

Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi ve Yapay Sinir Ağları ile Türkiye’deki COVID-19 Vefat Sayısının Tahmin Edilmesi

Araştırma Makalesi/Research Article

 Tülay TURAN^{1*},  Gökhan TURAN¹,  Utku KÖSE²

¹Bilgisayar Teknolojileri Bölümü, Burdur Mehmet Akif Ersoy Üniversitesi, Burdur, Türkiye

²Bilgisayar Mühendisliği Bölümü, Süleyman Demirel Üniversitesi, Isparta, Türkiye

tulayturan@mehmetakif.edu.tr, gokhanturan@mehmetakif.edu.tr, utkukose@sdu.edu.tr

(Geliş/Received:06.04.2021; Kabul/Accepted:26.01.2022)

DOI: 10.17671/gazibtd.910806

Özet— COVID-19, küresel pandemi olarak ilan edilmiş, kritik ve ölümcül bir hastalıktır. Küresel salgın tehlikesinin sürmekte olduğu bu süreçte, pandemi ile yüzleşmek için özel politikalar ve planlar yapmak oldukça önemlidir. COVID-19 doğrulanmış verilerini kullanarak, yapay zeka teknikleri ile tahminlerde bulunmak ise gelecek planlarının geliştirilmesine yardımcı olduğu için önemli bir konudur. Bu çalışmada, Türkiye Sağlık Bakanlığı COVID-19 bilgilendirme sayfasında yayımlanan veriler kullanılarak, uyarlamalı ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS) ve yapay sinir ağları (YSA) ile tahmin modelleri geliştirilmiştir. Bu modeller farklı istatistiksel değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Değerlendirme sonucunda ANFIS modeli 0.0247 ortalama mutlak hata (MAE) değeri, 0.0012 ortalama kare hata (MSE) değeri, 0.0351 kök ortalama kare hata (RMSE) değeri ve 0.9847 regresyon katsayısı R² sonucu ile en iyi model sonucunu elde etmiştir. Ayrıca ANFIS ile oluşturulan modelin gelecek beş günlük vefat sayılarını %96 doğruluk oranı ile tahmin ettiği görülmüştür.

Anahtar Kelimeler— COVID-19, pandemi, ANFIS, yapay sinir ağları, tahmin, Türkiye, vefat sayısı

Prediction of the COVID-19 Number of Death in Turkey by Adaptive Neuro-Fuzzy Inference System and Artificial Neural Networks

Abstract— COVID-19 is a critical and fatal disease, which was declared as the global pandemic. In this process in which the global pandemic state is alive, it is too important to make specific policies and plans to face the pandemic. Using COVID-19 verified data and making predictions with artificial intelligence techniques is an important issue as it allows deriving of future plans. In this study, Turkey's Health Ministry COVID-19 in the informational pages published using data, adaptive neuro-fuzzy inference system (ANFIS), and the artificial neural network (ANN) prediction models have been developed. These models were compared using different statistical evaluation criteria. As a result of the evaluation, the ANFIS model obtained the best model results with 0.0247 mean absolute error (MAE) value, 0.0012 mean square error (MSE) value, 0.0351 root mean square error (RMSE) value and 0.9847 regression coefficient R². In addition, it was seen that the model created with ANFIS showed a better performance and predicted the number of deaths in the next five days with an accuracy rate of 96%.

Keywords— COVID-19, pandemic, ANFIS, artificial neural networks, forecast, Turkey, death count

1. GİRİŞ (INTRODUCTION)

COVID-19, Aralık-2019 civarında Vuhan'da (Çin) ortaya çıkmış olan ölümcül bir virüsdür [1-3]. Bu virüsün yaptığı hastalığa Yeni Koronavirüs Hastalığı (COVID-19) adı verilmiş olup, Türkiye sınırları kapsamında ilk vaka 11 Mart 2020'de saptanmıştır [4-5]. Dünya Sağlık Örgütü (WHO), virüsün hızlı yayılma durumu ve ölümcül bağlamdaki şiddetinden yola çıkarak bu hastalığı tarihinde küresel salgın (diğer bir deyişle pandemi) olarak (11 Mart 2020) kamuoyuna bildirmiştir [6-8]. Pandemi sürecinin etkin bir şekilde yönetilebilmesi, kontrol edilebilmesi ve salgın yayılımlarının tahmin edilebilmesi için, yapay zekâ tabanlı sistemler ile çözümler bulmak ve geliştirmek önemlidir. Dünyada ve Türkiye'de paylaşılan COVID-19 verilerini kullanarak modeller çıkarmak, analiz etmek ve sonuçlar çıkarmak mümkündür. Birçok bilim insanı tarafından yapılan yapay zekâ tabanlı çalışmalar incelendiğinde, COVID-19 hastalık teşhisi [9-12], hastalık etken tahmini [13-15] ve zaman serisi tahmini [16-18] gibi konular ile pandemi sürecine olumlu çözümler ürettikleri görülmüştür. Sevli ve Başer çalışmalarında, COVID-19 dünya verileri üzerinde, Prophet ile model oluşturmuşlardır. Bu model ile vaka sayısı, iyileşen sayısı ve vefat sayısının, gelecek bir haftalık sürecini tahmin etmişlerdir. Sonuç olarak, vaka ve vefat sayısı artışının tahmin modeline göre daha fazla, iyileşen sayısının ise tahminler doğrultusunda gerçekleştiğini belirtmişlerdir [19]. Ly çalışmasında İngiltere'deki COVID-19 vaka sayısını tahmin etmek için uyarlanabilir nöro-bulanık çıkarım sistemi kullanmıştır. Ayrıca, İngiltere COVID-19 veri setine İtalya ve İspanya COVID-19 verilerini de ekleyerek, daha iyi tahmin sonucuna ulaştığını belirtmiştir [20]. Pinter ve arkadaşları çalışmalarında, COVID-19 Macaristan verilerini tahmin etmek için hibrit bir makine öğrenimi yaklaşımı önermektedirler. Enfekte bireylerin zaman serilerini ve ölüm oranını tahmin etmek için uyarlanabilir ağ tabanlı bulanık çıkarım sistemini ve çok katmanlı algılayıcı emperyalist rekabetçi algoritmasını (MLP-ICA) kullanmışlardır [21]. Al-Qaness ve arkadaşları çalışmalarında, Rusya ve Brezilya'daki COVID-19 salgını tahmin etmek için kaotik deniz avcıları algoritması (CMPA) ile uyarlanabilir nöro bulanık çıkarım sistemi modeli tasarlamışlardır. CMPA ile diğer tüm modellerden önemli ölçüde daha iyi performans elde ettiklerini belirtmişlerdir [22]. Alile ve Otokiti çalışmalarında COVID-19'u tahmin etmek için Bayesian Belief Network (BBN) ile model oluşturmuşlardır. Bu model ile veri setlerini eğitmişler ve test verileri ile COVID-19'u %99 doğruluk ile tahmin ettiklerini belirtmişlerdir [23]. Rauf ve arkadaşları çalışmalarında COVID-19 vaka sayısını tahmin etmek için derin öğrenme tekniklerinden LSTM, RNN ve GRU yöntemlerini kullanmışlar ve %90 doğruluk ile vaka sayısını tahmin ettiklerini belirtmişlerdir [24]. Ukaoha ve arkadaşları çalışmalarında COVID-19 teşhisi için 600 verinin bulunduğu veri setini ANFIS ile eğitimini gerçekleştirdiklerini ve bu model ile %96,6 doğruluğa sahip bir sonuç elde ettiklerini belirtmişlerdir [25].


Bu çalışmada, öncelikle yapay zekâ tekniklerinden ANFIS ve YSA ile Türkiye COVID-19 verileri kullanılarak tahmin modelleri geliştirilmiştir. Daha sonra ANFIS ve YSA modellerinden en iyi performans gösterenler, istatistiksel yöntemler ile belirlenmiştir. Son olarak da belirlenen modeller kullanılarak, gelecek günlere ait vefat sayısı tahmini gerçekleştirilmiş olup, ANFIS modelinin %96 doğruluk oranı ile gelecek beş günü tahmin etme başarısı gösterdiği görülmüştür.

2. MATERYAL METOT (MATERIAL METHOD)


2.1. Veri Seti (Data Set)

Veri seti, Türkiye Sağlık Bakanlığı COVID-19 bilgilendirme sayfasında yayımlanan, 27 Mart 2020 ile 17 Ocak 2021 tarihleri arasındaki 297 günlük istatistiksel raporlardan oluşturulmuştur [26].


Bu çalışma kapsamına ait veri setinde yer alan hasta sayısı, iyileşen sayısı ve test sayısı bağımsız değişkenler olarak, vefat sayısı bağımlı değişken olarak ele alınmıştır. Günlere ait test sayısı Şekil 1'de, hasta sayısı Şekil 2'de, iyileşen sayısı Şekil 3'te ve vefat sayısı Şekil 4'de gösterilmektedir.




Şekil 1. Günlere göre test sayısı grafiği
(Number of tests graph by days)



Şekil 2. Günlere göre hasta sayısı grafiği
(Number of patients graph by days)



Şekil 3. Günlere göre iyileşen sayısı grafiği
(Number of recovered graph by days)



Şekil 4. Günlere göre vefat sayısı grafiği
(Number of deaths graph by days)

Veri setindeki tüm değişkenler min-max normalizasyonu kullanılarak normalize edilmiştir. Min-max normalizasyonunda en büyük değer 1, en küçük değer 0 olacak şekilde diğer tüm değerler 0-1 aralığında normalleştirilir. Değer aralığının sınırlandırılması standart sapma değerinin küçülmesini sağlar [27]. Normalizasyon işlemi denklem (1)'de gösterilmektedir.

$$z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (1)$$

z_i normalize edilmiş veri; x_i girdi değeri; $\min(x)$ girdi seti içerisindeki en küçük değeri; $\max(x)$ girdi seti içerisindeki en büyük değeri ifade etmektedir.

Normalize edilmiş veriler, model doğrulama metodlarından Holdout yöntemi ile %80 eğitim, %20 test seti olarak ikiye bölünerek, ANFIS ve YSA modelleri oluşturulmuştur.

2.2. Model Değerlendirme Yöntemleri (Model Evaluation Methods)

Bu çalışmada, ANFIS ve YSA ile oluşturulan modellerin performans başarılarını değerlendirmek için MAE: mean absolute error, MSE: mean squared error, RMSE: root mean square error ve hatta R^2 : regresyon kat sayısı hesaplama yöntemleri kullanılmıştır.

Root Mean Square Error (RMSE), denklem 2'de gösterildiği şekilde hesaplanmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (2)$$

Mean Absolute Error (MAE), denklem 3'de gösterildiği şekilde hesaplanmıştır.

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (3)$$

Mean Squared Error (MSE), denklem 4'de gösterildiği şekilde hesaplanmıştır.

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (4)$$

Regresyon kat sayısı (R^2), denklem 4'de gösterildiği şekilde hesaplanmıştır.

$$R^2 = 1 - \frac{\sum_i^N (X_{Gerçek,i} - X_{tahmin,i})^2}{\sum_i^N (X_{Gerçek,i})^2} \quad (5)$$

Değerlendirme yöntemlerinden RMSE, MAE ve MSE sonuçlarının sıfıra yakın, R^2 değerinin ise bire yakın olması, iyi bir model performansı elde edildiği yorumunun yapılmasını sağlayacaktır.

2.3. Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System)

ANFIS, Sugeno türünden bulanık çıkarım sistemlerinin sinir-tabanlı ağlara uyarlanmış hali olmakla birlikte, 'if-then' kurallarını kullanarak girdi ve çıktı arasında bir eşleşme oluşturan yapıdır. ANFIS yapısında yer alan her bir düğüm belli bir fonksiyon işlemi gerçekleştirmektedir [28]. Sistem, üyelik fonksiyonlarını öğrenmek için geri yayılımı kullanır. En küçük kare tahmini ile de doğrusal kombinasyonların katsayılarını belirler [29]. İki adet giriş değişkenine (x , y) ve bir adet çıkışa (f) sahip bir ANFIS sistem kural kümesi denklem 6'da gösterildiği şekilde ifade edilir.

$$f = p_1 x + q_1 y + r_1 \quad (6)$$

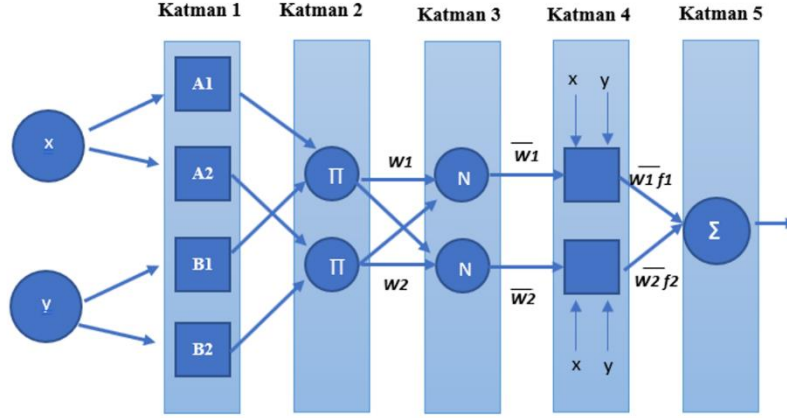
ANFIS, paralel işlem becerisi, yapılandırılmış bilgi temsili ve öğrenme yeteneği ile diğer çok katmanlı perceptronlara göre daha kuvvetlidir [30]. ANFIS beş katmandan oluşan sinir ağı modeline sahiptir [31]. Şekil 5'de ANFIS genel yapısı yer almaktadır.

ANFIS sisteminin birinci katmanı bulanıklaştırma katmanıdır. Bu katmanda, tüm düğümler için seçilen üyelik fonksiyonuna göre üyelik değerleri hesaplanır. Ayrıca her düğüme ait dilsel değişkenlerde bu katmanda belirlenir. Katmandaki her bir düğümün çıkışı denklem 7'de verildiği gibi hesaplanır.

$$O_{1i} = \mu_{A_i}(x), \quad i = 1, b \quad (7)$$

$$O_{1i} = \mu_{B_{i-2}}(y), \quad i = 3,4$$

İkinci katman kurallar katmanıdır. Bu katmanda, bulanık belirti değerleri Takagi Sugeno çıkarım kuralı kullanılarak birleştirilir ve her bir durum için sonuç oluşturulur.



Şekil 5. ANFIS modeli
(ANFIS model)

Üçüncü katman normalleştirme katmanıdır. Bu katmanda bulanıklaştırılmış girdi değerleri ağırlık fonksiyonlarıyla çarpılıp, toplanmış büyüklükleri normalize edilmektedir [32]. Denklem 9'da verildiği gibi hesaplanır.

$$O_{3i} = \bar{w}_i = \frac{\omega_i}{\sum_{i=1}^2 \omega_i} \quad (9)$$

Dördüncü katman durulaştırma katmanıdır. Bulanıklaşan değerlerin tekrar keskin hale getirilmesi ve her bir düğümün model çıktısı üzerindeki katkısı, bu katmanda belirlenir [33]. Denklem 10'da verildiği gibi hesaplanır.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (10)$$

Beşinci katman toplam katmanıdır. Tüm düğümlerden gelen çıkış değerlerinin toplandığı katmandır. Denklem 11'de verildiği gibi hesaplanır.

$$O_5 = \sum_i \bar{w}_i f_i \quad (11)$$

ANFIS performans değerlendirmesi, seçilen üyelik fonksiyonuna, optimizasyon yöntemine ve belirlenen kural sayısına bağlı olarak belirlenmektedir.

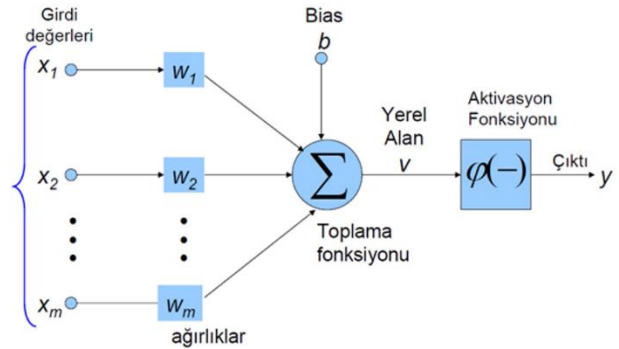
2.4. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları, beyin adı verilen bilgi depolama-işleme organının genel işleyişini referans alan ve sınıflandırma, regresyon problemleri için kullanılan makine öğrenmesi algoritmalarından biridir [34]. Yapay sinir ağları ile veri ilişkilendirme, tanıma, optimizasyon, sınıflandırma ve geleceğe yönelik tahminler yapılabilir [35].

Katmandaki her bir düğümün çıkışı denklem 8'de verildiği gibi hesaplanır.

$$O_{2i} = \mu_{A_i}(x) * \mu_{B_{i-2}}(y) \quad (8)$$

YSA'da işlem birimleri vardır. Her bir işlem birimine yapay sinir hücresi adı verilir. Tipik bir yapay sinir hücresi ağırlıklanmış girdiler / girişler, toplayıcı bir fonksiyon, bu fonksiyonu takip eden bir aktivasyon fonksiyonu ve akabinde çıkıştan oluşur. Girdiler, bağımsız değişkenlerin değerleridir. Ağırlıklar, katsayı değerleridir ve her girdi ile çarpılarak sonuçları, toplama fonksiyonuna gönderilir. Ağırlıklanmış giriş değerleri, toplama fonksiyonunda toplandıktan sonra, aktivasyon fonksiyonu ile işlenir ve çıkış değeri olarak üretilir [36]. Şekil 6'da Yapay Sinir Hücresi yer almaktadır.



Şekil 6. Yapay sinir hücresi
(Artificial nerve cell)

Yapay sinir ağları, birçok yapay sinir hücresinin birleşiminden oluşmaktadır. Bağlantılarına göre ileri veya geri beslemeli ağlar olarak tanımlanmaktadır [37]. İleri beslemeli ağlarda her ilgili katman bünyesinde işlenen veri kendinden sonra gelen katmana ağırlıklandırma işlemi gerçekleştirilerek iletilmektedir. Geri besleme mekanizması odağındaki ağlarda ise hem ileri hem de geri veri akışı sağlanmakta, dinamik yapısı ile tahmin problemlerinde daha iyi sonuçlar elde edilmektedir [38]. Bu çalışmada da yapay sinir ağları tabanlı çözümler

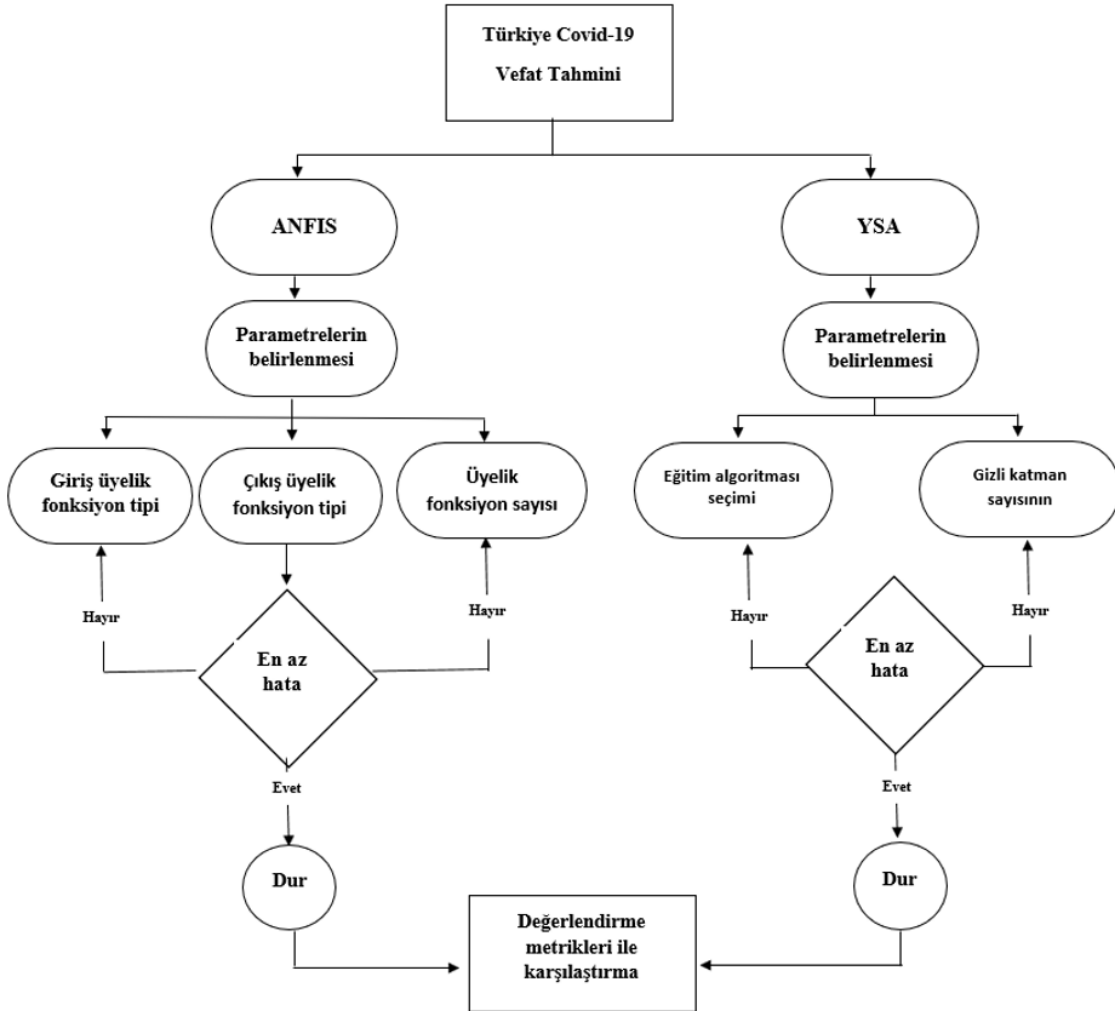
üzerinden en küçük hata değeri ile tahmin yapabilen katsayılara ulaşmak hedeflenmiştir.

3. UYGULAMA (APPLICATION)

Bu çalışmada Türkiye COVID-19 verileri kullanılarak oluşturulan veri seti üzerinde, günlük vefat sayısını tahmin etmek için çeşitli ANFIS ve YSA modelleri geliştirilmiştir.

Çalışma sırasında izlenen akış şeması Şekil 7'de verilmiştir.


ANFIS modellerinin performansı, giriş üyelik fonksiyonun belirlenmesine, çıkış üyelik fonksiyonu türüne, üyelik fonksiyonu sayısına, optimizasyon türüne ve belirlenen kurallara göre değişmektedir. Bu çalışma bağlamında optimizasyon yöntemi olarak hibrit yöntemi seçilmiş ve toplamda 16 model eğitilmiştir.




Şekil 7. Çalışmanın akış şeması
(Flowchart of the study)

Hybrid Optimizasyon yöntemi ile eğitilen modellerden, giriş üyelik fonksiyonu olarak gauss fonksiyonu, çıkış üyelik fonksiyonu constant fonksiyonu olarak belirlenen model değerlendirme ölçütlerine göre en az hata oranına sahip olarak, en iyi yaklaşımı sağlayan model olarak belirlenmiştir. Model'e ait ANFIS ağ yapısı Şekil 8'de gösterilmektedir.

İlgili modelde, üç giriş üyelik fonksiyonundan yirmi yedi bulanık kuralı üretilmektedir. Belirli bir vaka sayısı, iyileşen sayısı ve test sayısına göre, vefat sayısı değeri için bulanık kuralın çıktısı Şekil 9'da göstermektedir.



Şekil 8. ANFIS ağ yapısı
(ANFIS network structure)



Şekil 9. ANFIS kuralları
(ANFIS rules)

Tespit edilen en iyi ANFIS modelini değerlendirmek için eğitim ve test RMSE değerleri hesaplanmış ve birbirleri ile karşılaştırılmıştır. Buna göre, elde edilen sonuçlara göre gauss modeli sabit çıktı üyelik fonksiyonu ile en az eğitim ve test hatasını elde etmiştir. Tablo 1'de eğitim ve test RMSE değerleri gösterilmektedir.

Tablo 1. Eğitim ve test RMSE değerleri
(Training and testing RMSE values)

Çıkış Üyelik Fonksiyonu	Giriş Üyelik Fonksiyonu	Train RMSE	Test RMSE
constant	<i>trimf</i>	0.032933	0.0711588
	<i>trapmf</i>	0.043653	0.0667386
	<i>gbellmf</i>	0.032031	0.0670854
	<i>gaussmf</i>	0.029741	0.0487306
	<i>gauss2mf</i>	0.030948	0.0695225
	<i>pimf</i>	0.043408	0.0591242
	<i>dsigmf</i>	0.0591242	0.0859523
linear	<i>psigmf</i>	0.030410	0.0859524
	<i>trimf</i>	0.024449	0.0575956
	<i>trapmf</i>	0.029100	0.168608
	<i>gbellmf</i>	0.021495	0.0879616
	<i>gaussmf</i>	0.023831	0.0567048
	<i>gauss2mf</i>	0.023434	0.0652297
	<i>pimf</i>	0.023016	0.130079
	<i>dsigmf</i>	0.022592	0.0959541
<i>psigmf</i>	0.022592	0.0959541	

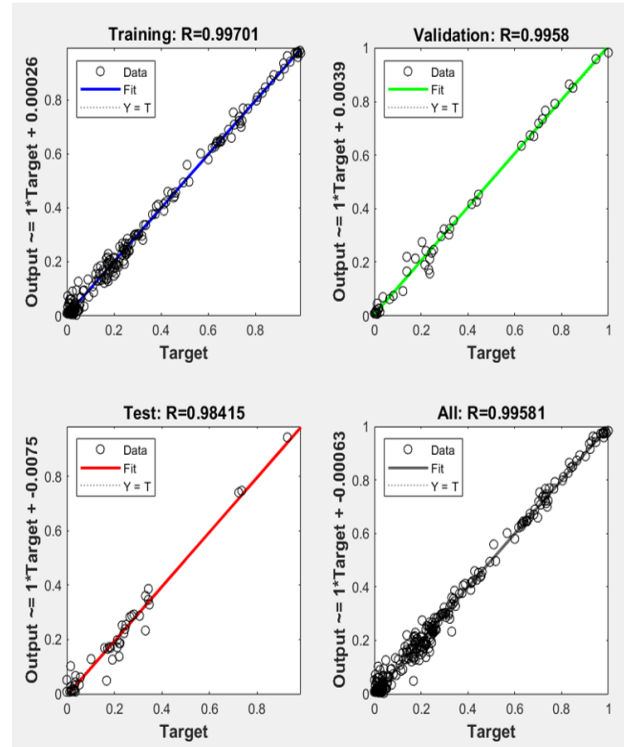
YSA modellerinin performansı, model-ağ türü, öğrenme süreci fonksiyonu, performans odaklı fonksiyon, gizli katmanların sayısı ve nihayetinde işe koşulan aktivasyon fonksiyonuna göre değişmektedir. Dolayısıyla çalışma sürecinde bu bağlamdaki çok sayıda farklı tür yapılar seçilerek modeller oluşturulmuştur. En iyi performansın

elde edildiği YSA modelinin girdi yapısı Tablo 2'de gösterilmektedir.

Tablo 2. Yapay Sinir Ağları modeli
(Artificial Neural Network model)

Ağ Tipi	Feed Forward Back Propagation Neural Network
Eğitim Fonksiyonu	TRAINLM
Öğrenme Süreci Fonksiyonu	LEARNGDM
Performans Odaklı Fonksiyon	MSE
Toplam Gizli Katmanlar Sayısı	10

İleri besleme geri yayılım ağ tipinde oluşturulan model üç giriş, on gizli katman ve bir çıkışa sahiptir. YSA modeli 1000 epoch(döngü) kullanılarak eğitilmiştir. Eğitim sonucunda söz konusu model, Şekil 10'da görülen regresyon değerlerine sahip olmuştur. Buna göre, belirlilik katsayısı 0.99 un üzerinde çıkmıştır. Böylelikle bağımlı değişkenin, bağımsız değişkenler tarafından %99 un üzerinde açıklandığı görülmektedir.



Şekil 10. YSA model regresyon grafiği
(ANN model regression graph)

4. SONUÇLAR (CONCLUSIONS)

Yapay zeka teknikleri ile pandemi sürecine ait verilerin kullanılarak, gelecek ile ilgili tahminler oluşturulması ve bu tahminler ışığında planlamalar yapılması önemli bir konudur. COVID19 tahmini ile ilgili güncel yayımlar

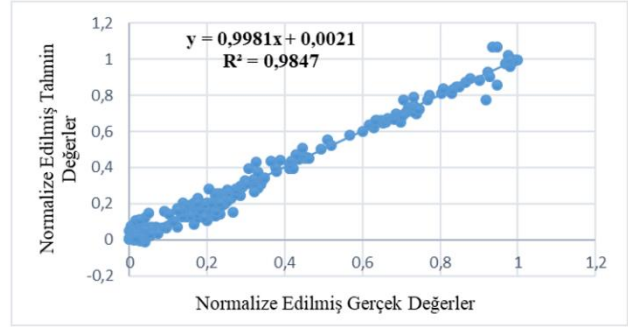
dikkate alındığında; kullanılan veri setleri ve yöntemler Tablo 3'de gösterildiği şekildedir.

Tablo 3. COVID-19 tahmini ile ilgili güncel çalışmalar
(Recent studies regarding COVID-19)

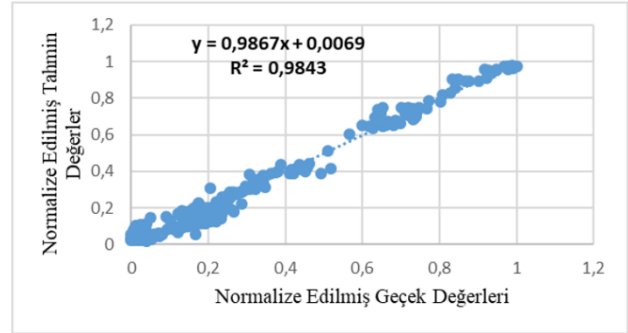
Makale Adı	Veri Seti	Kullanılan Yöntem
Makine Öğrenmesi Yöntemleri İle COVID-19 Verilerinin İncelenmesi: Türkiye Örneği [39]	Türkiye Sağlık Bakanlığı Sitesi	Random Forest
Forecasting Models For COVID-19 Cases Of Turkey Using Artificial Neural Networks and Deep Learning [40]	Türkiye Sağlık Bakanlığı Sitesi	ANN, LSTM
COVID-19 Salgınına Yönelik Zaman Serisi Verileri ile Prophet Model Kullanarak Makine Öğrenmesi Temelli Vaka Tahminlemesi [19]	COVID-19 Global Cases	Prophet Model
Makine öğrenmesi algoritmaları ile COVID-19 hastalarının belirlenmesi [41]	Albert Einstein Hastanesi dataset	KNN, NB,SVM
Optimization Method for Forecasting Confirmed Cases of COVID-19 in China [42]	Dünya Sağlık Örgütü web sitesi	ANFIS, FPA, SSA
Forecasting the novel coronavirus COVID-19 [43]	Johns Hopkins Üniversitesi dataset	Time Series
Estimation of COVID-19 prevalence in Italy, Spain, and France [44]	Dünya Sağlık Örgütü web sitesi	Time Series
Analysis and forecast of COVID-19 spreading in China, Italy and France [45]	Dünya Sağlık Örgütü web sitesi	SIR
Bu çalışma	Türkiye Sağlık Bakanlığı Sitesi	YSA, ANFIS

Tablo 3'de sunulan alternatifler dikkate alındığında özellikle zaman serisi (time series) çözümlerinin uzun zamandır takip edilen uygulamalar olduğu için sağlıklı çözümler üretebildikleri görülmektedir. Diğer yandan SVM tekniği, özellikle sinir ağları tabanlı çözümlere önemli bir alternatif oluşturmaktadır. Ancak bu çalışmada dikkate alınan veri dikkate alındığında sinir ağları çözümlerinin hız, tutarlılık ve doğruluk anlamında daha uygun bir yaklaşım sergilediği değerlendirilmektedir. Diğer yandan KNN, NB ve SIR gibi çözümler de daha hızlı çözüm için tercih edilebilecektir. Ancak hız ve doğruluk arasındaki dengeyi kurmak adına bu çalışmada uyarlamalı ağ tabanlı bulanık mantık çıkarım sistemi ve yapay sinir ağları kapsamında bir uygulama kapsamının takip edilmesini tercih edilmiştir. Tablo 3'deki çalışmalardan farklı olarak bu çalışmada, Türkiye COVID-19 vefat sayısını,

uyarlamalı ağ tabanlı bulanık mantık çıkarım sistemi ve yapay sinir ağları kullanarak tahmin etmekteyiz. Oluşturulan modeller karşılaştırıldığında; vefat sayısını en iyi doğruluk oranı ve en az hata değerleri ile ANFIS modelinin tahmin ettiği sonucuna ulaşılmaktadır. Gerçek değerler ve tahmin değerleri arasındaki denklem ve r kare değeri ANFIS modeli için Şekil 11'de, YSA modeli için Şekil 12'de gösterilmektedir.



Şekil 11. ANFIS model denklemi
(ANFIS model equation)



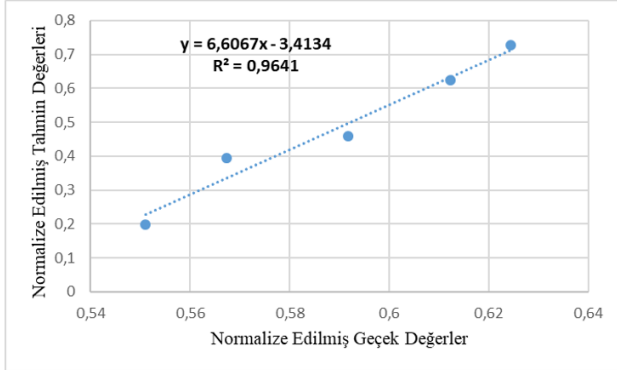
Şekil 12. YSA model denklemi
(YSA model equation)

Bu çalışma kapsamında ayrıca, ANFIS ve YSA ile oluşturulan modellerin sonuçları, diğer makine öğrenmesi yöntemlerinden K-Nearest Neighbors (KNN), Support Vector Regression (SVR) ve Random Forest (RF) regresyon modelleri ile de karşılaştırılmıştır. Modellerin değerlendirmeleri için ortalama mutlak hata (MAE), ortalama kare hata (MSE), kök ortalama kare hata (RMSE) ve regresyon katsayısı R² kullanılmıştır. Değerlendirme sonuçları Tablo 4'de yer almaktadır.

Tablo 4. Değerlendirme ölçüt sonuçları
(Evaluation criteria results)

	MAE	MSE	RMSE	R ²
KNN	0.025251700	0.001525031	0.039051648	0.9782
SVR	0.045900318	0.003004133	0.054809973	0.9570
RF	0.026088435	0.002148618	0.046353194	0.9693
YSA	0.026669676	0.001267148	0.035597026	0.9843
ANFIS	0.024754568	0.001237276	0.035174928	0.9847

Çalışmanın sonunda, 297 günlük veriye göre oluşturulan ANFIS modeli, gelecek günleri tahmin etme durumunu görmek için eğitim ve test setinde yer almayan veriler kullanılarak sınanmıştır. Sonuç olarak, modelin 17 Ocak 2021 tarihini takip eden 5 günü %96 doğruluk oranı ile tahmin edebildiği Şekil 13'de gösterilmektedir.



Şekil 13. ANFIS ile gelecek tahmini
(Future prediction with ANFIS)

Geliştirilen model ile Türkiye COVID-19 vefat sayıları tahmin edilebilmektedir. Bu model istenilirse diğer dünya ülkeleri tarafından yayımlanan veri setleri kullanılarak, ilgili ülkeye ait vefat sayılarının da tahmin edilmesinde kullanılabilir. Ayrıca benzer yaklaşımlar, modeller kullanılarak, COVID-19 verileri üzerinde farklı değişkenler içinde tahmin modelleri geliştirilebilir, Türkiye'nin pandemi sürecindeki gelecek plan ve politikalarının belirlenmesine katkı sağlanabilir. Buradan hareketle yazarlar da ilerleyen çalışmalar ölçeğinde yeni varyantlar karşısında değişkenlik gösterebilecek vefat sayı tahminleri üzerinde çalışmayı ve bu çalışmalarını yine alternatif tekniklerle karşılaştırmalı olarak incelemeyi düşünmektedir. Yine gelecek çalışmalar bağlamında COVID-19 ile ilgili farklı durumların (örneğin, iyileşme hızı, aşılama karşısında alternatif değişkenlikler...vs.) incelenmesi de yer almaktadır.

KAYNAKLAR (REFERENCES)

- [1] Y. N. Mi, T. T. Huang, J. X. Zhang, Q. Qin, Y. X. Gong, S. Y. Liu, Y. X. Cao, "Estimating The Instant Case Fatality Rate of COVID-19 In China", *International Journal of Infectious Diseases*, 97, 1-6, 2020.
- [2] K. Senel, M. Özdiñç, S. Ozturkcan, A. Akgul, "Instantaneous R for COVID-19 in Turkey: estimation by Bayesian statistical inference", *Türkiye Klinikleri Journal of Medical Sciences*, 40(2), 127-131, 2020.
- [3] B. Ergül, A. Altın Yavuz, E. Gündoğan Aşık, B. Kalay, "Dünyada ve Türkiye'de nisan ayı itibarıyla COVID-19 salgın verilerinin istatistiksel değerlendirilmesi", *Anadolu Kliniği Tıp Bilimleri Dergisi*, 25(1), 130-141, 2020.
- [4] Internet: T.C. Sağlık Bakanlığı, <https://COVID19.saglik.gov.tr/>, 3.01.2021.
- [5] T. B. Alakus, I. Turkoglu, "Comparison of deep learning approaches to predict COVID-19 infection". *Chaos Solitons & Fractals*, 140, 110120, 2020.
- [6] Internet: Dünya Sağlık Örgütü, <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/question-and-answers-hub/q-a-detail/coronavirus-disease-COVID-19,03.01.2021>.
- [7] N. S. Punn, S. K., Sonbhadra, S. Agarwal, "COVID-19 Epidemic Analysis Using Machine Learning And Deep Learning Algorithms", *MedRxiv*, 2020.
- [8] A. Zeroual, F. Harrou, A. Dairi, Y. Sun, "Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study". *Chaos Solitons & Fractals*, 140, 110121, 2020.
- [9] R. Zhang, X. Tie, Z. Qi, N. B. Bevins, C. Zhang, D. Griner, G. H. Chen, "Diagnosis of Coronavirus Disease 2019 Pneumonia by Using Chest Radiography Value of Artificial Intelligence", *Radiology*, 298(2), E88-E97, 2020.
- [10] J. S. Suri, S. Agarwal, S. K. Gupta, A. Puvvula, M. Biswas, L. Saba, & S. Naidu, "A Narrative Review on Characterization of Acute Respiratory Distress Syndrome in COVID-19-infected Lungs using Artificial Intelligence", *Computers in Biology and Medicine*, 130, 2021.
- [11] N. Lessmann, C. I. Sánchez, L. Beenen, L. H. Boulogne, M. Brink, E. Calli, ... & B. Ginneken, "Automated Assessment of COVID-19 Reporting and Data System and Chest CT Severity Scores in Patients Suspected of Having COVID-19 Using Artificial Intelligence", *Radiology*, 298(1), E18-E28, 2021.
- [12] K. Rangarajan, S. Muku, A. K. Garg, P. Gabra, S. H. Shankar, N. Nischal, ... & C. Arora, "Artificial Intelligence-assisted chest X-ray assessment scheme for COVID-19", *European Radiology*, 31(1), 1-10, 2021.
- [13] S. Schalekamp, M. Huisman, R. A. van Dijk, M. F. Boomsma, P. J. Freire Jorge, W. S. de Boer, ... & C. M. Schaefer-Prokop, "Model-based prediction of critical illness in hospitalized patients with COVID-19", *Radiology*, 298(1), E46-E54, 2021.
- [14] A. Caillon, K. Zhao, K. O. Klein, C. Greenwood, Z. Lu, P. Paradis, & E. L. Schiffrin, "High systolic blood pressure at hospital admission is an important risk factor in models predicting outcome of COVID-19 patients", *American Journal of Hypertension*, 34(1), 1-29, 2021.
- [15] X. Guan, B. Zhang, M. Fu, M. Li, X. Yuan, Y. Zhu, ... & Y. Lu, "Clinical and inflammatory features based machine learning model for fatal risk prediction of hospitalized COVID-19 patients: results from a retrospective cohort study", *Annals of Medicine*, 53(1), 257-266, 2021.
- [16] Z. He, Y. Chin, S. Yu, J. Huang, C. J. Zhang, K. Zhu, ... & W. K. Ming, "The Influence of Average Temperature and Relative Humidity on New Cases of COVID-19: Time-Series Analysis", *JMIR Public Health and Surveillance*, 7(1), 1-14, 2021.
- [17] H. T. Rauf, M. I. U. Lali, M. A. Khan, S. Kadry, H. Alolaiyan, A. Razaq, ... & R. Irfan, "Time series forecasting of COVID-19 transmission in Asia Pacific countries using deep neural networks", *Personal and Ubiquitous Computing*, 25(1), 1-18, 2021.
- [18] S. Ballı, "Data analysis of COVID-19 pandemic and short-term cumulative case forecasting using machine learning time series methods", *Chaos, Solitons & Fractals*, 142(1), 1-7, 2021.

- [19] O. Seveli, V. G. B. GÜLSOY, "COVID-19 Salgınına Yönelik Zaman Serisi Verileri ile Prophet Model Kullanarak Makine Öğrenmesi Temelli Vaka Tahminlemesi", *Avrupa Bilim ve Teknoloji Dergisi*, (19), 827-835, 2020.
- [20] K. T. Ly, "A COVID-19 forecasting system using adaptive neuro-fuzzy inference", *Finance Research Letters*, 101844, 2020.
- [21] G. Pinter, I. Felde, A. Mosavi, P. Ghamisi, R. Gloaguen, "COVID-19 Pandemic Prediction for Hungary; a Hybrid Machine Learning Approach", *Mathematics*, 8(6), 890, 2020.
- [22] M. A. Al-Qaness, A. I. Saba, A. H. Elsheikh, M. AbdElaziz, R. A. Ibrahim, S. Lu, ... & A. A. Ewees, "Efficient artificial intelligence forecasting models for COVID-19 outbreak in Russia and Brazil", *Process Safety and Environmental Protection*, 149, 399-409, 2020.
- [23] S. Alile, K. Otokiti, "A CoronaVirus Disease-2019 Prediction Model Based on Bayesian Belief Network", *International Journal of Academic Engineering Research*, 4(4), 24-35, 2020.
- [24] H. T. Rauf, M. I. U. Lali, M. A. Khan, S. Kadry, H. Alolaiyan, A. Razaq, R. Irfan, Time series forecasting of COVID-19 transmission in Asia Pacific countries using deep neural networks", *Personal and Ubiquitous Computing*, 24(6), 1-18, 2020.
- [25] K. C. Ukaoha, O. Ademiluyi, J. Ndunagu, S. S. Daodu, F. Osang "Adaptive Neuro Fuzzy Inference System for Diagnosing Coronavirus Disease 2019 (COVID-19)", *International Journal of Intelligent Computing and Information Sciences*, 20(2), 1-31, 2020.
- [26] Internet: T.C. Sağlık Bakanlığı, <https://COVID19.saglik.gov.tr/TR-66935/genel-koronavirus-tablosu.html>, 04.01.2021.
- [27] Internet: Veri Bilimci, <https://veribilimcisi.com/2017/07/18/Ozellik-Olcekleme-Ve-Normallestirme-Nedir-Feature-Scaling-And-Normalization>, 10.01.2021.
- [28] F. R. Yıldırım, **Uçak Trim Performans Parametresinin Anfis ile Modellemesi**, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, 2020.
- [29] F. E. Dinç, **Otomotiv Satış Sonrası Hizmetleri için Eşzamanlı Sinirsel Bulanık Sistem Önerisi**, Doktora Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, 2012.
- [30] F. O. Hocaoglu, M. Kurban, "Adaptif ağ tabanlı bulanık mantık çıkarım sistemi ile Eskişehir bölgesi için güneşlenme süreleri tahmini", *Journal of Engineering Sciences and Design*, 6(3), 396-405, 2018.
- [31] M. Polatgil, "Anfis ve Bulanık K Ortalamalar İle Kalp Hastalığının Tespit edilmesi", *Bilişim Teknolojileri Dergisi*, 13(4), 443-449, 2020.
- [32] A. Ece, O. Ulucak, "Yapay Sinir Ağları Ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi İle Francis Tipi Türbinler İçin Verim Tahminlemesi", *Isı Bilimi Ve Tekniği Dergisi*, 40, 87-97, 2020.
- [33] M. A. Al-Qaness, H. Fan, A. A. Ewees, D. Yousri, M. AbdElaziz, "Improved ANFIS model for forecasting Wuhan City Air Quality and analysis COVID-19 lockdown impacts on air quality", *Environmental research*, 110607, 2020.
- [34] M. Yılmaz, **Asenkron Motorlarda Sıcaklık, Akım, Titreşim Verilerinin Analizi ve Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi Uygulaması**, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2008.
- [35] F. Sönmez Çakır, **Yapay Sinir Ağları Matlab Kodları Ve Matlab Toolbox Çözümleri**, Nobel Yayınevi, Ankara, 2018.
- [36] A. Ertaylan, Ö. Aktaş, Y. Doğan, "Yapay Sinir Ağları ile Piyasa Takas Fiyatı Tahminlemesi", *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(67), 93-105, 2021.
- [37] A. Ece, O. Ulucak, "Yapay Sinir Ağları Ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi İle Francis Tipi Türbinler İçin Verim Tahminlemesi", *Isı Bilimi ve Tekniği Dergisi*, 40, 87-97, 2020.
- [38] F. Çoban, L. Demir, "Yapay Sinir Ağları ve Destek Vektör Regresyonu ile Talep Tahmini: Gıda İşletmesinde Bir Uygulama", *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(67), 327-338, 2021.
- [39] Ö. Zeynep, M. Demirsöz, "Makine Öğrenmesi Yöntemleri İle COVID-19 Verilerinin İncelenmesi: Türkiye Örneği", *Sağlık Bilimlerinde Yapay Zeka Dergisi*, 1(2), 1-7, 2021.
- [40] E. Yunus, "Forecasting Models For Covid-19 Cases Of Turkey Using Artificial Neural Networks And Deep Learning", *Endüstri Mühendisliği*, 31(3), 353-372, 2020.
- [41] A. Mine, "Makine Öğrenmesi Algoritmaları İle COVID-19 Hastalarının Belirlenmesi", MS thesis, *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü*, 2021.
- [42] M. A. Al-Qaness, A. A. Ewees, H. Fan, M. Abd El Aziz, "Optimization method for forecasting confirmed cases of COVID-19 in China", *Journal of Clinical Medicine*, 9(3), 674, 2020.
- [43] S. Makridakis, M. Petropoulos, Forecasting The Novel Coronavirus COVID-19, *Plosone*, 15(3), 2020.
- [44] C. Zeynep. "Estimation of COVID-19 prevalence in Italy, Spain, and France", *Science of The Total Environment*, 729, 2020.
- [45] D. Fanelli, P. Francesco, "Analysis and forecast of COVID-19 spreading in China, Italy and France", *Chaos, Solitons & Fractals*, 134, 109761, 2020.