumalarını sağlayacaktır. Aksi durumda CBDC'ye olan çekimser tavırlar uzun vadede merkez bankaları açısından olumsuz etkiler doğurabilecektir. Bunların başında özel şirketlerin kendi kurdukları ödeme sistemlerinde devletlere olan bağlılıklarının azalması gelmektedir. Örneğin eski adıyla Facebook'un (Meta) iptal edilen Diem projesi, merkez bankalarının para üzerindeki kontrolüne rakip olan en büyük projedir². Bu bağlamda CBDC, şirketlerin sunduğu özel dijital paralara nazaran daha güvenli bir alternatif sağlayabilmektedir. Ancak CBDC'nin bu faydalarından yararlanabilmek için nasıl bir tasarıma sahip olması gerektiği önem kazanmaktadır.

Bir CBDC tasarlanırken veri tabanının seçiminde kullanılacak zincir yapısı ve tasarım biçiminin ne olacağına karar vermek gerekmektedir. CBDC sisteminde Dağıtık Defter Teknolojisi (DDT) ve DDT'nin bir türü olan blok zinciri kullanılırken merkezi veri sisteminin kullanılması da mümkündür. DDT ve blok zinciri teknolojisinde verilerin sisteme işlenmesinde farklılıklar bulunmaktadır. Blok zinciri teknolojisi kullanan mimarilerde veri girişinin ve kayıtların tutulması blok zinciri tipine göre değişmektedir. DDT'de ise veriler tek bir merkezden girilebilir ve kayıtlar dağıtık olarak tutulabilmektedir. Bu çalışma içerisinde blok zinciri veri tabanına ve DDT'ye sahip CBDC mimarileri incelenmektedir. Zincir tipi bakımından izinsiz (açık), izinli ve konsorsiyum olmak üzere üç zincir tipi bulunmaktadır [24]. İzinsiz blok zinciri, herhangi bir merkezin iznine tabi olmadan zincire katılmanın herkesçe mümkün olduğu bir zincir tipidir. Bu zincire kişisel donanım ile katılmak mümkündür. İzinsiz blok zincirinde sisteme dâhil olan herkes veri girişinde bulunabilmekte ve kayıtlar dağıtık olarak tutulmaktadır. İzinsiz blok zincirine örnek olarak Bitcoin ve Ethereum verilebilir. İzinli blok zinciri, bir merkez veya platform tarafından zincirin kontrol edildiği blok zinciri tipidir. Bu zincire madenci olarak katılabilmek için merkezin izin vermesi gerekmektedir ve zincirde düğüm (node) kontrolü merkezin elindedir. Dolayısıyla kayıtlar dağıtık olarak tutulurken veri girişleri bir merkezin kontrolünde ancak yine dağıtık bir şekilde yapılmaktadır. Konsorsiyum blok zinciri, izinli bir blok zinciri tipidir ancak ağır kontrolü bir

² Facebook (Meta) şirketinin Instagram, WhatsApp ve Facebook uygulamalarının kullanıcı sayısı 14.06.2022 tarihi itibarı ile 2,93 milyardır. Şirketin kullanıcıların kişisel verilerine sahip olması nedeniyle dünya üzerindeki önde gelen merkez bankalarının para üzerindeki tekel

hakkını tehdit etmesi nedeniyle finansal kurumlar ve üst düzey politikacılar Libra (Diem) projesine tepki göstermiştir. Bu konuda bkz. <https://www.nytimes.com/2019/07/10/technology/fed-chair-facebook-cryptocurrency-libra.html>

kuruluş yerine birden fazla kurum ve kuruluş tarafından sağlanmaktadır. Bu ağda yer alan her bir kurum yetkili olduğu düğümleri kontrol etmektedir.

CBDC'ler kullanım amaçlarına göre perakende ve toptan olmak üzere iki şekilde kategorize edilmektedir. Toptan CBDC, merkez bankası ve bankalarla doğrudan ilişkide olan kuruluşların ödemelerini içermekte ve bankalar arasındaki ödemelere yeni bir altyapı oluşturmaktadır [25]. Bankaların kendi aralarında kredi riskinin artmasından kaynaklı olarak meydana gelen borçların sonlanması toptan CBDC ile sağlanabilmektedir. Perakende CBDC genel olarak bireyler ve işletmeler arasındaki ödemeler için kullanılmakta ve nakitin dijital bir biçimi olarak nitelendirilmektedir. Perakende CBDC, doğrudan, dolaylı ve hibrit olmak üzere kendi içinde üçe ayrılmaktadır [26]. Doğrudan CBDC, merkez bankası tarafından çıkartılan dijital paranın kişilerin hesaplarına merkez bankası tarafından aktarıldığı bu modelde kişilerin hesapları ve işlemleri merkez bankası tarafından tutulmakta ve kontrol edilmektedir. Son kullanıcılar merkez bankasından bir hesap açar ve işlemlerini gerçekleştirir. Bu haliyle model, klasik bankacılık sistemini dışlar. Dolaylı CBDC, geleneksel bankacılık sisteminin dijital hali olarak nitelendirilebilir. Merkez bankası tarafından ihraç edilen dijital para doğrudan kişilere aktarılmasından ziyade bu süreç finansal kurumların aracılığı ile gerçekleştirilir. Son kullanıcılar para talebinde bulunurken merkez bankasının yerine burada yer alan aracı finansal kurumlardan talepte bulunur. Burada hesapların ve işlemlerin kontrolü aracı kurumlar tarafından sağlanır. Hibrit CBDC, kullanıcıların işlemleri bu modelde hem merkez bankası hem de aracı kurumlar tarafından sağlanmaktadır. Bu modelde merkez bankası, perakende işlemlere ait defterleri kendi bünyesinde tutar ve kontrolünü sağlar.

Ödeme alt yapısı olarak CBDC'ler hesap tabanlı, token tabanlı ve semi token olmak üzere üçe ayrılmaktadır [27]. Hesap tabanlı CBDC, son kullanıcıya merkez bankası veya aracı kurumlar tarafından bir hesap tanımlanarak sisteme dahil edilmektedir. Bu sisteme dahil olmak isteyen kişiler kimlikleri ile hesaba sahip olmaktadır. Bu durumda blok zincirin anonimliğinden vazgeçilmektedir. Klasik bankacılık sistemindeki hesap sistemine benzer bir yapısı bulunmaktadır. Token tabanlı CBDC, kullanıcı özel ve genel anahtarı ile işlemlerini gerçekleştirmektedir. Bu ödeme sistemi, nakit kullanımının bir versiyonu olarak nitelendirilebilir [28]. Kullanıcının sahip olduğu tokenlere dair anahtarı varsa transfer işlemlerini gerçekleştirebilmektedir. Bu yöntem ile anonimliği sağlamak mümkündür. Ancak anahtar çifti kimlik ile merkez bankası veya aracı kurumlar tarafından sağlanırsa anonimlikten yine vazgeçilmektedir. Semi token, hem token temelli hem de hesap temelli bir hesap yapısı

sunmaktadır. Nakit kullanımı gibi küçük ödemeler token temelli yürürken daha büyük para transferleri hesap tabanlı gerçekleşmektedir. Burada token temelli yürüyen ödemeler tıpkı nakit kullanımı gibi kullanıcılara mahremiyet sağlamaktadır.

3. CBDC TASARIMLARI (CBDC DESIGNS)

CBDC literatüründe önerilen modellerin bir kısmı ölçeklenebilirlik sorununu çözmek için tasarlanmıştır. Practical Byzantine Fault Tolerance (PBFT) protokolü ile Panda modeli [29] olarak adlandırılan yeni bir dolaylı CBDC modeli önerilmektedir. Modelde geleneksel blok zincirinin meydana getirdiği ölçeklenebilirlik probleminin ortadan kaldırılması için Hesap (Account) Blok Zinciri ve İşlem (Trading) Blok Zinciri olmak üzere iki blok zincirli bir yapı sunmaktadır. Bu iki zincirin sadece bir işlevselliğe odaklanması nedeniyle model ölçeklenebilirdir. İzinli blok zinciri teknolojisi ve PBFT protokolü kullanılarak MBDC [30] adlı dolaylı CBDC modeli önerilmektedir. Model ödemelerin daha hızlı gerçekleşmesi ve ölçeklenebilirliğin iyileştirilmesi için çoklu blok zinciri mimarisi kullanılmaktadır. Ölçeklenebilirliğin sağlanabilmesi için zincirler arası iletişim protokolleri tanımlanmaktadır.

Zang vd. [31] POA-BFT protokolü ile hibrit bir CBDC modeli önermektedir. Modelde, işlem hızının artırılması, küçük-büyük ödemelerin yerleşimi, doğrulanması ve sorgulanması için dijital para birimlerini kayıt eden hesap şeması kullanılmaktadır. Dijital para birimlerinin kullanılabilirliğini iyileştirmek için Harcanmamış İşlem Çıktısı (UTXO) formu kullanılmıştır. Hesap şeması, banka hesapları gibi çalışmakta ve kullanıcıların bakiyesini kaydetmek için liste kullanılmaktadır. PoW ve PoS protokollerinde, düğümler üretilen bloğu doğrulamaktadır, ancak kötü niyetli bir saldırı ile ağın yarısı kontrol edildiğinde sistem manipüle edilir. PBFT mekanizması daha kararlı ve verimli bir mekanizma iken düğüm sayısındaki artış performansı düşürebilmektedir. Delegated Proof of Stake (DPoS) ise CBDC'de kullanıldığında, sahte kimlik oluşturarak ağı kontrol etme girişimini (Sybil Saldırısı) engellemek için etkin bir mekanizmadır. Bununla birlikte geleneksel blok zincirinin dezavantajları göz önünde bulundurularak blok transfer etmek ve üretim sırasını belirlemek için PBFT yolunu kabul eden birkaç blok üreticisine oy veren DPoS-BFT konsensüsü kullanılarak POA-PBFT algoritması önerilmektedir. Bu protokole göre, defter tutan düğüm seçiminin yerini merkez bankası tarafından doğrudan atama ve yetkinin kaldırılması almıştır. Bu yöntem ile oylamadaki etkisizlik ortadan kalkmaktadır. DPoS'ta blokların üretim sırası tüm düğümler tarafından görüşülürken önerilen protokolde, merkez bankası tarafından belirlenen bir düğüm ile numara bloğu üretilebilir. Bu durum çatallı zincirlerin oluşmasının da önüne geçebilmektedir.

Boston Federal Rezerv Bankası (Boston Fed) ve Massachusetts Teknoloji Enstitüsü'nün Dijital Para Birimi Girişimi (MIT-DCI) tarafından 2021 yılında Hamilton Projesi başlatıldı. Birinci faz raporunda, iki farklı CBDC mimarisi tasarlanmış ve temelde ölçeklenebilirlik üzerinde durulmuştur [32]. Modelde veri kayıtlarının işlenmesi ve konsensüsün sağlanması için Raft protokolü kullanılmıştır. Ağ performansının artırılması için kripto paralarda kullanılan UTXO protokolünün tüm verilerini tutmak yerine UTXO'ya ait değer, seri numarası ve yükümlülük yüklemine hash fonksiyonu alınarak çekirdek işlemcisinde tutulur. Modelde her UTXO'ya seri numarası eklenerek "küresel benzersizliğe" ulaşılır ve çifte harcama önüne geçilir. Projede Atomizer ve İki Aşamalı Taahhüt (2PC) olmak üzere iki farklı mimari tasarlanmıştır. DDT kullanılarak oluşturulan modelde Atomizer tasarımı ile saniyede 170 bin işlem ulaşılırken 2PC tasarımı ile saniyede 1,7 milyon işlem gerçekleştirilmektedir.

Kripto paraların ortaya çıkması ile birlikte uluslararası para ödemeleri daha hızlı ve daha güvenilir bir duruma gelmiştir. Ülkelerin CBDC çalışmalarının artması ile birlikte farklı CBDC ağları arasında işlemlerin sağlanması için çalışmalar yapılmıştır. Jung ve Jeong [33] CBDC'ler arasında işlem yönetimini sağlamak, işlemleri kayıt etmek ve alışverişini mümkün kılmak için ISO/IEC 11.179 meta veri kaydına dayalı bir blok zinciri sistemi ve yönetimi önermektedir. Han vd. [34] birlikte çalışabilirliğin sağlanması için Blok Zincirler Arası İletişim (IBC) protokolü kullanılarak iletişimi sağlayan Cosmos blok zinciri tabanlı CBDC modeli önermektedir. Model, perakende CBDC olarak tasarlanmış ve gizliliğin sağlanması için "Grup Anahtar Yönetim Sistemi" önerilmiştir. Bu modelde konsensüs protokolü olarak BFT kullanılmıştır. Cos-CBDC ile heterojen blok zincirlerini bağlamak veya yan zincirler oluşturmak teorik olarak mümkündür. Bu sebeple, Cos-CBDC sınır ötesi ve toptan ödemede etkin bir şekilde kullanılabilir.

CBDC için bir diğer önemli unsur tasarımdır. Tasarım tercihi ise CBDC'nin yapısına göre değişmektedir. DDT tabanlı CBDC araştırmalarının perakende işlemler yerine genellikle toptan işlemlerin gerçekleştirilmesi üzerine yapıldığı [35] vurgulanarak toptan DDT sisteminde dağıtılan dijital para birimi veya tokenin bankalar tarafından sağlanan hesaplar aracılığı ile perakende kullanıcıların erişebildiği CBDC tasarımı önerilmektedir. Toptan CBDC bankalar arasındaki verimliliği ve dijital para dolaşımının kontrolünü artırabilir. Ancak toptan CBDC'nin kullanıldığı bir durumda perakende işlemlere erişim kısıtlanacak ve CBDC'nin avantajları kaybolacaktır. Bu sorunun çözümü için modelde, perakende işlemler için dijital paraları dağıtmak üzere

ticari bankalarda DDT tabanlı toptan CBDC ağı ve DDT olmayan sistemleri entegre edecek bir tasarıma odaklanılmıştır. Benzer bir biçimde [36] iki katmanlı bir CBDC modeli önermektedir. Dağıtım katmanı, merkez bankası ve ticari bankalar arasındaki izinli blok zinciri ağına dayalı toptan CBDC'nin kayıtlarının tutulduğu zincirdir. Kullanıcı katmanında ise perakende CBDC kayıtları yer almaktadır. İki ayrı katmanın oluşturulması, ağ trafiğini azaltarak daha ölçeklenebilir bir sistem sunar.

Blok zinciri tarafından sağlanan hizmetler nedeniyle finansal kurumlar ve bankalar finansal sistemden dışlanabilir. Önerilen birçok CBDC modelinde bankacılık sisteminin dışlandığını vurgulayan [37] mevcut bankacılık sistemini etkilemeden uygulanabilecek dolaylı bir CBDC tasarımı önermektedir. İzinli bir blok zinciri mimarisinde tanımlanan CBDC modeli mevcut bankacılık sisteminde birkaç değişiklik yapmaktadır. Dijital ödemeler, ödeme ağları ve ödeme işlemcileri ile çevrimiçi olarak gerçekleşmektedir. Ancak son kullanıcının sisteme erişemediği veya erişim problemi yaşadığı durumlar söz konusu olmaktadır. Bu bağlamda [38] çevrim dışı ödemeleri (OPS) mümkün kılan bir CBDC modeli önermektedir. Dijital paranın güvenli bir şekilde transferinin sağlanması amacıyla sertifika yetkilisi olan merkez bankası, dijital imza oluşturmak için diğer finansal kurumlar ile ortak anahtar kriptografisi kullanarak iki katmanlı hiyerarşik bir anahtar alt yapısı oluşturmuştur. Bu güvenli anahtar yapısı, sertifika alt yapısını CBDC ödemelerinden ayırmakta ve bankalar gibi cüzdan sağlayıcılarının dijital para işlemlerini daha hızlı ve güvenilir bir şekilde gerçekleşmesine olanak tanımaktadır.

Literatürde yer alan CBDC tasarımlarında ölçeklenebilirlik problemlerinin çözümü için çift katmanlı yapılar ve birden fazla blok zincirin olduğu tasarımlar yer almaktadır. Buna göre merkez bankalarının etkin bir CBDC tasarlarken mevcut sorunların üstesinden gelebilmek için blok zinciri teknolojisini geleneksel yapılardan farklı bir biçimde ele almaları gerekmektedir. Bununla birlikte kripto paraların sunduğu mahremiyet, CBDC tasarımlarında genel olarak ihmal edilen bir meseledir. Merkezi olmayan kripto paralarda kullanıcılar sisteme açık (public) ve özel (private) anahtarları ile dahil olmaktadır. Merkezi bir yapıya sahip olan CBDC'lerde ise Müşterini Tanı (KYC), Sertifika Yetkilisi (CA) gibi uygulamalar ile kullanıcılar sisteme dâhil olmaktadır. Bu mimari içerisinde token tabanlı bir CBDC tasarımının tercih edilmesi kullanıcılara mahremiyet sağlayabilir. Ancak kullanıcıların açık ve özel anahtarlarını nereden ve nasıl alacağı burada önem kazanmaktadır. Merkez bankasının bu anahtarları verdiği bir durumda mahremiyet ortadan kalkacaktır.

4. CBDC TASARIMLARINDA ALTERNATİF PROTOKOL TASARIMLARI (ALTERNATIVE PROTOCOL DESIGNS IN CBDC DESIGNS)

Konsensüs protokolleri, sistem içerisinde yer alan üyelerin başarısızlıklardan kurtulup fikir birliği sağlanmasına olanak tanımaktadır. DDT’de ve blok zinciri teknolojisinde kullanılan protokoller temelde fikir birliğini sağlasa da işleyiş ve verimlilik bakımından farklılıklar ortaya çıkmaktadır. Blok zinciri teknolojisinde işlem verimliliği sistem içerisinde kullanılan konsensüs protokolüne göre değişiklik göstermektedir. PoW ve PoS protokollerinin düşük işlem hızı göz önünde bulundurulduğunda bir ülkenin CBDC tasarımı için protokol tercihi önem kazanmaktadır. Gün içerisinde milyonlarca işlemin onaylanması gerektiği bir durumda PoW protokolü gibi işlem hızının düşük olduğu protokol yapıları ölçekleme problemini ortaya çıkarmaktadır. Bununla birlikte kullanılacak protokolün enerji tüketimi açısından da verimli olması gerekmektedir. Bu bölümde CBDC tasarımlarında yer alan protokollerin (PoW, PoS, DPoS, PBFT, PoA ve Raft) teknik yapıları incelenmiştir.

PoW protokolünün ilk uygulaması Bitcoin olduğu için protokol, Bitcoin üzerinden ele alınmıştır. Bitcoin’de bir bloğun oluşturulması ortalama 10 dakikaya tekabül etmektedir ve ortalama sapması durumunda blok oluşturmak için istenen özütün zorluğu nonce³ değeri ile algoritmik olarak ayarlanmaktadır. Bu süre içerisinde madenciler rekabete girerek bloğun nonce değerini bulmaya çalışmaktadır. Bloğun nonce değerinin bulunmasının ardından madenci özeti bulduğunu ağa bildirmektedir. Ağda bulunan düğümler bloğun doğruluğu konusunda konsensüs sağladığında blok zincirine eklenmektedir ve madenci oluşturduğu bloktan ödül olarak Bitcoin ve işlem ücretlerini almaktadır. Nakamoto’nun bu önerisi ile “Bizans Generalleri Problemi” çözülsede sistem hala saldırılara açıktır. Ağ içerisinde kötü niyetli olan kişilerin oranı %51 olduğunda sistemi manipüle etmek mümkündür⁴.

PoS protokolü, cüzdanında para tutan her bir kullanıcının düğüm olduğu bir sistemdir. PoW protokolünün yarattığı yüksek enerji maliyetlerinin ortadan kaldırılması için geliştirilen bir modeldir [39]. Bu protokole göre, bir düğüm cüzdanında ne kadar çok kripto para tutarsa ve ne kadar erken sisteme dahil olursa bir sonraki bloğun oluşturulması için o kadar fazla şansa sahip olacaktır. Bu yüzden PoS’da yeni bir blok oluşturma hisse kanıtı ile ilişkilidir. Yeni blok oluşturmak için madenciler servetlerine göre seçilir. Bloğu oluşturan madenciler ödül olarak aldıkları servetlerin bir

bölümünü paylaştıklarından güvenilir kabul edilmektedir [40].

PBFT protokolü dağıtık hesaplama sistemlerinde kullanılmakta ve Bizans Generalleri probleminin başarısızlığını belli bir düzeyde tolere etmektedir. HyperLedger sisteminde kullanılan bu konsensüs protokolü, kullanıcıların platforma daha önce kayıtlı olması nedeniyle izinli blok zinciri sistemlerinde kullanılmaktadır [41]. Bu protokole her düğümün birer açık ve özel anahtarı bulunmaktadır ve düğümler birbirinin açık anahtar bilgisine sahiptir. Yeni bir blok oluşturulduğunda bloğu oluşturan düğüm diğer düğümlerden doğrulama yanıtını beklemektedir. Doğrulama yapan düğümler tüm düğümlerin içerisinde 2/3’e sahip olduğunda işlem onaylanıp üzerinde uzlaşma sağlandığı kabul edilerek blok, muhasebe defterine eklenmektedir. Bu protokol merkezi bir yapının izni ile yeni katılımcı kabul etmektedir. Bu sebeple izinsiz blok zinciri sisteminde kullanılmamaktadır.

PoS’un bir alt protokolü olan DPoS protokolü, iki katmanlı temsili demokrasi ve gerçek zamanlı oylama kullanılmaktadır. DPoS’da oylama sistemi blok zincirin daha demokratik bir yapı sağlanmasına olanak sağlar. Bu protokole, kripto parası olan güvenilir bir grup oylama ile seçilmektedir. Bu grubun kontrolü ile bloklar oluşturulmaktadır. Bu grubun dışında kalan diğer bir grup ise blokların oluşturulmasını sağlamakta ve bunun karşılığında ödül almaktadır.

2017 yılında Ethereum’un kurucu ortağı Gavin Wood tarafından tanıtılan PoA protokolü, blok zinciri sistemlerine verimlilik sunan fikir birliği algoritmasıdır. Bu protokole PoS protokolünden farklı olarak düğümler hesaplarında token tutmak yerine kimlikleri ile sisteme dahil olmaktadır. Daha çok izinli blok zinciri yapısına uygun olan bu protokole düğümler merkezin onayladığı bir komiteden oluşmaktadır ve sınırlı sayıda düğüm yer almaktadır. Aynı zamanda izinli zincirlerde PoA protokolü, performans ve verimlilik bakımından PoW protokolüne tercih edilir [42]. PoW’a göre sınırlı sayıda blok doğrulayıcısının olması sistemin daha ölçeklenebilir bir yapıya sahip olmasına olanak tanımaktadır. Bu sisteme dahil olmak isteyen doğrulayıcılar “kimlik kanıtı” DApp’ini kullanarak kimliklerini kanıtlamak zorundadır⁵. Ağ kurallarının bir madenci tarafından ihlal edilmesi durumunda ağda bulunan diğer katılımcılar sorunun çözümü için yasal haklara başvurabilecektir. Bir madenci ağa katılırken doğrulayıcılardan aldığı anahtarı üç

³ Verilerin SHA-256 formatında özütü oluşturulurken başında ‘n’ adet sıfır olması istenmektedir. İstenen ‘n’ adet sıfır PoW mekanizmasının zorluğuna göre değişmektedir. Madenciler istenilen zorluğa sahip başında ‘n’ adet sıfır olan özüt değerine ulaşmak için nonce değerini

kullanmaktadır. Tek kullanımlık sayı (nonce) değeri madenciler tarafından değiştirilerek istenilen özel özüt değer elde edilmeye çalışılır.

⁴ Bu saldırıya “%51 saldırısı” adı verilir.

⁵ <https://github.com/PoAnetwork/wiki/wiki/POA-Network-Whitepaper>

anahtarla değiştirmesi gerekmektedir. Bunlar, madencilik anahtarı, oylama anahtarı ve ödeme anahtarıdır.

Konsensüs algoritmalarında Leslie Lamport tarafından oluşturulan Paxos önemli bir konuma sahiptir ve çoğu konsensüs algoritması bu protokole dayanmakta veya ondan etkilenmektedir [43]. Paxos algoritması pratik sistemleri desteklemesi açısından oldukça karmaşık ve anlaşılması zor bir protokoldür. Bu karmaşadan hareketle daha işlevsel ve anlaşılması kolay olması amacıyla Raft protokolü hayata geçirilmiştir. Bu protokol, çoğaltılmış sıralı kayıtları yönetmek için kullanılan bir algoritmadır. Protokol içerisinde sunucular üç durumdan birindedir; lider, takipçi, aday. Protokolde ilk olarak küme içerisinde yer alan sunuculardan bir tanesi lider olarak seçilmekte ve lidere sıralı kayıtları yönetmesi için tam yetki verilmektedir. Lider, istemcilerden gelen sıralı kayıt girişlerini kabul eder ve bunları sunucularda çoğaltır. Bununla birlikte lider, sunuculara sıralı kayıtları durum makinelerine işlemenin ne zaman güvenli olduğunu söyler. Burada veri kayıtlarının tutarlı olması ve fikir birliği sağlanması için her sunucu aynı çıktıyı veren bir algoritma kullanmaktadır. Lider diğer sunucularla uzaktan prosedür

çağruları (RPC) ile iletişime geçmektedir. Bu protokol yapısında verilerin tek merkezden girilmesi fikir birliğinin daha hızlı olmasına dolayısıyla işlem hızının daha yüksek olmasına neden olmaktadır.

5. CBDC'DE KULLANILAN KONSENSÜS PROTOKOLLERİNİN KARŞILAŞTIRMALI ANALİZİ (COMPARATIVE ANALYSIS OF CONSENSUS PROTOCOLS USED IN CBDC)

Bu bölümde blok zinciri ve CBDC'de kullanılan protokollerin karşılaştırmalı analizi, iki sektör uzmanı ve üç akademisyenle yapılan görüşmeler sonucunda elde edilen verilerle yapılmıştır. Çalışmada yarı yapılandırılmış mülakatla on bir soru sorulmuş ve katılımcıların bir kısmı ile yüz yüze görüşmeler yapılırken bir kısmının görüşleri form ile alınmıştır. Çalışma kapsamında PoW, PoS, DPoS, PoA, PBFT ve Raft protokolleri analiz edilmiştir. Bu bağlamda verimlilik, blok zinciri türü, işlem hızı, iletişim karmaşıklığı ve enerji tüketimi parametreleri belirlenerek protokollerin verimlilik, güvenlik ve mahremiyet katmanları incelenmiştir.

Tablo 1. Protokol Yapılarının Analizi
(Analysis of Protocol Structures)

Protokol	Avantaj	Dezavantaj	Sınıflandırma
Proof of Work (PoW) – İş İspatı	-Yüksek Güvenilirlik -Adalet -Saldırlara Karşı Dirençli	-Enerji Maliyetleri -Yüksek CPU-GPU talebi -Düşük işlem hızı	Genellikle izinsiz blok zinciri ağlarında kullanılır (Bitcoin)
Proof of Stake (PoS) – Hisse Kanıtı	-Düşük enerji talebi -PoW'a göre madencilik düşük maliyetli -PoW'a göre ağa katılmak daha kolaydır	-Güvenilirliği düşük -Adaletsiz -Çatallaşma ihtimali yüksek	İzinsiz blok zinciri ağlarında kullanılır (Ethereum)
Delegated Proof of Stake (DPoS) – Temsili Hisse Kanıtı	-PoS'a göre daha adil -Çift katmanlı -Esnek uzlaşma	-Delege kartelleri oluşabilir -Merkezi bir hale gelebilir -Saldırlara daha az dirençli olabilir	Hibrit bir protokoldür ve izinsiz blok zinciri ağlarında kullanılır (BitShares)
Proof of Authority (PoA) – Yetki İspatı	-Kimlik temelli itibar sistemi -Mesajlaşma ağı hafiftir -Doğrulamacılar itibarını korumak için güven oluştururlar	-Teşvik sistemi dengesiz olabilir -Merkezileşme sorunu ortaya çıkabilir -Sonuç olarak saldırılara açık hale gelebilir	İzinli veya izinsiz blok zinciri ağlarında kullanılır (VeChain)
Practical Byzantine Fault Tolerance (PBFT) – Pratik Bizans Hata Toleransı	- Yüksek işlem hacmi -Delegeler oylama sistemine göre seçilir -Onaylama süresi kısadır	-Mesajlaşma ağı ağırdır -Ağ merkezi hale gelebilir -Ağ yeni delegeler için cazip olamayabilir	Genellikle izinli veya konsorsiyum blok zinciri ağlarında kullanılır (Hyperledger Fabric)
Raft Protokolü	-Yüksek işlem hacmi -Lider oylama sistemine göre seçilir -Doğrulamacılığы yüksektir	-Sunucular arasında iletişim problemi yaşanabilir -Enerji kullanımı fazladır -Karar almada olası gecikme	DDT'lerde kullanılır

Tablo 1’de incelenen protokoller yarı yapılandırılmış mülakat ile elde edilen verilerle blok zinciri türüne göre sınıflandırılmış ve karşılaştırmalı analizde belirlenen parametreler bağlamında avantaj ve dezavantajları saptanmıştır.

PoW’da blok oluşturma hızı CPU ve GPU gücü ile doğru orantılıdır. Dolayısıyla Bitcoin’de işlem hızını ve verimliliği etkileyen üç unsur ortaya çıkmaktadır; blok boyutu, blok aralığı ve CPU gücü. PoW protokolünün verimliliğini Bitcoin üzerinden açıklayabiliriz. Bitcoin’in 10 dakikalık ortalama blok aralığı ve her blok için ortalama 1 MB boyutu göz önüne alındığında, verim 7 TPS ile sınırlıdır [44]. CBDC gibi yüksek işlem talebinin olduğu bir durumda saniyede 7 işlemin yapılması sistemde ölçekleme problemini ortaya çıkarabilmektedir. Buna ek olarak Bitcoin’de işlemlerin doğrulanması için özel donanım ve yüksek miktarda enerji gerektirmektedir [45]. PoW protokolü CPU gücü ile ilişkili olması ve blok oluşturmak için yüksek miktarda enerji gerektirmesi nedeniyle enerji kullanımı açısından da verimsiz bir sistemdir. PoW protokolünün güvenliği özel donanım ve elektrik gibi kıt kaynaklara bağlı olduğundan sistemi kaynak açısından verimsiz hale getirir böylece madenciler karını arttırmak için sürekli olarak daha fazla kaynak kullanmaya mecbur kalmaktadır [46]. PoW protokolünün bu verimsizliği nedeniyle CBDC tasarımlarında tercih edilmeyen bir protokoldür. Katılımcılara göre PoW protokolünde işlem sayısını arttırmak mümkün olsa da blok boyutunun sınırlı olması işlem sayısını belli bir yere kadar arttırmaktadır ve enerji verimliliği açısından etkin bir protokol değildir. PoW protokolü yapısı itibarıyla tamamıyla merkeziyetsiz bir sistem sunmaktadır. Bu protokolda birkaç madenci ekosistemden ayrılrsa da sistem işlemeye devam etmektedir. Bununla birlikte PoW protokolü %51 saldırısına açıktır. Kötü niyetli madencilerin yarısından bir fazlasına ulaşması durumunda sistem manipüle edilecektir. Katılımcılar, merkez bankalarının para üzerindeki tekel hakkını kaybetmemek için tamamıyla merkeziyetsiz bir sistem sunan PoW protokolünün tercih edilmeyeceğini düşünmektedir.

PoW’da enerji ve buna bağlı olarak ortaya çıkan verimlilik sorunu PoS protokolü ile çözülmeye çalışılır. PoS protokolünün temel mantığında kullanıcıların varlıklarını stake etmeleri yatmaktadır. Kripto para birimine olan güvenin ortadan kalkması durumunda kullanıcıların stakeleri değersizleşecektir. PoS protokolünün etkin bir şekilde çalışması için ekonomik bir teşvik gerekmektedir [47]. PoS protokolünün PoW’a göre fiziksel maliyetleri görece düşük olduğundan katılımcıların birincil maliyeti, ödülleri toplamak için teminat olarak stake etmektir [48]. Madenci faaliyetleri görece daha az enerji maliyetlerine yol açtığından PoS protokolünün PoW protokolüne göre

daha verimli olduğu söylenebilir. Fakat PoS protokolünün daha çok izinsiz blok zincir türünde kullanılması merkez bankalarının CBDC tasarımında kullanımını zorlaştırabilir. Aynı zamanda PoS’un çatallaşma ihtimalinin olması CBDC için etkin bir protokol olmayabilir. Simülasyon deneylerinden elde edilen bulgulara göre [49]; PoS protokolü PoW protokolüne göre enerji tüketimini %75’ten fazla azaltabilmiştir. Aynı zamanda PoS protokolünün güvenilirlik ve adalet açısından düşük olduğu bulgularına ulaşmıştır. Karma protokol yapılarının enerji, güvenilirlik ve adalet açısından daha etkin olduğu gözlenmiştir. Böylece CBDC için de karma bir protokolün tercih edilmesi PoS’da ortaya çıkacak sorunların çözülmesini sağlayabilir. Katılımcılara göre verimlilik açısından PoS protokolü etkin bir sistem olsa da işlemleri onaylayanların stake miktarına göre işlem onaylama önceliğini elde etmesi adaletsiz bir yapı ortaya koymaktadır. PoW’a göre PoS protokolünün alternatif olarak ortaya çıkmasındaki temel unsurlardan biri çevreye verdiği zarardır. PoW’un yarattığı karbon emisyonu PoS mekanizması ile azaltılabilmektedir. Böylece PoS protokolü PoW’a göre daha etkin bir yapı sunarak çevreye olan etkileri bakımından daha duyarlı bir mekanizmaya sahiptir.

CBDC tartışmalarında genel olarak bir merkezin onayının gerektiği üzerine fikir birliği olması nedeniyle PBFT protokolü sıkça modellerde kullanılmıştır. PBFT protokolünün sıkça kullanılmasının bir diğer sebebi ise verim avantajı sağlamasıdır. Bununla birlikte PBFT protokolü ağ iletişim yükünün fazla ve sistem esnekliğinin düşük olması sorunlarına sahiptir [50]. Ağın iletişim yükünün fazla olması verimliliği olumsuz etkileyebilmektedir. Bu yüzden PoA ile kıyaslandığında PBFT’nin iletişim gücü verimsiz kalmaktadır. Dolayısıyla CBDC protokol tasarımları ele alınırken iletişim gücü ağ verimliliği açısından oldukça önemlidir. CBDC’ler ülke ekonomilerini kapsadığından iletişim yükünün fazla olduğu protokol yapıları verimliliği olumsuz etkileyebilecektir.

DPOS protokolü çift katmanlı ve esnek uzlaşma sağlaması ile PoS protokolünden farklılaşmaktadır. Dolayısıyla DPOS, PoW ve PoS’a göre daha hızlı işlem sağlamaktadır [51]. DPOS’un demokratik yapısı, ağ üzerinde kullanıcılara kontrol hakkına olanak tanıyarak blok zincirin verimliliğini arttırmaya çalışır. DPOS protokolü ağ üzerinde kullanıcılara kontrol hakkı sunabildiğinden PoW’a göre daha verimli bir ağ kullanıcılığı ve madencilik yapısı sunmaktadır [52]. Çünkü PoW protokolünde yalnızca madenciler ödüllendirildiğinden, gelirini maksimumlaştırmak için çabalayacaklardır dolayısıyla bu yapı madenciler ve para sahipleri arasında çatışmaya sebep olabilecektir. Aynı zamanda DPOS protokolü bakım

maliyetlerini azaltması nedeniyle blok zincirinin verimliliğini arttırmaktadır. DPoS, PoS protokolünün dezavantajlı yapılarına çözüm getirdiğinden CBDC tasarımlarında daha kullanışlı bir yapı sunabilir. Merkez bankalarının işlem hacminin yüksek olduğu, esnek uzlaşma ve iletişim yükünün hafif olduğu protokol yapılarını CBDC tasarımında tercih etme ihtimalleri yüksektir. Bu yüzden CBDC'nin protokol yapısında DPoS benzeri bir konsensüs mekanizması verimliliği artırabilir ve bakım maliyetlerini azaltabilir.

PoA protokolünün izinli blok zincirlerde daha sık kullanılmasının sebebi mesajlaşma ağına daha az ihtiyaç duymasından kaynaklanmaktadır. Dolayısıyla mesajlaşma ağının daha hafif olması protokolün performansını arttırmaktadır [53]. PoA'nın daha düşük haberleşme ağına ihtiyaç duyması ve kimlik doğrulaması gerektirmesi izinli blok zinciri yapılarında verimliliği arttıracak potansiyele sahiptir [54]. PoA ve PBFT protokollerinin doğrulama mekanizmalarının sınırlı olması ağlarda merkezileşme sorununu ortaya çıkarabilir. Ağda merkezi yapının oluşmaya başlaması blok zinciri saldırılara daha açık hale getirebildiğinden bu yapıların merkezileşmemesi önem kazanmaktadır. PoA ve PBFT protokollerinin bu benzerlikleri dikkate alındığında CBDC tasarımını saldırılara açık hale getirme potansiyelleri barındırmaktadır. Dolayısıyla etkin bir CBDC tasarımının önemli kriterlerinden bir diğeri saldırılara karşı dirençli protokol yapısının sağlanmasından geçmektedir. Böylece merkez bankalarının tercih edecekleri protokol yapıları dikkate alındığında bu yapıların avantaj ve dezavantajları hakkında fikir sahibi olmaları önemlidir. Bununla birlikte katılımcılara göre PoA protokolüne dâhil olacak delegelerin kimliğiyle sisteme katılması, kötü niyetli saldırıların önüne geçmenin önemli bir unsurudur. PoA protokolünün bir diğer avantajı ise işlem sayısının yüksek olmasına bağlı olarak birim işlem maliyetlerini azaltmasıdır. İşlem sayısının yüksek olması ise ağda bulunan bütün onaylayıcılar yerine otorite tarafından seçilen onaylayıcıların büyük çoğunluğunun işlemin doğruluğunu kabul etmesi durumunda bloğa kaydedilmesinden kaynaklanmaktadır. İletişim sürecini kısaltan bu uygulama işlem hızını arttırmaktadır. Bu protokolün merkez bankası tarafından kullanılması, onaylayıcıların merkez bankası tarafından belirlenmesi anlamına gelmektedir. PoA protokolünün en büyük dezavantajı ise mahremiyeti ortadan kaldırması ve merkezi bir yapı statüsü sunmasıdır. Merkez bankası açısından bakıldığında para üzerindeki kontrolün merkezi olarak sağlanması için PoA protokolü işlevsel protokollerden biridir.

Raft protokolünde sunucuların lider, takipçi ve aday olması ve bu yapıda liderin oylama sistemine göre seçilmesi PoW

ve PoS protokollerine göre daha demokratik bir yapı sunmaktadır. İşlemlerin lider eşliğinde gerçekleşmesi iletişim yükünü azaltarak işlem hızını arttırmaktadır. Ancak enerji ihtiyacının PoW'daki gibi yüksek olması protokolün önemli bir dezavantajıdır. Bununla birlikte Raft protokolünde oylama sisteminin olması, sisteme gelecek güncelleme ve yeniliklerde oy birliğinin sağlanması gerektiği durumlarda karar almada olası gecikmeler ortaya çıkabilir. Bu protokolün daha çok DDT'lerde kullanılması ve veri girişinin tek bir merkezden yapılması CBDC tasarımında mahremiyeti zedeleyebilir. Buna ek olarak veri girişinin tek merkezden yapılması merkez bankasını saldırılara karşı daha açık bir hale getirebilir.

6. SONUÇ (CONCLUSION)

Merkez bankası dijital parası tasarımlarında ölçeklenebilirlik probleminin çözülmesi için genel olarak çift katmanlı yapılar ve birden fazla blok zincirinin kullanımı önerilmiştir. CBDC'de kullanılan protokollerin verimliliği ise ikincil planda tutulmuştur. CBDC'lerde kullanılan protokollerin karşılaştırmalı analiz sonuçlarına göre Raft protokolü ile yüksek işlem gücüne ulaşılsa da enerji kullanımı bakımından dezavantajlıdır [55]. Protokollerin verimliliğinin artmasında iletişim sürecinin kısa olması önemlidir. PoA protokolünde iletişimsel sürecin kısa olması işlem hızını arttırmaktadır. Bununla birlikte CBDC'lerin bir merkezin kontrolünde olacağı göz önünde bulundurulduğunda PoA protokolü hem yasal bir zemin sağlamakta hem de ağı genişletilebilir olması nedeniyle işlem hacminin yetersiz kaldığı bir durumda avantaj sağlamaktadır. Bankaların CBDC mimarisi içerisindeki konumu ise PoA protokolünde onaylayıcı olarak yer almasına fırsat sunmaktadır. Aynı zamanda PoA protokolünde bankalara yönelik teşvik sisteminin de verimliliği olumsuz etkilemeyecek yapıda olması gerekmektedir. Teşvik sisteminin asimetrik olması ağı saldırılara açık hale getirme ihtimalini ortaya çıkarabilmektedir. Bu yüzden sadece tek bir protokolün olanakları üzerinden tasarlanan CBDC, verimliliği olumsuz etkileyebilir.

PoW protokolünün genellikle izinsiz blok zinciri ağlarında kullanılması ve yüksek işlem hacmine ulaşmak için enerji tüketiminin fazla olması CBDC tasarımında bu protokolün etkin çalışmamasına neden olmaktadır. Bununla birlikte etkin bir CBDC tasarımında kullanılacak protokolün güvenli, işlem hacmi yüksek, ölçeklenebilir ve verimli olması gerekmektedir. Bu yüzden sadece bir protokolün olanaklarından faydalanmak yerine hibrit protokoller geliştirilerek oluşturulacak protokolün zayıf yönleri güçlendirilebilir. Karşılaştırmalı analize göre elde edilen sonuçlardan biri CBDC tasarımlarında kullanılan protokollerin güçlü yönleri dikkate alınarak hibrit bir protokol oluşturulabilir. Protokol yapısının güçlü olması

dijital paranın etkinliğini arttırarak para politikası bağlamında CBDC'nin kullanılabilirliğini arttırabilir. Görüldüğü üzere yüksek performanslı, enerji ihtiyacı düşük ve verimli bir CBDC tasarımı için protokollerin yapısı CBDC tasarımlarında önemli bir unsurdur.

CBDC tasarımlarında göz ardı edilen bir diğer unsur ise mahremiyettir. Token tabanlı bir CBDC'nin tasarlanması durumunda bu problem çözülebilir. Bununla birlikte etkin bir CBDC tasarımı için izinli bir blok zinciri daha avantajlıdır. Böylece sisteme dahil olmak isteyen herhangi bir finansal kuruluş merkez bankasının onayı ile katılacaktır. İzinli bir blok zincirinin kullanılması aynı zamanda sistemi %51 saldırısına karşı daha dirençli hale getirebilir. Ancak bu durumda yine mahremiyet arka planda kalacaktır. Semi token tabanlı bir CBDC tasarımının tercih edilmesi ise kullanıcılara belli bir düzeyde mahremiyet sağlamaktadır. Bu bağlamda mahremiyet, CBDC tasarımında otoritenin tercih edeceği tasarıma göre değişmektedir.

Çalışma kapsamında verimlilik, blok zinciri türü, işlem hızı, iletişim karmaşıklığı ve enerji tüketimi parametreleri dikkate alınarak protokollerin karşılaştırmalı analizi CBDC literatürünü kapsayacak şekilde yapılmıştır. Bu bağlamda yarı yapılandırılmış mülakat ile elde edilen bulgular literatürle uyumludur. Gelecek çalışmalarda rakip tolerans modeli, gecikme ve bant genişliği gibi parametreler de eklenerek karşılaştırmalı analiz genişletilebilir. Buna ek olarak elde edilen bulguların ilerleyen çalışmalarda nicel olarak analiz edilmesi daha doğru sonuçlar üretecektir. Böylece CBDC'de kullanılacak protokollerin etkinliği, güçlü ve zayıf yönleri daha detaylı analiz edilebilir.

TEŞEKKÜR (ACKNOWLEDGMENT)

Bu çalışmaya görüşleri ile destek veren mfer.earth uzmanlarına ve değerli akademisyenlerimize teşekkürü borç biliriz.

KAYNAKLAR (REFERENCES)

- [1] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System", *Decentralized Business Review*, 21260, 1-9, 2008.
- [2] P. K. Ozili, "Central bank digital currency research around the World: a review of literature", *Journal of Money Laundering Control*, 2022.
- [3] F. Allen, X. Gu, J. Jagtiani, "Fintech, cryptocurrencies, and CBDC: Financial structural transformation in China", *Journal of International Money and Finance*, 124, 102625, (2022).
- [4] P. K. Ozili, "Central bank digital currency in Nigeria: opportunities and risks", Available at SSRN, (2021).

- [5] S. L. Nález Alonso, M. A. Echarte Fernández, D. Sanz Bas, J. Kaczmarek, "Reasons fostering or discouraging the implementation of central bank-backed digital currency: A review", *Economies*, 8(2), 41, 2020.
- [6] S. Haber, W. S. Stornetta, "How to Time-Stamp a Digital Document", **In Conference on the Theory and Application of Cryptography**, Cilt 537, Editör: Menezes A. J., Manstone S. A., Springer, Berlin, Heidelberg, Lecture Notes in Computer Science, 437-455, 1990.
- [7] C. Dwork, M. Naor. "Pricing Via Processing or Combatting Junk Mail", **In Annual International Cryptology Conference**, Cilt 470, Editör: Brickell E. F., Springer, Berlin, Heidelberg, Lecture Notes in Computer Science, 139-147, 1992.
- [8] D. Chaum, "Security Without Identification: Transaction Systems to Make Big Brother Obsolete", *Communications of the ACM*, 28(10), 1030-1044, 1985.
- [9] G. Bashar, G. Hill, S. Singha, P. Marella, G.G. Dagher, J. Xiao, "Contextualizing Consensus Protocols in Blockchain: A Short Survey", **2019 First IEEE International Conference on Trust, Privacy and Security in Intelligent Systems and Applications (TPS-ISA)**, IEEE, Lahor-Pakistan, 190195, 1921 December, 2019.
- [10] N. Chaudhry, M. M. Yousaf, "Consensus Algorithms in Blockchain: Comparative Analysis, Challenges and Opportunities", **In 2018 12th International Conference on Open Source Systems and Technologies (ICOSST)**, IEEE, Lahor-Pakistan, 5463, 1921 December, 2018.
- [11] Q. Wang, J. Huang, S. Wang, Y. Chen, P. Zhang, L. He, "A Comparative Study of Blockchain Consensus Algorithms", *In Journal of Physics: Conference Series*, 1437(2020), 332-339, 2020.
- [12] A. Baliga, "Understanding Blockchain Consensus Models", *Persistent*, 4(1), 1-17, 2017.
- [13] D. Mingxiao, M. Xiaofeng, Z. Zhe, W. Xiangwei, C. Qijun, "A Review on Consensus Algorithm of Blockchain" **In 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)**, IEEE, Banff, AB, Canada, 25672572, 0508 October, 2017.
- [14] O. Demir, H. Odabaşı, "Merkez Bankası Dijital Para Sisteminin Avantaj ve Dezavantajları Neler Olabilir? *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (61), 199-222, 2022.
- [15] İ. Al, H. Akyazı, "Merkez Bankası Dijital Parası ve Para Politikasına Yansımaları", *Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 19(3), 573-593, 2019.
- [16] K. Sebahattin, "Paranın Dijitalleşmesi ve Merkez Bankası Dijital Para Olasılığı", *Bitlis Eren Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Akademik İzdüşüm Dergisi*, 5(2), 196-204, 2020.
- [17] N. Öztürk, A. Okan, "Paranın Dönüşümünde Yeni Bir Evre: Merkez Bankası Dijital Parası", *Uluslararası Muhasebe ve Finans Araştırmaları Dergisi*, 3(2), 85-104, 2021.
- [18] Y. Toroman, "E-Para ve Tokenler (Dijital Türk Aakçesi) İle Borçlanma: Dijital Türk Lirası (DTL) Üzerine Bir Çalışma", *Bilge Uluslararası Sosyal Araştırmalar Dergisi*, 5(2), 124-134, 2019.
- [19] G. Calle, D. Eidan, "Central Bank Digital Currency: An Innovation in Payments", *R3 White Paper*, 1-20, 2020.

- [20] D. Priyadarshini, S. Kar, "Central Bank Digital Currency (CBDC): Critical Issues and the Indian Perspective", *Institute of Economic Growth Working Paper*, No. 444, 2021.
- [21] M. D. Bordo, A. T. Levin, "Central Bank Digital Currency and the Future of Monetary Policy", *National Bureau of Economic Research*, Working Paper, No 23711, 1-30, 2017.
- [22] R. Auer, R. Böhme, "The Technology of Retail Central Bank Digital Currency", *BIS Quarterly Review*, March, 85-100, 2020.
- [23] S. M. Davoodalhosseini, "Central bank digital currency and monetary policy", *Journal of Economic Dynamics and Control*, 104150, (2021).
- [24] G. Ünal, Ç. Uluyol, "Blok zinciri teknolojisi", *Bilişim Teknolojileri Dergisi*, 13(2), 167-175, 2020.
- [25] Zhang, T., & Huang, Z. (2021). Blockchain and Central Bank Digital Currency. *ICT Express* 8, 264–270, 2022.
- [26] R. Auer, G. Cornelli, J. Frost, "Rise of the Central Bank Digital Currencies: Drivers, Approaches and Technologies", *Bank for International Settlements Working Paper*, 1-42, 2020.
- [27] N. Bilotta, F. Botti, **The (Near) Future of Central Bank Digital Currencies: Risks and Opportunities for the Global Economy and Society**, Bern, İsviçre, Peter Lang International Academic Publishers, 2021.
- [28] İnternet: D. Niepelt, Central Bank Digital Currency: Considerations, Projects, Outlook, <https://voxeu.org/article/central-bank-digital-currency-considerations-projects-outlook>, 10.06.2022.
- [29] W. Tsai, Z. Zhao, C. Zhang, L. Yu, E. Deng, "A Multi-Chain Model for CBDC", **2018 5th International Conference on Dependable Systems and Their Applications**, Dalian, China, 2534, 2223 September, 2018.
- [30] H. Sun, H. Mao, X. Bai, Z. Chen, K. Hu, W. Yu, "Multi-Blockchain Model for Central Bank Digital Currency", **2017 18th International Conference on Parallel and Distributed Computing, Applications and Technologies**, Taipei, Taiwan, 360367, 1820 December, 2017.
- [31] J. Zhang, R. Tian, Y. Cao, X. Yuan, Z. Yu, X. Yan, X. Zhang, "A Hybrid Model for Central Bank Digital Currency Based on Blockchain", *IEEE Access*, 9, 53589-53601, 2021.
- [32] J. Lovejoy, C. Fields, M. Virza, T. Frederick, D. Urness, K. Karwaski, N. Narula, "A High Performance Payment Processing System Designed for Central Bank Digital Currencies", *Cryptology ePrint Archive*, 1-35, 2022.
- [33] H. Jung, D. Jeong, "Blockchain Implementation Method for Interoperability Between CBDCs", *Future Internet*, 13(5), 133, 2021.
- [34] J. Han, J. Kim, A. Youn, J. Lee, Y. Chun, J. Woo, J. W. K. Hong, "Cos-CBDC: Design and Implementation of CBDC on Cosmos Blockchain", **22nd Asia-Pacific Network Operations and Management Symposium**, Tainan, Taiwan, 303308, 0810 September, 2021.
- [35] D. T. Sasongko, S. Yazid, "Integrated DLT and non-DLT System Design for Central Bank Digital Currency", **Proceedings of the 5th International Conference on Sustainable Information Engineering and Technology**, New York, United State, 171176, 1617 November, 2020.
- [36] S. Kumar, "Permission Blockchain Network Based Central Bank Digital Currency", **2021 IEEE 4th International Conference on Computing, Power and Communication Technologies**, Kuala Lumpur, Malaysia, 16, 2426 September, 2021.
- [37] S. Maharjan, K. Ko, C. Kang, J. Woo, J. W. Hong, "A Study of CBDC Model Applicable for the Current Banking Environment", **KNOM Conference 2020**, Daejeon, South Korea, 5660, 2020.
- [38] M. Christodorescu, W. C. Gu, R. Kumaresan, M. Minaei, M. Ozdayi, B. Price, M. Zamani, "Towards a Two-Tier Hierarchical Infrastructure: an Offline Payment System for Central Bank Digital Currencies", *arXiv preprint:2012.08003*, 1-21, 2020.
- [39] F. Saleh, "Blockchain Without Waste: Proof-of-stake", *The Review of Financial Studies*, 34(3), 1156-1190, 2021.
- [40] E. Deirmentzoglou, G. Papakyriakopoulos, C. Patsakis, "A Survey on Long-Range Attacks for Proof of Stake Protocols", *IEEE Access*, 7, 28712-28725, 2019.
- [41] S. Kardaş, "Blokzincir Teknolojisi: Uzlaşma Protokolleri", *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 481-496, 2019.
- [42] C. N. Samuel, S. Glock, F. Verdier, P. Guitton-Ouhamou, "Choice of Ethereum Clients for Private Blockchain: Assessment from Proof of Authority Perspective", **2021 IEEE International Conference on Blockchain and Cryptocurrency**, Sydney, Australia, 15, 0306 May, 2021.
- [43] D. Ongaro, J. Ousterhout, "In Search of an Understandable Consensus Algorithm", (extended version), 2013.
- [44] Y. Gao, H. Nobuhara, "A Proof of Stake Sharding Protocol for Scalable Blockchains", *Proceedings of the Asia-Pacific Advanced Network*, 44(1), 13-16, 2017.
- [45] U. Gallersdörfer, L. Klaufen, C. Stoll, "Energy Consumption of Cryptocurrencies Beyond Bitcoin", *Joule*, 4(9), 1843-1846, 2020.
- [46] O. Vashchuk, R. Shuwar, "Pros and Cons of Consensus Algorithm Proof of Stake. Difference in the Network Safety in Proof of Work and Proof of Stake", *Electronics and Information Technologies*, 9(9), 106-112, 2018.
- [47] C. Ganesh, C. Orlandi, D. Tschudi, "Proof-of-Stake Protocols for Privacy-Aware Blockchains", **Annual International Conference on the Theory and Applications of Cryptographic Techniques**, Darmstadt, Germany, 690719, 1923 May, 2019.
- [48] G. Fanti, L. Kogan, P. Viswanath, "Economics of Proof-of-Stake Payment Systems", *Working Paper*, 2019.
- [49] R. Zhang, W. K. V. Chan, "Evaluation of Energy Consumption in Block-chains with Proof of Work and Proof of Stake". *Journal of Physics: Conference Series*, 1584(1), 2020.
- [50] X. Zheng, W. Feng, "Research on Practical Byzantine Fault Tolerant Consensus Algorithm Based on Blockchain", *Journal of Physics: Conference Series*, 1802(3), 2021.
- [51] S. M. S. Saad, R. Z. R. M. Radzi, "Comparative Review of the Blockchain Consensus Algorithm Between Proof of Stake (PoS) and Delegated Proof of Stake (DPoS)", *International Journal of Innovative Computing*, 10(2), 27-32, 2020.
- [52] T. Do, T. Nguyen, H. Pham, "Delegated Proof of Reputation: A Novel Blockchain Consensus", **Proceedings of the 2019 International Electronics Communication Conference**, Okinawa, Japan, 9098, 0709 July, 2019.

- [53] S. De Angelis, L. Aniello, R. Baldoni, F. Lombardi, A. Margheri, V. Sassone, "PBFT vs proof-of-authority: Applying the CAP Theorem to Permissioned Blockchain", **Italian Conference on Cyber Security**, Milan, Italy, 26 February, 2018.
- [54] A. Avasthi, A. Saxena, "Two Hop Blockchain Model: Resonating Between Proof of Work (PoW) and Proof of Authority (PoA)", *International Journal of Information Systems & Management Science*, 1(1), 128-131, 2018.
- [55] J. F. Paris, D. D. Long, "Pirogue, a lighter dynamic version of the Raft distributed consensus algorithm", **2015 IEEE 34th International Performance Computing and Communications Conference**, Nanjing, China, 18, 1416 December, 2015.

Blok Zinciri Tabanlı Akademik Tavsiye Mektubu Sistemi Modeli

Araştırma Makalesi/Research Article

 Caner DEMİR¹,  Selçuk ÖZDEMİR²

¹Yönetim Bilişim Sistemleri, Gazi Üniversitesi, Ankara, Türkiye

²Bilgisayar ve Öğretim Teknolojileri Eğitimi, Gazi Üniversitesi, Ankara, Türkiye

caner.demir2@gazi.edu.tr, sozdemir@gazi.edu.tr

(Geliş/Received:12.08.2022; Kabul/Accepted:17.01.2023)

DOI: 10.17671/gazibtd.1161180

Özet— Tavsiye mektubu iş, staj ve eğitim başvurularında öğrenciler hakkında genel ve öznel bilgi sağlayan yaygın olarak kullanılan bir yöntemdir. Mevcut süreçlerde tavsiye mektuplarının fiziksel olarak alıcı kurumlara iletilmesi veya alıcı kurumların ilgili merkezi sunucularına çevrim içi portal aracılığı ile yüklenmesi yaygın olarak tercih edilmektedir. Fiziksel iletilen durumda belge ve dokümanların kaybolması; çevrim içi olarak iletilen belgelerde ise merkezi sunucuların doğası gereği verinin kaybolması, çalınması ve değiştirilmesi gibi riskler mevcuttur. Bu çalışmada mevcut süreçlerde yaşanabilecek sorunların önüne geçilebilmesi için blok zinciri tabanlı akademik tavsiye mektubu modeli önerilmektedir. Akıllı sözleşmeler kullanılarak izlenebilir, şeffaf, güvenli ve merkezi olmayan yapıda tasarlanan model ile birlikte mevcut süreçlerde yer alan ve kurumdan kuruma değişen farklı istek ve ihtiyaçların standart bir iş akışı getirilerek paydaşlar arası veri iletiminin otomatize edilmesi amaçlanmaktadır. Ethereum ağı kullanılarak tasarlanan sistemin mimari modeli, sözde kodları ve iş akışı detaylı olarak aktarılmakla birlikte paydaşların birbirleri arasındaki bilgi akışı sıra diyagramları ile tarif edilmektedir. Geliştirilen sisteme ait akıllı sözleşme kodları açık kaynak olarak Github üzerinden paylaşılmaktadır.

Anahtar Kelimeler— blok zinciri, akademik tavsiye mektubu, ethereum, akıllı sözleşme

Blockchain Based Academic Letter of Recommendation System Model

Abstract— Letter of recommendation is a widely used method that provides general and subjective information about students in job, internship and education applications. In the current processes, it is widely preferred that the letters of recommendation are physically sent to the recipient institutions or uploaded to the relevant central servers of the recipient institutions via an online portal. There are some risks such as loss of documents when they are physically transmitted and loss, theft and alteration of data in documents transmitted online due to the nature of central servers. In this study, a blockchain-based academic recommendation letter model is proposed to prevent problems that may occur in current processes. With the model designed in a traceable, transparent, secure and decentralized structure using smart contracts, it is aimed to automate data transmission between stakeholders by bringing a standard workflow for different requests and needs that take place in existing processes and vary from institution to institution. The architectural model, pseudo-codes and workflow of the system designed using the Ethereum network are explained in detail, and the information flow between the stakeholders is described with sequence diagrams. Smart contract codes of the developed system are shared on Github as open source.

Keywords— blockchain, academic letter of recommendation, ethereum, smart contract

1. GİRİŞ (INTRODUCTION)

Tavsiye mektubu, talep edenin kişilik özellikleri, çalışma alışkanlıkları ve iş deneyimi hakkında bilgi sağlayan yaygın kullanılan bir yöntemdir. Tavsiye mektupları, tipik olarak yazıldığı kişi için yaygın ve özel bilgiler sağlar [1]. Tavsiye verenlerin başvuru sahiplerini çeşitli boyutlarda tanımlamalarına olanak tanır ve kuruluşlar genellikle tavsiye yazarlardan bu bilgileri başvuru sahiplerinin belirli bir iş veya eğitim için uygunluğuna göre uyarlamalarını ister [2]. Akademik tavsiye mektubu ise başvuru pozisyonu dair ilgili öğrencinin becerilerini, kişisel özelliklerini ve yetkinliğini, onu iyi tanıyan öğretmen ve akademisyenlerin yorumlarıyla beraber yazdığı bir referans yazısıdır. Üniversitede okuyan lisans veya lisansüstü öğrenciler çeşitli iş ve eğitim başvurularında genellikle tavsiye mektubuna ihtiyaç duymaktadırlar. Tavsiye mektubunun ulaştığı alıcı kurum veya üniversite için birçok başvuru arasında doğru adayı seçme noktasında tavsiye mektuplarının önemli bir rolü bulunmaktadır. Öğrenciyi doğru ve açık bir şekilde tanımlayan tavsiye mektubu en uygun öğrencinin en kısa zaman içerisinde seçilmesine neden olarak hem maliyet hem de zaman tasarrufu sağlamaktadır [3]. Tavsiye mektupları öğrencilerin mezuniyet not ortalaması ve alınan derslerdeki başarısından sonra uygun aday belirleme aşamasında üçüncü önemli faktör olarak tanımlanabilmektedir [4]. Adayı başvurduğu rol için uygun olduğunu etkili bir şekilde ifade eden referans mektubu, ilgili kişiyi diğerleri karşısında bir adım öne çıkaran önemli bir etken olmaktadır [5].

Yüksek öğrenim öğrencilerinin üniversite, kamu ve özel kurum başvurularında akademik referans mektubu sıklıkla istenilen şartlardan birini oluşturmaktadır. Mevcut durumda referans yazısı iki şekilde alıcı kuruma ulaştırılmaktadır. İlk yöntem, geçmişten gelen yaklaşımı oluşturmakta olup zarf içerisinde kapalı ve imzalı olarak akademisyen tarafından ilgili öğrenciye teslim edilip daha sonra alıcı kuruma fiziksel olarak ulaştırılmasını oluşturmaktadır. Bu yöntem özellikle internet kullanımının yaygın olmadığı geçmiş dönemlerde daha çok kullanılmasına rağmen halen günümüzde de yaygın bir şekilde tercih edilmektedir. Bir diğer yöntemde ise öğrenci, ilgili akademisyenden aldığı gizli olmayan belgeyi dijital ortamda ilgili alıcıya e-posta olarak veya ilgili kurumun başvuru ortamında çevrim içi olarak ileterek gerçekleştirmektedir. Son yöntem ise, günümüzde daha çok tercih edilen şekilde, ilgili kurumun çevrim içi başvuru ortamından akademisyen e-posta adresine gönderilen tekil bir adres üzerinden erişilip referansın yüklenmesiyle tamamlanmaktadır.

Mevcut süreçte kullanılan yöntemler ile akademik tavsiye mektupları tahrif edilmeye müsait olmakla birlikte yanlış ve doğru olmayan beyan durumu bulunmaktadır. Bunun önüne geçmek için alıcı kurumlar ilgili akademisyene telefon veya e-posta ile ulaşarak doğrulama sağlamaktadır. Bu yöntem sürecin uzatarak zaman ve maliyet israfına sebep olmaktadır. Ayrıca fiziki olarak ulaştırılan belgeler her zaman kaybolma ihtimaliyle karşı karşıya kalmaktadır.

Dijital ortamda ulaştırılan yazılar da merkezi sunucularda oluşabilecek bir kesintiden etkilenecektir. Tek bir hata noktası (Single Point of Failure) merkezi sunucularda yaşanan önemli bir zafiyet türüdür. Bu zafiyet mevcut dijital veriye ulaşmada kesinti yaşanmasına ve hatta tamamen veri kaybına neden olabilmektedir [6].

SocialTalent adlı global düzeyde bir insan kaynakları kurumunun 1000'den fazla kurum ile birlikte yaptığı geniş kapsamlı bir anket araştırmasında, kurumların %17'den fazlası iş başvurularında sahte referans ile karşılaştıklarını belirtmişlerdir. Bu hileli tavsiye mektuplarının ise %80'den fazlasını başlangıç ve orta seviye pozisyonlar için temin edildiği bildirilmiştir. Belirli bir ücret karşılığında istenilen tavsiye mektubunu ilgili kişi için yazan çevrim içi ortam sayısı günümüzde hızla artmaktadır. Tavsiye mektubunun kişiler için iş ve akademik başvurularında önemli bir değerlendirme aracı olduğu düşünüldüğünde bu iş başvuru süreçlerine oldukça zarar verdiği açıktır [7].

Blok zinciri teknolojisi dünya genelinde Bitcoin kripto parasının başarısı ve etkisiyle adını duyurmuştur [8]. Genellikle dağıtık defter olarak da tanımlanan bu teknoloji tümüyle aynı kavramı ifade etmemektedir. Dağıtık defter birden fazla katılımcının çoklu lokasyonlarda tuttuğu veri tabanı olarak tanımlanabilirken blok zinciri teknolojisini kullanma zorunluluğu içermemektedir. Blok zinciri ise dağıtık defterin bir uygulaması olarak bir kayıt zinciri oluşturmak için defterdeki veri blokların kriptografik olarak imzalanarak bağlanması olarak ifade edilebilmektedir [9]. Blok zinciri birbirine güven esaslı olmayan düğümler tarafından tutulan sadece kayıt eklenerek büyüyen bir veri yapısıdır. Blok zincirinde yer alan düğümler, içerisinde çok sayıda işlem içeren sıralı bir blok kümesi üzerinde anlaşmaya varırlar [10]. Blok zinciri ağındaki her bloğun özet değeri, ardışık olarak sonra gelen blok tarafından tutulmakta ve bağlantı sağlanmaktadır. Böylelikle ağı daha güvenli ve değiştirilmeye karşı korumalı hale getirmektedir [11]. Son yıllarda finanstan eğitime, enerjiden sağlığa ve dijital kimlikten tarıma birçok farklı sektörde kendisine uygulama alanı bulan bir teknoloji haline gelmiştir [12]. Mevcut merkezi otoritenin dışında ve aracılar olarak katılımcıların güvenli bir şekilde işlem kaydını dağıtık olarak tutabilen, değiştirilemez ve dağıtık bir altyapı sunmaktadır [13].

Mevcut akademik referans sürecindeki zorluklar ve eksiklikler incelendiğinde blok zinciri teknolojisi ile bu zafiyetlerin üstesinden gelebilecek güvenli, süreçlerin çevrim içi ortamda ilerlediği, merkezi sunucularda tutulmayan ve tavsiye mektubu süreçlerinin standart bir iş akışı ile sunulduğu akıllı sözleşme tabanlı bir model önerilmektedir. Ethereum akıllı sözleşmeleri kullanılarak birçok kurumun birbirinden farklı işleyiş ile ele aldığı süreçlerin ortak bir iş akışına sahip olabilmesi ve şeffaf bir biçimde kayıt altına alınması hedeflenmektedir. Bu çalışma kapsamında açık Ethereum ağında modelin kendi yetkilendirme ve doğrulama fonksiyonları detaylı olarak tasarlandığından ve paydaşların kayıtlarından referans mektuplarının ilgili kurum tarafında doğrulanmasına kadar

tüm süreç geliştirilip test edildiğinden dolayı kapsam akademik boyut ile kısıtlanmıştır. Herhangi bir merkezi otorite veya aracı olmadan tasarlanan model, paydaşlar arasında referans mektubu sürecinin detaylı olarak anlaşılabilmesi için ilgili sıra diyagramları, sözde kod blokları ve iş akışının yer aldığı sistem mimarisi ile birlikte anlatılmıştır. Modüler bir biçimde tasarlanan ve geliştirilen akademik tavsiye mektubu modeli ek paydaşların eklenmesiyle global ölçekte genişlemeye müsait olup diğer sektörlerde de benzer iş süreçlerinde kolaylıkla geliştirilebilir ve kullanılabilirliğine sahip olabilecektir.

Makalenin devamında literatürde yer alan benzer çalışmalar anlatılmıştır. Materyal ve metot kısmında kullanılan teknolojiler ve takip edilen yöntemler anlatılmış olup kullanılan akıllı sözleşme kodları sözde kod olarak sunulmuştur. Ayrıca sıra diyagramları ve sistemin genel mimarisi ile modelin işleyişi detaylı olarak tarif edilmiştir. Bu bölüm, ilgili fonksiyonların maliyet analizi ve tartışma bölümü ile sonlandırılmıştır. Son bölümde sonuç ve ileriye yönelik çalışmalar anlatılmıştır.

2. LİTERATÜR ARAŞTIRMASI (LITERATURE REVIEW)

Bu bölümde akademik tavsiye mektubunun blok zinciri olmadan mevcut kullanım alanları ve blok zinciri yaklaşımı ile yapılmış benzer çalışmalar anlatılmaktadır. Literatürde blok zinciri tabanlı akademik referans uygulaması ile ilgili çalışmaların çok az olması sebebiyle blok zinciri tabanlı sertifika, doküman ve diploma yönetimi gibi bizim çalışmamıza yakın çalışmalarda dahil edilmiştir.

Dünya genelinde her yıl yapılan sıralamalarda üst basamaklarda yer alan, çok sayıda başvuru alan ve dolayısıyla en çok referans mektubu talebi ile karşılaşan üniversitelerden bazılarının bu konudaki yaklaşımında ise kendi işleyişlerine göre farklılıklar bulunmaktadır [14].

MIT (Massachusetts Institute of Technology) öğrencilerin tavsiye mektuplarını kendi başvuru portallarından çevrim içi olarak gönderilmesini tercih etmektedir [15]. Ayrıca portal dışında belgelerin saklanabileceği Interfolio gibi bazı web uygulamalarına da izin vermektedir. Interfolio, başvurular sırasında gönderilen bazı belgelerin firmanın merkezi sunucularında saklanarak birden çok kuruma veya üniversiteye tek bir yerden gönderilmesine yardımcı olan bir web uygulamasıdır [16]. Cambridge Üniversitesinde ise başvuru aşamasında ilgili akademisyenlerin e-posta bilgisi verilerek üniversitenin o kişilere göndereceği tekil belge yükleme linki ile bu aşama tamamlanmaktadır [17]. Stanford Üniversitesinde başvurular istenilen iki adet referans belgesinin öğrenci tarafından çevrim içi başvuru portalına eklenmesi beklenmektedir. Dosya eklenmesi sırasına oluşabilecek hatalarda ise belgelerin ilgili e-posta adresinden de iletilebileceği belirtilmektedir [18]. Harvard Üniversitesi başvurularında kendi uygulama portalını kullanmaktadır. Bu portal üzerinde istenilen üç adet tavsiye mektubu için ilgili akademisyenlerin e-posta

bilgisinin sisteme eklenmesi beklenmektedir. İlgili akademisyenlere gönderilecek bağlantı adresleri ile öğrenci hakkında tavsiye yazısı kendi sistemleri üzerinden eklenmektedir. Interfolio gibi harici web uygulamalarının kullanımına izin verilmemektedir [19]. Kaliforniya Teknoloji Üniversitesi (CALTECH) ise başvuru sistemi üzerinden üç adet tavsiye mektubu istemektedir. Bu mektuplar dijital olarak öğrenci tarafından gönderilebileceği gibi akademisyende ilgili e-posta adresine veya fiziksel olarak posta yoluyla üniversite ilgili enstitü adresine gönderebilmektedir [20]. Türkiye’de yer alan üniversiteler de ise Orta Doğu Teknik Üniversitesi (ODTÜ) başvurularında referansı iletilmek istenilen kişinin bilgileri ilgili alanlara girildikten sonra 48 saat içinde tavsiye yazılmak için bir adet link göndermektedir. Referans yazacak ilgili kişi bu link aracılığı ile çevrim içi olarak süreçleri tamamlamaktadır [21]. Boğaziçi Üniversitesinde referans mektubu alınacak en az iki kişinin adı, soyadı ve e-posta adresi başvuru portalında iletilmektedir. Başvuru öğrenci tarafından gönderildikten sonra, iletişim bilgileri verilen kişilere referans mektuplarının iletilmesi için ilgili otomatik e-posta gönderilir. Referans mektubunu yazacak olan kişiler çevrim içi sistem aracılığı ile referans mektubunu iletildiğinde başvuru sahibine bilgilendirme e-posta ile yapılmaktadır [22].

Yukarıda araştırılan üniversitelerin başvuru bilgi sistemleri incelendiğinde öğrenme yönetim sistemlerine ek bir modül ile veya başka bir web tabanlı yazılım ile bu başvuruların alındığı anlaşılmıştır. Mevcut akademik öğrenme ve başvuru süreçlerinde fiziksel olarak katılım Covid-19 pandemisi ile birlikte yerini daha çok çevrim içi öğrenme ve başvuru süreçleri ile değiştirmiştir [23]. Fiziksel olarak tavsiye mektubunun iletimini daha çok dijital olarak iletilmesine bırakmıştır. Bu sebeple incelenen üniversitelerin birçoğunun da web tabanlı başvuru portalları aracılığı ile tavsiye mektuplarını dijital olarak merkezi sunucularında tuttukları görülmüştür. Üniversitelerde artan çevrim içi uygulamalarda birçok öğrenci ve akademisyen bilgilerine ek olarak başvurular sırasında iletilen kişisel bilgiler ile referans mektupları da yer almaktadır [24]. Literatürde tavsiye mektupları özelinde merkezi sunucularda gerçekleşmiş kayıp sayısı ile ilgili veri bulunamamıştır. Bununla birlikte referans mektupları ile birlikte diğer tüm eğitim bilgilerinin saklandığı üniversite ağ ve sunucularına gerçekleşen saldırılarda yıldan yıla bir artış olduğu ve bu durumun diğer eğitim ve kişisel bilgilerin yanında öğrencilerin gizli referans bilgilerinin de siber tehlike altında olabildiğini göstermektedir. BlueVoyants (2021), yayınladığı siber saldırı raporunda üniversite sunucularına yapılan siber atakların sayısının 2019 ile 2020 arasında %100 arttığını belirtmiştir. Bu siber saldırıların maliyetinin okullara 447.000 Amerikan doları olduğu ifade edilmiştir [25]. Tavsiye mektupları dahil birçok hassas veri barındıran bu sunuculardaki yazılım ve ağ zafiyetleri bilgisayar korsanları tarafından önemli bir hedef olmaya gelecekte de devam edeceği öngörülmektedir [26].

Tavsiye mektuplarının yukarıda bahsedilen geleneksel yöntemlerle iletilmesinin dışında blok zinciri tabanlı

olarak bu sürecin doğruluğunun sağlanması üzerine Rahman ve ark. (2021) çalışma yapmıştır. Ethereum blok zinciri ağında tasarlanan bu model ile tavsiye mektuplarının tahrif edilmesi ve yalan beyanların önüne geçilebilmesi için referans mektubunun sadece IPFS temelli belge yüklenip doğrulandığı aşama blok zinciri teknolojisi ile tasarlanmıştır [27]. Marella ve Vijayan (2020) yaptıkları çalışmada iş başvurularında kullanılan belge ve dokümanların değiştirilmesini engellemek için blok zinciri tabanlı Hyperledger altyapısı ile belge doğrulama modeli geliştirmişlerdir. Başvuru esnasında gerekli olan bütün dokümanların hash değerlerinin konsorsiyum blok zinciri ağına kaydedilmesi ve bu değeri belgenin kendi hash değeri ile kıyaslanarak doğrulanması üzerine bir sistem tasarlamışlardır [28]. Kumavat (2020), öğrencilerin aldığı sertifikaları blok zinciri ağına aktararak doğrulanmasının sağlanması üzerine bir çalışma yapmıştır. Gerçekleştirilen modelde blok zinciri ağı olarak Ethereum ve dağıtık dosya paylaşım sistemi IPFS kullanılmıştır. Yapılan çalışma ile yanlış sertifika beyanında bulunulmasının engellenmesi, doğru ve değiştirilmemiş sertifikaların dağıtık web uygulaması aracılığı ile ilgili kurumlarla paylaşılması ele alınmıştır [29]. Taha ve Zakaria (2020) yaptıkları çalışmada iş başvurularında özgeçmiş, sertifika ve tavsiye mektuplarının doğrulanmasını sağlamak üzere Ethereum ağında geliştirdikleri modelde kişilerin bu beyanlarının doğrulanmasını amaçlamışlardır. Maliyet analizi de yapılan makalede sertifika kuruluşları, işe başvuranlar ve işverenler arasında güvenli bir blok zinciri tabanlı ağ kurulması hedeflenmiştir [30]. Alabduljabbar (2021) gerçekleştirdiği çalışmada mobil uygulama ile referans mektubunun öğrencinin iş, eğitim ve staj başvurularındaki süreçlerin kısılmasını ve daha standardize edilmiş hazır şablon mektupların oluşmasını amaçlamıştır. Paydaşlar arasındaki süreçlerin zaman olarak kısaltılmasını amaçlayan bu makale de geliştirilen yazılım için ayrıca kullanıcı kabul testleri de yapılmış olup önerilen model blok zinciri teknolojisi ile geliştirilmemiştir [31].

Blok zinciri ve akıllı sözleşmeler kullanılarak yapılan çalışmaların sayısı giderek artmasına rağmen akademik tavsiye mektubu ile ilgili literatürde yukarıda bahsedilen az sayıda çalışmaların yapıldığı görülmektedir. Bu araştırmalar da genel olarak doküman ve belge doğrulama ağırlıklı olarak yapılmıştır [27-29]. Önerdiğimiz modelde belgelerin okunup doğrulandığı aşamaya ek olarak üç adım daha mevcuttur. Bunlar paydaşların kaydedilmesi, talebin iletilmesi, talebin değerlendirilmesi süreçleridir. Akademik tavsiye mektubu modelinin benzer çalışmalardan farklı olarak aşağıda belirtilen durumlar üzerinden literatüre özgün şekilde katkı sağlayacağı hedeflenmektedir.

- Açık erişimli Ethereum blok zinciri ağında yer alan Metamask vb. cüzdanlarla kimlik doğrulama aşamasına ek olarak önerdiğimiz model kendi doğrulama ve işlem bazı yetkilendirme fonksiyonlarına sahip bulunacaktır. Paydaşların önerdiğimiz model üzerinde yapacakları her bir işlem için Ethereum ağında tanımlı olmasına ek olarak

kendi modelimiz üzerinde tanımlı olması durumunda işlemleri gerçekleştirebilecektir.

- Paydaşların modele; rollerine göre kaydedilmesi, öğrencilerin mektup için istek göndermesi ve bunun akademisyenlerce değerlendirilmesi, kurumların ilgili mektupları doğrulayıp okuyabilmesi aşamalarının detaylı olarak tasarımı, geliştirilmesi ve testleri yapılarak tüm süreç boyutunda tam bir çerçeve sunulacaktır.
- Modelin tüm akıllı sözleşme kodları açık kaynak olarak paylaşılıp gelecek benzer çalışmalara katkı sağlayabilecektir.

Üniversite lisansüstü ve iş başvurularında akademik referansın halen yaygın kullanıldığı da göz önüne alındığında bu çalışma kapsamında önerdiğimiz blok zinciri tabanlı akademik referans sistemi modelinin mevcut başvuru ve değerlendirme adımlarında daha şeffaf, güvenli, uluslararası ölçekte genişletilebilir ve süreçlerin standardize edildiği bir çözüm önerisi getirmektedir.

3. MATERYAL VE METOT (MATERIAL AND METHOD)

3.1. Önerilen Model Tasarımı (Proposed Model Design)

Blok zinciri tabanlı akademik tavsiye mektubu sistemi Şekil 1'de gösterildiği gibi sistemi kullanan aktörlerden, akıllı sözleşmelerden ve IPFS gibi dağıtık dosya paylaşım ortamından oluşmaktadır. Eğitim bölümünde yer alan paydaşlardan üniversiteleri ekleyen paydaş, üniversiteler, öğrenciler ve akademisyenler birçok ülkede aynı rollerde bulunduğu için farklı bir ülkede önerilen sistemin kullanılması herhangi bir değişikliğe neden olmayacaktır. Özel firmaların bağlı olduğu üst birim Türkiye'de TOBB iken Amerika'da U.S. Chamber of Commerce, Almanya'da Association of German Chambers of Commerce and Industry olarak geçmektedir. Özel firmaların bağlı olduğu üst meslek odalarının ülkeler değiştiğinde sadece adı değişmekte olup önerdiğimiz model kullanımında herhangi bir rol ve sistem değişikliğine gidilmesine sebep olmamaktadır. Kamu kurumlarının bağlı olduğu bir üst birim birçok ülkede mevcut olup Cumhurbaşkanlığı, Başbakanlık veya Bakanlık olarak önerilen sisteme en başta tanımlanarak modelin uygulanması gerçekleştirilebilmektedir. Sistemde yer alan akademik paydaşları üniversiteleri ekleyen paydaş, üniversiteler, akademisyenler ve öğrenciler oluşturmaktadır. Referanslar özel ve kamu kurumları ile üniversitelere gönderilebileceği için bu kısımda özel firmaları sisteme ekleyen paydaş, özel işyerleri ile kamu kurumları ve kamu kurumlarını sisteme ekleme yetkisinde olan paydaş düşünülmüştür. Önerilen modelin örnek olarak uygulanması ve testleri Türkiye veya diğer ülkelerde neredeyse hiçbir değişikliğe gidilmeden uygulanabilir durumdadır. Sistemin kullanacağı iş kurallarının olduğu akıllı sözleşmeler, Ethereum ağına üniversiteleri sisteme ekleyen paydaş tarafından yüklenecektir. Sözleşmeler yüklenmesi sırasında üniversiteleri, özel firmaları ve kamu kurumlarını sisteme

ekleme yetkisine sahip paydaşların blok zinciri ağındaki adresi gerekmektedir. Kayıt kontratını sisteme ekleyen paydaş ayrıca ağ içerisinde yer alacak üniversiteleri adresleri ile sisteme ekleyebilecektir. Üniversiteler kendilerinde çalışan akademisyenler ile okuyan öğrencileri sisteme ekleme yetkisine sahip olmaktadır. Kamu kurumlarını sisteme ekleyen paydaş kamu kurumlarının adresleri ile kaydedebilecek ve özel firmaları ekleme yetkisini bulunduran paydaş da üye özel işyerlerini sisteme yine benzersiz tekil adresler ile ekleyebilecektir. Mevcut hali ile sadece yetkili adreslerin işlem yapabilmesine izin verilen özel Ethereum ağı oluşturulması hedeflenmiştir. Sistemin ana yapısını oluşturan akademik referans mektubu modeli çeşitli medya formatlarında (Word, Excel, Jpeg, Png vb.) IPFS ağına dağıtık bir şekilde kaydedilip dosyaya özel tekil bir hash değeri elde edilecek ve sistemde dosyalara erişim bu hash değeri ile yetkili kişiler tarafından yapılabilecektir. Takip eden bölümde sistemde yer alan paydaşların detaylı bilgileri ve sistemdeki rollerine yer verilmiştir.

3.1.1. Sistem Paydaşları (System Stakeholders)

Sistem paydaşları aşağıda yer almaktadır. Ülkeler bazında roller değişmeksizin paydaşlar üzerinde bazı isim değişiklikleri yapılarak model kolaylıkla uygulanabilir durumdadır.

Kamu Kurumlarını Sisteme Ekleyen Paydaş: Tavsiye mektubu modelinde kamu kurum ve kuruluşlarının sisteme tekil adreslerinin eklenmesi rolüne sahip bulunmaktadır. Sisteme eklenen kamu birimleri kendilerine iletilen tavsiye mektuplarına rolleri dahilinde erişebilmektedir. Türkiye örneği için bu paydaş T.C. Cumhurbaşkanlığı olarak düşünülebilir.

Özel Firmaları Sisteme Ekleyen Paydaş: Sistemde yer alacak özel firma ve kurumların Ethereum ağına önceden belirli adresleri ile eklenmesinden sorumludur. Eklenen firmalar kendilerine atanmış tavsiye mektuplarını görebilmektedir. Türkiye örneği için bu paydaş Türkiye Odalar ve Borsalar Birliği (TOBB) olarak düşünülebilir.

Üniversiteleri Sisteme Ekleyen Paydaş: Sistemde üniversite tanımlama yetkisine sahip olup kayıt akıllı sözleşmesinde bu paydaşların eklenmesi rolünün sahibidir. Kayıt akıllı sözleşmesinin Ethereum ağına yüklenmesinden sorumlu olup kontrat sahibidir. Türkiye örneğinde bu paydaş Yükseköğrenim Kurumu (YÖK) olarak düşünülebilir.

Üniversiteler: Devlet veya vakıf üniversiteleri tekil adresleri ile sisteme tanımlanmaktadır. Sistemde akademisyenleri ve öğrencileri kendilerine özel adresleri ve bilgileri ile üniversiteler kaydetmektedir. Buna ek olarak

kendilerine gelen tavsiye mektubunu okuma yetkisine de sahiptir.


Öğrenciler: Üniversitelerde okuyan veya mezun öğrenciler, üniversiteler aracılığı ile tanımlandıktan sonra tavsiye mektubu talebini, referans mektubu almak istediği akademisyen adres bilgisini, mektubu göndermek istediği özel/kamu kurumu veya üniversite bilgilerini ve tavsiye mektubunu neden almak istediğine dair açıklama ile Ethereum blok zinciri ağına ilgili talebi oluşturup göndermektedir.

Akademisyenler: Üniversitelerde görev yapan akademisyenler, sisteme görev yaptıkları üniversite tarafından tanımlandıktan sonra kendilerine öğrencilerden gelen talepleri inceleme ile birlikte ilgili talebi onaylayıp reddetme rolüne sahip olmaktadır. Onayladığı talep içerisinde öğrenci hakkındaki tavsiyesini belirttiği tavsiye dokümanı ile sistem üzerinden IPFS ağına kaydederek elde edilen ilgili hash değeri ile blok zinciri ağına ilgili kurum veya üniversiteye tavsiye mektubunun ulaşmasını sağlamaktadır.

Özel ve Kamu Kurumları: Sistemde blok zinciri ve IPFS dağıtık dosya ağına kaydedilen akademik tavsiye mektubunun akışında en son yer alan aktörlerdir. Kendi tekil adreslerine atanan referans mektuplarına erişmekte, okumakta ve modelde yer alan tavsiye mektubu akışını tamamlamaktadırlar. İlgili öğrencinin akademisyen tarafından doğrulanmış tavsiye mektubuna blok zinciri ağı üzerinden güvenli bir şekilde ulaşmaktadırlar.

Tablo 1. Sistem paydaşları (System stakeholders)

Paydaş	Rolü
Kamu Kurumlarını Sisteme Ekleyen Paydaş	Kamu kurumu ekleme, güncelleme ve silme
Özel Firmaları Sisteme Ekleyen Paydaş	Özel kurum ekleme, güncelleme ve silme
Üniversite	Akademisyen / öğrenci ekleme, güncelleme ve silme, tavsiye mektubu okuma
Akademisyen	Tavsiye mektubu onay/red ve oluşturma
Özel Kuruluş	Tavsiye mektubu okuma
Kamu Kurumu	Tavsiye mektubu okuma
Öğrenci	Tavsiye mektubu talep oluşturma ve silme



Şekil 1. Önerilen sistem mimarisi (Recommended system architecture)

3.2. Önerilen Modelin Uygulanması (Implementation of the Recommended Model)

Bu bölümde önerilen blok zinciri tabanlı akademik tavsiye mektubu modelinin detayları anlatılmıştır. İlgili model Ganache yerel blok zinciri ağında, Remix IDE kullanılarak Solidity akıllı sözleşme programlama dili kullanılarak geliştirilmiştir. İlgili kodlar herkese açık Github hesabında paylaşılmıştır*. Model birbirini takip eden dört aşama ve arka planda üç akıllı sözleşmeden oluşmaktadır. Paydaşların rolüne göre sisteme eklenmesi (Kayıt Kontratu), öğrencilerin ilgili tavsiye mektubu isteklerini belirledikleri ve model üzerinde tanımlı akademisyenlere göndermesi (Talep Kontratu), akademisyenlerin ilgili talebi onay veya reddetmesi (Talep Kontratu), ilgili referans mektubunun son olarak referans isteyen kurum tarafından doğrulanıp okunması (Talep Okuma Kontratu). Bu sözleşmeler aşağıda detayları ile birlikte anlatılmıştır.

3.2.1. Kayıt Akıllı Sözleşmesi (Registration Smart Contract)

Sistemin sahibi tarafından yüklenen kayıt akıllı sözleşmesi ile modelde yer alan paydaşlar blok zinciri ağına kaydedilmektedir. Her bir paydaş tekil adres değerine sahiptir. Sözleşmenin yüklenmesi esnasında üniversiteleri, kamu kurumlarını ve özel firmaları ekleyen paydaşların adresleri tanımlanmıştır. Sözleşme yüklendikten sonra ilgili iş akışları aracılığı ile akademik tarafta üniversiteler, akademisyenler ve öğrenciler sisteme eklenmektedir. Tavsiye mektuplarının ulaşacağı özel ve kamu kuruluşları da yine bu sözleşme ile ilgili yetki hiyerarşisine göre ağı

eklenir Ethereum ağının doğası gereği yüklenen akıllı sözleşmelerdeki iş akışı ve mantık değiştirilememektedir.

Sözde Kod 1: Öğrenci Kayıt	
Girdi: Öğrenci adresi (adres), ad, soyad, bölüm, üniversite	
1	if Metodu çağırılan adres Üniversite then
2	if Öğrenci bilgisi daha önce kayıtlı değil then
3	ogrenciListesi[adres].durum ← true
4	ogrenciListesi[adres].ad ← ad
5	ogrenciListesi[adres].soyad ← soyad
6	ogrenciListesi[adres].universite ← universite
7	ogrenciListesi[adres].bolum ← bolum
8	else
9	Öğrenci zaten kayıtlıdır uyarısı
10	end
11	Else
12	Sadece Üniversite bu işlemi yapmaya yetkilidir uyarısı
13	end

Şekil 2. Öğrenci kayıt sözde kodu (Student registration pseudocode)

Şekil 2’de yer alan sözde kod ile öğrenci kayıt aşamaları detaylı bir şekilde anlatılmaktadır. Öğrenci kaydına yetkili olan birim blok zinciri ağına üniversite olarak kayıt edilmiş olan paydaştır. Öğrenci akıllı sözleşme ile daha önce ağı kayıtlı ise bu adreste öğrenci bilgisi kayıtlıdır uyarısı akıllı sözleşmeden hata olarak dönmektedir. Öğrencinin bu sözleşme listesinde olmadığı yeni

* <https://github.com/fucyier/referenceLetter>

kayıtlarda ise adı, soyadı, bölümü ve üniversite bilgileri ile öğrencinin tekil adresi ağa eklenmektedir.

Özel kurum ve üniversite kaydı işlemi kamu kurumu kaydı işlemine benzediği için yer verilmemiştir. Özel kurumda kayıt yapma yetkisine özel firmaları sisteme ekleyen paydaş sahip iken üniversite kaydında üniversiteleri sisteme ekleyen ana paydaş olarak belirlenmiştir. Diğer işlemlerde olduğu gibi daha önce yeni eklenecek adreslerin sistemde olup olmadığı kontrolü yapılmakta ve olmadığı durumda yeni kayıt blok zinciri ağına eklenebilmektedir. Akademisyen, Öğrenci, özel kurum ve kamu kurumu yeni kayıtlarına ek olarak bu paydaşları sisteme ekleme yetkisine sahip paydaşlar tarafından mevcut bilgilerinde güncelleme yapılabilecektir. Ayrıca yetkisi olan paydaşlar tarafından ilgili kayıtlar pasif duruma çekilebilecektir.

Şekil 3'te kayıt sözleşmesinde yer alan kayıt adımları sıra diyagramında detaylı bir şekilde tarif edilmiştir. Sistemde yer alan tüm paydaşlar tekil blok zinciri adresi ile ağa eklenerek ilgili işlemleri yetkisi dahilinde yapabilecektir. Ayrıca her bir işlemten sonra ilgili paydaşlara Solidity programlama dilinde yer alan olay metodu ile bilgilendirme sağlanacaktır.

3.2.2. Referans Talep Akıllı Sözleşmesi (Reference Request Smart Contract)

Modelin ana bileşenin oluşturan akademik tavsiye mektubunun öğrenciler tarafından süreç içerisine dahil edildiği ve ilgili firma, kamu kuruluşu veya üniversiteye gönderilme aşamasından oluşmaktadır. Kayıt kontratına bağımlı olduğu için yükleme esnasında yapıcı metodu kayıt akıllı sözleşmesinin adres değerine gereksinim duymaktadır.

Şekil 6'da mevcut modelde yer alan öğrenci, akademisyen ve alıcı kurumların birbiri ile etkileşimi genel hatlarıyla gösterilmiştir. Öğrenci, web tabanlı merkeziyetsiz (DApps) önyüz uygulamasından tavsiye mektubunu ilgili akıllı sözleşme aracılığı ile akademisyen ve alıcı adres bilgilerini ekledikten sonra blok zinciri ağına kaydederek tavsiye mektubunun akışını başlatmış olmaktadır.

Akademisyenler kendilerine gönderilen tavsiye mektuplarını onayladıktan ve tavsiye yazısı eklendikten sonra gönderilmek istenen ilgili kurum veya üniversiteye iletilmektedir. Her işlem sonrasında ilgili paydaşlara bilgi mesajları gitmektedir.

Tavsiye Mektubu Talebi Oluştur veya Sil

Öğrencinin referans mektubu Şekil 4'te yer alan sözde kodda gösterildiği gibi sadece öğrenci tarafından sisteme eklenebilmektedir. Öğrenci dışında bir adresten bu metot çağırıldığında yetki hatası almaktadır. Talep edilen akademisyen ve alıcı kurum adresi sitemde tanımlı olarak bulunan ilgili adres listelerinde yoksa uygulama hata

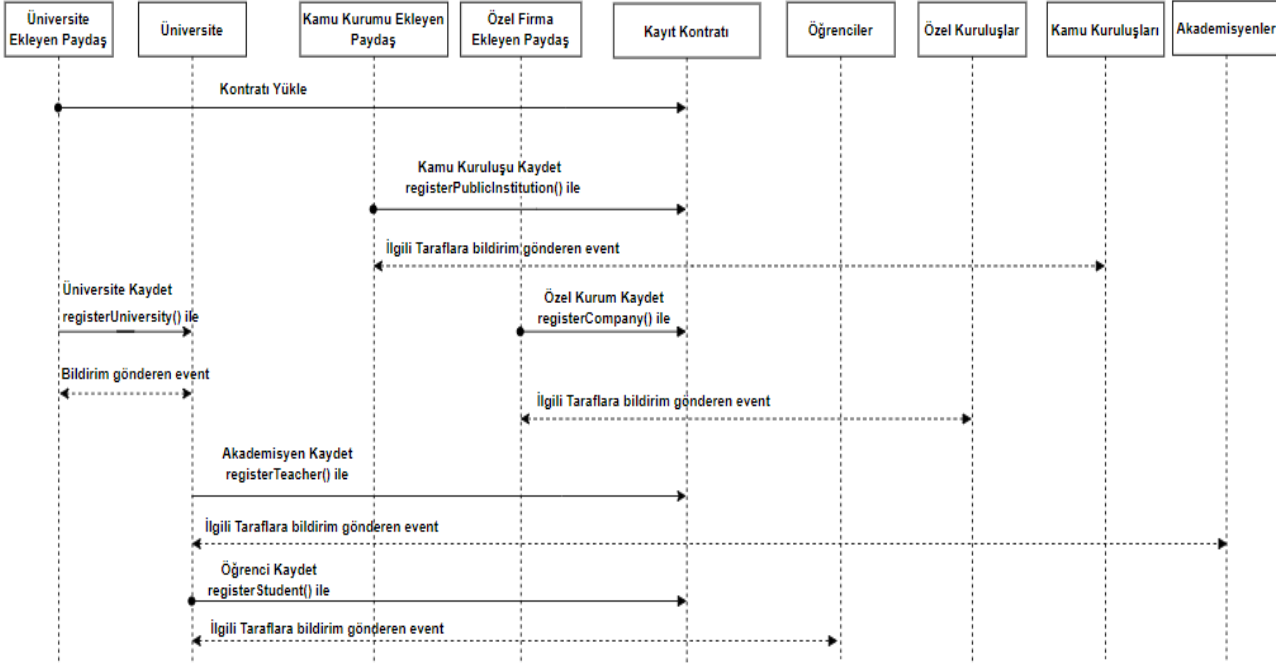
dönerek işlemi iptal edecektir. Doğru tanımlanmış adresler girildiğinde talep edilen referans blok zinciri ağına eklenecektir. Öğrenci tarafından oluşturulmuş talepler, talebi oluşturan öğrenci tarafından eğer akademisyen tarafından süreci başlatılmamış ise sistemden silinebilmektedir.

Tavsiye Mektubu Talebi Okuma ve Değerlendirme

Öğrenci tarafında talebi oluşturulan referans mektubu ilgili akademisyene atanmaktadır. Süreç işleyişinin bu aşamadan sonrası akademisyen tarafında gerçekleştirilip ilerlemesi sağlanmaktadır. İlgili referans talebinin hangi öğrenciden geldiğini talep gerekçesi ile birlikte akademisyen okumaktadır. Daha sonraki aşamada akademisyen bu talebi kabul edebilmekte veya reddedebilmektedir. Kabul edilen talepler bir sonraki sürece ilerleyip öğrenciye bilgi mesajı iletilmektedir. Reddedilen taleplerde ise ret gerekçesi ile birlikte öğrenciye mesaj gidecektir. Ret alan talepler için süreç kapanmış olmakla birlikte kabul edilenler sürece devam edebilecektir.

Sözde Kod 2: Tavsiye Mektubu Talebi Oluştur	
Girdi:	Akademisyen adresi (akademisyenAdres), alıcı adresi (aliciAdres), referansNotu, mektup No (letterId)
mektupListesi:	Akıllı sözleşmede tavsiye mektuplarının tutulduğu mapping tipinde dizidir
Mektup:	Tavsiye mektubu objesidir
Belge:	IPFS hash bilgisi ve belgenin görülme zamanını tutan objedir
Durum:	Mektup aşamalarını tutan enum tipli nesnedir.
1	if Metodu çağırın adres Öğrenci then
2	if Akademisyen adresi ağda kayıtlı then
3	if Alıcı adresi ağda kayıtlı then
4	letterId ← letterId + 1;
5	mektupListesi [letterID] ←
	Mektup(msg.sender,
	akademisyenAdres, aliciAdres,
	referansNotu, Durum.Created,
	Belge(0,block.timestamp,0));
6	Kayıt Tamamlandı Bilgilendirmesi
7	else
8	Alıcı kayıtlı değildir uyarısı
9	end
10	else
11	Akademisyen kayıtlı değildir uyarısı
12	end
13	else
14	Sadece Öğrenci bu işlemi yapmaya yetkilidir uyarısı
15	end

Şekil 4. Tavsiye mektubu talep oluşturma sözde kodu (Recommendation request generation pseudocode)



Şekil 3. Paydaşların kayıt süreçlerine ait sıra diyagramı (Sequence diagram of stakeholder registration processes)

Tavsiye Mektubu Ekleme

Akademisyen olumlu değerlendirdiği talep ile ilgili tavsiye mektubu yazıp belirli bir medya tipinde blok zinciri tabanlı dağıtık web uygulaması üzerinden IPFS ağına kaydederek hash değeri elde eder. Sadece akademisyen tarafından çağırılan tavsiye mektubu ekleme fonksiyonu yetkili olmayan ağdaki başka bir paydaş tarafından eklenildiğinde uyarı mesajı dönecektir. IPFS'ten alınan hash değeri, yazılma zamanı ve yeni süreç durumu ile birlikte mektup nesnesinin ilgili özellikleri atanmaktadır. Eklenilecek belge blok zinciri ağında tutulmadığı dağıtık IPFS sunucularında tutulduğu için sadece belgenin sabit uzunluktaki hash değeri blok zinciri ağındaki mektup nesnesinde tutulacaktır. Bu nedenle eklenecek belgelerin boyutunun oluşacak işlem maliyetine bir etkisi olmayacaktır.

3.2.3. Referans Okuma Akıllı Sözleşmesi (Reference Reading Smart Contract)

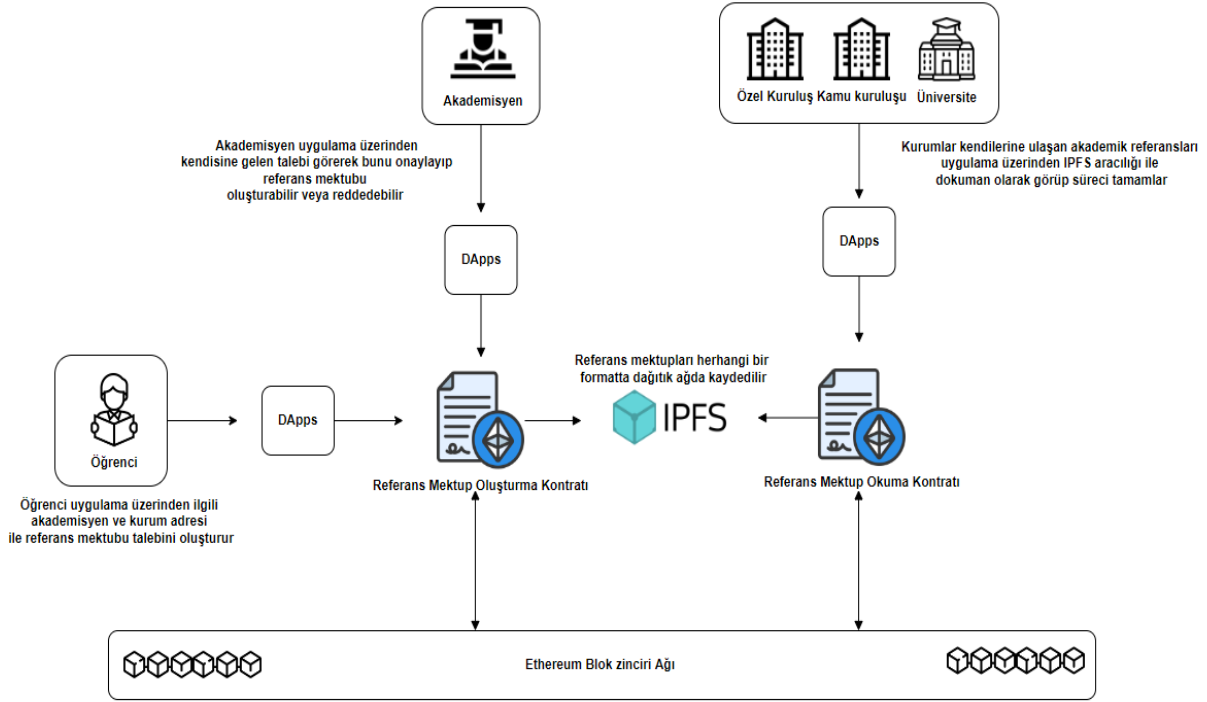
Kayıt kontratına ve referans talep akıllı sözleşmesine bağımlı olduğu için yüklenme esnasında yapıcı metoduna bu akıllı sözleşmelerinin hash değerlerine gereksinim duymaktadır. Öğrenciler tarafından talep edilen ve akademisyenler tarafından blok zinciri ağına yüklenen tavsiye mektupları ilgili kuruma veya üniversiteye gönderilmektedir. Referans okuma sözleşmesi kurumlara gönderilen referansların okunması ve durumunun okundu olarak güncellenmesinden sorumlu olmaktadır. Okundu durumuna getirilen referans mektupları ile birlikte ilgili süreç tamamlanmaktadır. Şekil 5'te yer alan sözde kodda görüldüğü gibi tavsiye mektubu okuma metodu sadece alıcı kurum tarafından çağırılabilir. Tavsiye

mektubunun gönderileceği öğrenci tarafından belirlenmiş alıcı kurum adresinden başka bir adres ilgili referans mektubunu görememektedir.

Başka bir adres metodu çağırıldığında yetki uyarı mesajı dönerek işlemi iptal edecektir. Mektubun atandığı doğru kurum tarafından çağırılan metod içerisinde mektubun görülmeye ve görüldü durumu güncellenmektedir. Hash değeri ile DApps üzerinden IPFS'te yer alan ilgili tavsiye mektubu yüklenen formatta indirilebilecektir. Şekil 7'de talep ile ilgili metodların süreçteki akışı gösterilmektedir.

Sözde Kod 3: Tavsiye Mektubu Okuma	
Girdi:	Mektup No (letterId)
mektupListesi:	Akıllı sözleşmede tavsiye mektuplarının tutulduğu mapping tipinde dizidir.
belge:	IPFS hash bilgisi ve belgenin yazılma zamanını tutan objedir.
durum:	Tavsiye mektubunun süreçteki durumunu belirten enum tipli nesnedir. Created, TeacherAdmitted, TeacherRejected, TeacherCompleted, SeenByRecipient değerlerini alabilir.
1	if Metodu çağırılan adres Alıcı Kurum then
2	if Mektup akademisyen tarafından TAMAMLANDI durumunda then
3	mektupListesi
4	[letterID].belge.gorulmeTarih ← block.timestamp;
5	mektupListesi [letterID].durum ← status.SeenByRecipient;
6	else
7	Mektup durumu sadece TAMAMLANDI belgelerle işlem yapılabilir uyarısı
8	end
9	else
10	Sadece Alıcı Kurum bu işlemi yapmaya yetkilidir uyarısı
	end


Şekil 5. Tavsiye mektubu okuma sözde kodu (Letter of recommendation reading pseudocode)



Şekil 6. Referans mektubu talebi süreç mimarisi (Reference letter request process architecture)

Tavsiye mektubu modeline ait tüm süreçler Şekil 6 üzerinde sistemde yer alabilecek tüm paydaşlar ile birlikte gösterilmiştir. Tavsiye mektubu sürecinde sisteme yetkili paydaşlar tarafından öğrenciler, akademisyenler, kamu ve özel kurumlar eklenmektedir. Tanımlar yapıldıktan sonra öğrenciler tarafından seçilen akademisyene iletilen tavsiye mektubu akademisyenlerce değerlendirilmektedir. Bu

aşamada IPFS dağıtık dosya paylaşım sistemine tavsiye mektubunun doküman hali eklenir ve hash bilgisi blok zincirinde ilgili yapı nesnesine atanır. Onaylanan mektup öğrenciler tarafından ilk adımda seçilmiş kurumlara gitmektedir. Kurumlar kendilerine gelen referans mektubunu okuyarak süreci tamamlamış olmaktadır.



Şekil 7. Paydaşlar arasındaki tavsiye mektubunun süreçlerine ait sıra diyagramı (Sequence diagram of processes of the letter of recommendation among stakeholders)

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA (RESEARCH RESULTS AND DISCUSSION)

4.1. Model Testi (Model Test)

Önceki bölümlerde modeli ve işleyişi tarif edilen akademik referans mektubu sisteminin bu bölümde yerel blok zinciri ağında test senaryoları çalıştırılmıştır. Öğrencinin talebiyle başlayan süreçte ilgili alıcı tarafından mektubun görülmesiyle tamamlanan iş akışı Remix IDE kullanılarak test edilmiştir. Remix geliştirme ortamı akıllı sözleşmeler ile kodların yazılmasını ve test edilebilmesini sağlayan web tabanlı geliştirme ortamıdır [32]. Test aşamaları akıllı sözleşme temel alınarak üç farklı aşamada incelenmiştir. Bunlar sırasıyla kayıt işlemleri, talep işlemleri ve mektup okuma işlemidir. Tablo 2’de testler sırasında paydaşların kullandığı adresler gösterilmektedir.

Tablo 2. Paydaşların örnek ethereum adresleri (Stakeholders' sample ethereum addresses)

Paydaş	Ethereum Adresi
Üniversiteleri Sisteme Ekleyen Paydaş	0x019e4e6CFd589b2401F6F13138D575a0B9292C46
Özel Firmaları Sisteme Ekleyen Paydaş	0x7A01F6027652c37C3f9C402A58E34e00611A481d
Kamu Kurumlarını Sisteme Ekleyen Paydaş	0xE4f03dc6b6F7db945f1cbbD7428587D9B282A380
A Üniversitesi	0x5F70de7C808004Eb09aE74a3A4C61CCf446C8F11
XYZ Firması	0x527682F97D1979692113361638897d3146bfbEE9
Akademisyen	0xFF17a8C06ff26ea93F777f555f7936eEAA54c825
Öğrenci	0x98ce595B0FcF1D8100DC9DcEDD460f6cD70A3F3A

4.1.1. Kayıt İşlemleri (Registration Processes)

Kayıt kontratı Ethereum ağına yüklenirken yapıcı sınıfında sistemi kullanacak olan öğrenci, akademisyen ve kurumları yükleyecek olan ana paydaşların adreslerini almaktadır. Bu paydaşları sisteme yükleme iznine sahip olan role sahip kimse bulunmadığından bu adresler

sisteme baştan yüklenmektedir. Kontrat yükledikten sonra paydaşlar, kendilerine ait olan rolün iznine göre öğrenci, kurum, üniversite gibi yeni paydaşlar eklemektedir.

Üniversite kaydı tamamlandıktan sonra akademisyen ve öğrenci kayıt yetkisi üniversitelerde olduğu için ilgili adres üzerinden yapılmak zorundadır. Şekil 8’de akademisyene ait bilgiler ile blok zinciri ağına yazılmaktadır.

Şekil 8. Akademisyen kayıt işlemi
(Academician registration process)

Şekil 9’da görüldüğü gibi akademisyen ilgili üniversite tarafından ağa eklenmiştir. Ekleyen adres tabloda verilen üniversite ve akademisyen adresi ile eşleşmektedir. Benzer şekilde öğrenciler üniversite tarafından, özel kurumlar ve kamu kurumları ilgili paydaşlar tarafından ağa başarı ile eklenmiştir.

Şekil 9. Başarılı akademisyen kayıt işlemi
(Successful academic registration process)

4.1.2. Tavsiye Mektubu Talep İşlemleri

Tavsiye mektubunun talep edildikten ilgili alıcı kuruma gönderilme sürecine kadar olan kısmı referans talep akıllı sözleşmesi tarafından kontrol edilmektedir. İlgili akıllı sözleşme kayıt akıllı sözleşmesinin Ethereum ağındaki adresi ile ağa yüklenmiştir. Ağa yükledikten sonra sürecin ilk basamağını oluşturan öğrenci mektup talebinde bulunmuştur. Blok zinciri ağına daha önce kayıt kontratı ile kaydedilmiş olan ve modelde yer alan akademisyen adresi ile birlikte alıcı kurum veya üniversite adresi referans mektubu talebini yapma gerekçesiyle ilgili metodu Şekil 10’da çağırıştır.

Şekil 10. Yeni talep oluşturma işlemi
(New request creation process)

Modelde kayıt edilmiş bir öğrenci doğru bir akademisyen ve alıcı kurum adresi ile talep gerçekleştirdiğinde Şekil 11'deki gibi başarılı işlem bilgi mesajını almıştır.

Şekil 11. Başarılı talep oluşturma işlemi
(Successful request creation process)

Oluşturulan talep akademisyen tarafından okunmaması şartı ile sistem üzerinden silinebilecektir. Böylelikle yanlış oluşturulan taleplerin akademisyende kalması engellenmiş olacaktır. Talep oluşturma işlemi tamamlandıktan sonra ilgili akademisyene gelen referans mektubu isteği ilk olarak değerlendirme aşamasına ulaşmıştır. Bu aşamada sadece gelen talebin kimden ve ne sebeple geldiği ilgili akademisyen tarafından okunmuştur. Bu ilk değerlendirme sürecinden sonra gelen isteği olumlu veya olumsuz değerlendirme süreci Şekil 12'de yer almaktadır. Modelin otomatik olarak oluşturduğu tekil mektup numarası ile birlikte akademisyen bu talebi olumlu değerlendirip bir sonraki aşamaya gönderebilmek ile birlikte gerekçesiyle birlikte reddedip süreci bu basamakta sonlandırma yetkisine sahip bulunmaktadır.

Şekil 12. Tavsiye mektubu onaylama veya reddetme işlemi (Recommendation approval or rejection process)

Yukarıdaki görselde akademisyen talebi olumlu olarak onaylamış ve bir sonraki sürece geçmesini sağlamıştır. Şekil 13'de başarılı bir onay işleminin gerçekleştiği görülmüştür.

Şekil 13. Tavsiye mektubu talebi onaylama işlemi
(Letter of recommendation request approval process)

Mektubun akademisyen tarafından yapılacak son işlemi ilgili öğrencinin talebine istinaden referans mektubu eklenmesi işlemi oluşturmaktadır. Daha önce modelin oluşturduğu tekil mektup numarası ile IPFS sistemine yüklenen referans dokümanı sonrasında alınan hash değeri ile birlikte akıllı sözleşme aracılığı ile blok zinciri ağına referans talebine ait adres ile eklenmiştir. Tavsiye mektubu ile ilgili verdiği belgeyi değiştirmek isteyen akademisyen bu işlemi yeni yüklenen belge numarası ile gönderilen firma veya kurum mektubu okunmaması şartı ile yapabilecektir.

Talep kontratına ait işlemler akademisyenin IPFS'ten türetilen mektup belge numarasının eklenmesiyle sonlanmış ve alıcı kuruma ilgili mesaj uyarısı ulaşarak sürecin bir sonraki aşaması olan alıcı kurumun tavsiye mektubunu okuma aşamasına geçmiştir.

4.1.3. Tavsiye Mektubu Okuma İşlemi

Akademik tavsiye mektubu modelinin son aşamasını ilgili alıcı kurumun referans mektubunu okuduğu aşama oluşturmaktadır. Mektubun öğrenci tarafından ilk aşamada tanımlandığı alıcı kurum veya üniversiteler bu işlemi yapmaya yetkilidirler. Talep okuma kontratı üzerinden alıcı kurum kendisine gönderilen referans mektubunu ilgili tekil numarası ile okuma işlemini gerçekleştirmiştir.

Yetkili ve mektubun gönderildiği alıcı kurum tarafından işlem gerçekleştirildiğinde başarılı işlem gerçekleştirilmiş ve IPFS aracılığı ilgili doküman yüklenmiş ve okunmuştur. Tavsiye mektubu bu aşama ile birlikte ilgili referans talebi için sona ermiştir. Blok zincirin doğası gereği bu talep akademisyen ve alıcı kurum tarafında her zaman görülebilecek ve belli bir son tarihe sahip olmayacaktır.

4.1.4. İşlemlerin Performans Analizi (Performance Analysis of Process)

Bu bölümde modelde kullanılan akıllı sözleşmelerde yer alan fonksiyonların işlem bazında gas maliyetleri incelenmiştir. Ethereum blok zinciri ağında gas adı ile bilinen dahili ölçüm değişkenleri mevcuttur. Gas maliyeti blok zinciri üzerinde gerçekleştirilen işlemlerde algoritmik olarak tanımlanmış yürütme maliyeti olarak ifade edilmektedir. Akıllı sözleşmelerde yer alan işlemlerde algoritmik karmaşıklık ne kadar fazla ise gas maliyeti de o kadar yüksek olmaktadır [33]. Diğer bir ifade ile Ethereum

ağındaki işlemi gerçekleştirebilmek için madenci tarafından tahsil edilecek kripto para birimi miktarını ölçen birimdir [34].

Testlerde Ganache blok zinciri kullanılmıştır. Ganache 10 farklı hesap ve 100 birim ether ile gelmekte olup işlemler için ağda hızlı bir şekilde bloklar oluşturarak uzun bekleme süresine gerek bırakmamıştır [35]. Yerel Ganache sunucusunda gas birim fiyatı 20 Gwei olarak alınmıştır. Ethereum fiyatları değişkenlik gösterdiğinden 12.07.2022 tarihi itibarı ile döviz kuru bilgilerine göre güncel durum Ethereum Gas Station sitesi üzerinden alınmıştır [36]. Şekil 14'te yer alan işlem maliyetleri testler sırasında Remix IDE tarafından çıktı olarak sunulmuştur. Alınan bu maliyet değerleri Gwei cinsinden olup önce Ether değerine çevrilmiş ve daha sonra döviz kurları ile gerekli çevirmeler yapılmış olup Türk lirası değerleri bulunmuş ve Tablo 3'te gösterilmiştir. Bazı işlemler algoritmik karmaşıklıklarından dolayı daha yüksek maliyetli çıkmıştır. İlgili maliyet ücretlerinin sahipleri her bir işlem için belirtilmiştir.



Tablo 3'te görüldüğü üzere, bir referans sürecinde yer alan tüm işlemlerin baştan sona 12.07.2022 tarihli kripto ve döviz kurları ile hesaplama yapıldığında yaklaşık 17 Türk lirası (TL) gibi bir toplam tutar oluştuğu görülmüştür.

Tablo 4'te çalışmamızda önerilen çözüm diğer literatürdeki benzer modeller ile karşılaştırılmaktadır. Tabloda yer alan üniversitelerde hali hazırda kullanılan akademik referans mektubu iletimi merkezi sunucular üzerinde yapıldığı için blok zinciri, akıllı sözleşme ve izlenebilirlik gibi avantajlara sahip bulunmamaktadır. Blok zinciri ile geliştirilen modellerin bazılarında dağıtık belge saklama ortamı kullanılmadığı, bazılarında süreçlerde yer alan işlemlere ait maliyet analizi gerçekleştirilmediği görülmektedir. Blok zinciri ile tasarlanan modeller izlenebilirlik, akıllı sözleşme ve merkeziyetsizlik özelliklerine sahip bulunmaktadır [37].

Önerdiğimiz çözüm blok zinciri, akıllı sözleşme ve izlenebilirlik özelliğinin yanı sıra maliyet analizi ve açık kaynak kodlu olarak paylaşılması ile öne çıkmaktadır.

Tablo 3. İşlem bazında ethereum işlem maliyetleri
(Ethereum transaction costs by transaction)

İşlem Adı	Ethereum İşlem Maliyeti (TL)	Maliyet Sahibi
Kurum Kayıt	1.30	Kamu Kurumu Kaydeden Paydaş
Akademisyen Kayıt	3.04	Üniversite
Öğrenci Kayıt	2.68	Üniversite
Firma Kayıt	2.14	Kamu Kurumu Kaydeden Paydaş
Yeni Referans Talebi	3.65	Öğrenci
Talep Değerlendirme	0.69	Akademisyen
Talep Onayla Reddet	1.02	Akademisyen
Referans Mektubu Ekle	0.82	Akademisyen
Referans Mektubu Oku	2.58	Üniversite veya Firma



Şekil 14. Gas işlem maliyetleri (Gas transaction costs)

Tablo 4. Önerilen çözümün benzer çalışmalar ile karşılaştırılması (Comparison of proposed solution with similar studies)

Özellik	MIT	Stanford	Harvard	CALTECH	Cambridge	ODTÜ	Boğaziçi	Rahman ve Ark. (2021)	Marella ve Vijayan (2020)	Kurnavat (2020)	Taha ve Zakaria (2020)	Alabduljabbar (2021)	Önerdiğimiz Çözüm
Blok zinciri	X	X	X	X	X	X	X	√	√	√	√	X	√
Akıllı Sözleşme	X	X	X	X	X	X	X	√	√	√	√	X	√
Dağıtık Dosya Kayıt	X	X	X	X	X	X	X	√	X	X	X	X	√
Maliyet Analizi	X	X	X	X	X	X	X	X	X	X	√	X	√
İzlenebilirlik	X	X	X	X	X	X	X	√	√	√	√	X	√
Merkezi olmayan Sunucu	X	X	X	X	X	X	X	√	√	√	√	X	√
Açık Kaynak Kodlu	X	X	X	X	X	X	X	X	√	X	X	X	√
Kimlik doğrulama ve yetkilendirme	√	√	√	X	√	√	√	X	X	X	X	X	√

4.2. Tartışma (Discussion)

Çalışma kapsamında önerilen modelimizde akademik tavsiye mektubu sistemi blok zinciri tabanlı olarak dağıtık, izlenebilir ve değiştirilemez yapıda geliştirilmiştir. Bütün iş kurallarının Ethereum blok zinciri ağına akıllı sözleşmeler tarafından çalışacak şekilde yüklendiği sistem baştan sona kadar örnek bir senaryo ile test edilmiş ve doğrulanmıştır. Maliyet analizi de gerçekleştirilmiş ve Tablo 3'te görüldüğü üzere toplam maliyetin oldukça düşük olduğu görülmüştür. Tavsiye mektubu başına oluşan maliyetin düşük olduğu belirtilmiş olsa da bir öğrencinin talep edeceği birden çok sayıda tavsiye mektubu ile birlikte kendisine çıkacak olan maliyetinde az bir artış olacağı gerçektir. Aynı durum akademisyen ve sistemi kullanan diğer paydaşlar için de geçerlidir. Belirli aşamalarda bazı kamusal teşvikler ile bu dezavantajlı görülebilecek durumun, blok zincirinin sağladığı güvenli ve şeffaf altyapı ile sunduğu avantajlarının daha baskın olacağı ve sistemin yaygın olarak kullanılmasında olumsuz bir durum oluşturmayacağı düşünülmektedir.

Önerdiğimiz modelde yer alan paydaşlar, işlemlerini blok zinciri teknolojisinin de sunduğu avantajlar ile güvenli ve merkezizsiz olarak gerçekleştirebilmektedir. Referans talep eden üniversiteler, kamu ve özel kurumlar arasında literatür bölümünde de değinildiği üzere referans mektubu süreçlerinde ortak kabul görmüş standart bir işleyişin olmadığı görülmüştür. Günümüzde halen pek çok iş, eğitim ve staj başvurularında referans mektubu talep edildiği

düşünüldüğünde önerdiğimiz modelin global ölçekte mevcut farklı aşamaları standart bir hale getirebileceği öngörülmektedir. Bu sebeple geliştirdiğimiz çalışma akademik referans mektubu süreçlerini iyileştirmektedir.

Blok zincirin sunduğu global ölçekte dağıtık veri tabanı ile merkezi sunucularda yaşanabilecek kesintilerin ve veri kayıplarının önüne geçme imkânı sağlayacaktır. Akademik ölçekte ele alınmış kapsamda incelenen çalışma akademik olmayan alanlarda ve küresel ölçekte de büyütülebilir ve uygulanabilirliğine sahiptir. Kodlarını açık kaynak olarak sunduğumuz çalışmayı kullanmak isteyen her ülke kendi özel ve kamu kurumlarının sisteme eklenme hiyerarşisine göre akıllı sözleşmeleri kendi iş gereksinimlerine göre güncelleyerek sistemi kolaylıkla kullanabilecektir.

Önerilen sistem akademik tavsiye mektubu aşamalarını öğrenci talebinden ilgili alıcı kuruma kadar ulaşmasını blok zinciri tabanlı dağıtık uygulama ile gerçekleştirmektedir. Bununla birlikte akademik olmayan kişilerden de kayıt sürecindeki işleyleştik değişikliklerle tavsiye mektubu alınabilecek hale getirilebilir. Referans iş akışının dışında, bir talebin alınıp ilgili kişiye ulaştırılması ve yetkili kişinin gerekli belgeyi ekleyip bir sonraki ilgili kişi veya kurumlara ulaştırılması sürecine sahip bütün sektörlerde kolaylıkla kullanılabilir. İlgili kişi tarafından talep edilen bir belge veya doküman yetkili ve ağda kayıtlı herhangi bir yetkili kişi veya kurum tarafından IPFS aracılığı ile blok zinciri ağına sadece hash değeri tutularak global ve hızlı bir şekilde erişimi sağlanabilir. Bu nedenle

dünyanın her ülkesinde yer alan yükseköğrenim kurumları, üniversiteler, akademisyenler, öğrenciler, kamu ve özel kurumları bu geliştirilen modeli kullanarak ilgili süreçlerini güvenli, izlenebilir, dağıtık ve güvenli hale getirebilir.

5. SONUÇ (CONCLUSION)

Bu makalede akademik tavsiye mektubundaki mevcut süreçlerde yer alan sorunlardan bahsedilmiş ve blok zinciri tabanlı akademik tavsiye mektubu modeli önerilmiştir. İş, staj ve eğitim başvuruları için sıklıkla öğrencilerden talep edilen bir aşama olarak akademik referans mektubu mevcut durumda belli bir standartı olmayan, fiziksel veya merkezi uygulama sunucularında dijital olarak saklanmaktadır. Önerdiğimiz model ile dağıtık olarak, izlenebilir, değiştirilemez ve küresel ölçekte genişletilebilir şekilde ve süreçlerdeki zaman kayıplarını en aza indireyecek şekilde tasarlanmıştır. Ethereum ağında geliştirilen sistem, Remix çevrim içi ortamı kullanılarak geliştirilmiş ve test edilmiştir. Belge ve doküman yüklemek için IPFS dağıtık dosya paylaşım sistemi kullanılmıştır. Geliştirilen akıllı sözleşmelerin kodları açık kaynakları olarak paylaşılmıştır. Mevcut olarak bazı önde gelen üniversitelerde kullanılan referans mektubu süreçleri ve blok zinciri tabanlı olarak tasarlanan diğer benzer çalışmalarla önerilen model karşılaştırılmıştır. Gelecekteki çalışmalarda akademik olmayan yani akademisyenler haricinde paydaşlar tarafından da belge ve doküman eklenebilir blok zinciri tabanlı uygulama modeli geliştirmelidir. Ayrıca test ortamında geliştirilen model gerçek Ethereum ağında uygulanma ve kullanıcı dostu önyüz uygulaması eklenerek tam bir web uygulaması olarak geliştirilmelidir.

KAYNAKLAR (REFERENCES)

- [1] B. T. Loher, J. T. Hazer, A. Tsai, K. Tilton, and J. James, "Letters of reference: A process approach", *Journal of Business and Psychology*, 11(3), 339-355, 1997.
- [2] S. H. Peres, J. R. Garcia, "Validity and dimensions of descriptive adjectives used in reference letters for engineering applicants", *Personnel Psychology*, 15(3), 279-286, 1962.
- [3] M. R. Anderson-Rowland, J. E. Sharp, "Helping Students (and ultimately faculty) write an effective recommendation letter", **38th Annual Frontiers in Education Conference**, New York, USA, 9-13, 2008.
- [4] P. Akos, J. Kretchmar, "Gender and Ethnic bias in Letters of Recommendation: Considerations for School Counselors", *Professional School Counseling*, 20(1), 102-113, 2016.
- [5] J. H. Kong, L. J. Steele, C. M. Botham, "Ten simple rules for writing compelling recommendation letters", *PLOS Computational Biology*, 17(2), 1-6, 2021.
- [6] J. Zarrin, H. Wen Phang, L. Babu Saheer, B. Zarrin, "Blockchain for decentralization of internet: prospects, trends, and challenges", *Cluster Computing*, 24(4), 2841-2866, 2021.
- [7] Internet: Could You Spot a Fake Employment Reference?, <https://www.socialtalent.com/blog/recruiting/fake-references>, 31.10.2022
- [8] S. Nakamoto, Bitcoin: A Peer-to-Peer Electronic Cash System, <https://bitcoin.org/bitcoin.pdf>, 2008.
- [9] P. C. Franks, "Implications of blockchain distributed ledger technology for records management and information governance programs", *Records Management Journal*, 30(3), 2020.
- [10] T. T. A. Dinh, R. Liu, M. Zhang, G. Chen, B. C. Ooi, J. Wang, "Untangling Blockchain: A Data Processing View of Blockchain Systems", *IEEE Transactions on Knowledge and Data Engineering*, 30(7), 2018.
- [11] M. A. Benatia, V. E. De Sa, D. Baudry, H. Delalin, P. Halftermeyer, "A framework for big data driven product traceability system", **4th International Conference on Advanced Technologies for Signal and Image Processing**, Sousse, Tunisia, 1-7, 2018.
- [12] P. K. Patro, R. W. Ahmad, I. Yaqoob, K. Salah, R. Jayaraman, "Blockchain-Based Solution for Product Recall Management in the Automotive Supply Chain", *IEEE Access*, 9, 167756- 167775, 2021.
- [13] K. Salah, M. H. U. Rehman, N. Nizamuddin, A. Al-Fuqaha, "Blockchain for AI: Review and open research challenges", *IEEE Access*, 7, 10127-10149, 2019.
- [14] Internet: Global 2000 List By The Center For World University Ranking, <https://cwur.org/2021-22.php>, 31.10.2022
- [15] Internet: Letters of recommendation, <https://mitadmissions.org/apply/firstyear/letters-of-recommendation>, 16.07.2022.
- [16] Internet: Interfolio's Dossier to manage and send out recommendation letters. <https://www.interfolio.com/products/dossier>, 12.07.2022.
- [17] Internet: Cambridge: Application Process, <https://www.postgraduate.study.cam.ac.uk/application-process>, 16.07.2022.
- [18] Internet: Letters of Recommendation, <https://admission.stanford.edu/apply/transfer/evals.html>, 16.07.2022.
- [19] Internet: Letters of Recommendation, <https://www.gse.harvard.edu/admissions/faq/letters-recommendation>, 13.07.2022.
- [20] Internet: Application Requirements, <https://www.gradoffice.caltech.edu/admissions/checklist>, 14.07.2022.
- [21] Internet: Graduate Program Applications, <https://fbe.metu.edu.tr/en>, 18.07.2022.
- [22] Internet: Executive and Other Graduate Programs Application, http://adaylar.boun.edu.tr/en-EN/Page/Admissions/II_Education/All, 17.07.2022.
- [23] S. A. Raza, W. Qazi, K. A. Khan, J. Salam, "Social Isolation and Acceptance of the Learning Management System (LMS) in the time of COVID-19 Pandemic: An Expansion of the UTAUT Model", *Journal of Educational Computing Research*, 59(2), 183-208, 2021.

- [24] E. C. K. Cheng, T. Wang, "Institutional Strategies for Cybersecurity in Higher Education Institutions", *Information*, 13(4), 192, 2022.
- [25] Internet: Bluevoyant. Cybersecurity in Higher Education Report. BlueVoyant. <https://www.bluevoyant.com/resources/cybersecurity-in-higher-education>, 31.10.2022
- [26] K. Beaudin, "The Legal Implications of Storing Student Data: Preparing for and Responding to Data Breaches", *New Directions for Institutional Research*, 2016(172), 37-48, 2017.
- [27] M. Rahman, H. Sultana, S. Paul, N. Mobtashim, "Online Recommendation Letter Verification Using Blockchain Technology", *International Journal of Scientific & Technology Research*, 10(9), 80-85, 2021.
- [28] V. Marella, A. Vijayan, "Document verification using blockchain for trusted CV information", **26th Americas Conference on Information Systems**, Utah, USA, 1-10, 2020.
- [29] N. Kumavat, "Certificate Verification System using Blockchain", *International Journal for Research in Applied Science and Engineering Technology*, 7, 53-57, 2019.
- [30] A. Taha, A. Zakaria, "Truver: A blockchain for verifying credentials: Poster", **Proceedings of the ACM Symposium on Applied Computing**, New York, USA, 346-348 2020.
- [31] R. Alabduljabbar, "Development of a System to Manage Letters of Recommendation", *International Journal of Advanced Computer Science and Applications*, 12(1), 2021.
- [32] B. Yu, P. Zhan, M. Lei, F. Zhou, P. Wang, "Food Quality Monitoring System Based on Smart Contracts and Evaluation Models", *IEEE Access*, 8, 12479-12490, 2020.
- [33] A. Donmez, A. Karaivanov, "Transaction fee economics in the Ethereum blockchain", *Economic Inquiry*, 60(1), 2022.
- [34] M. M. A. Khan, H. M. A. Sarwar, M. Awais, "Gas consumption analysis of Ethereum blockchain transactions", *Concurrency and Computation: Practice and Experience*, 34(4), 2022.
- [35] E. Karataş, "Developing Ethereum Blockchain-Based Document Verification Smart Contract for Moodle Learning Management System", *Bilişim Teknolojileri Dergisi*, 11(4), 399-406, DOI: 10.17671/gazibtd.452686, 2018.
- [36] Internet: Ethereum Gas Station, Recommended priority fee in Gwei, <https://ethgasstation.info>, 07.07.2022.
- [37] O. Ali, A. Jaradat, A. Kulakli, A. Abuhlimeh, "A Comparative Study: Blockchain Technology Utilization Benefits, Challenges and Functionalities", *IEEE Access*, 9, 12730-12749, 2021.