



Makine Öğrenmesi Yöntemleri ile Türkiye’de Covid-19’a İlişkin Günlük Vaka, Ağır Hasta, Vefat ve İyileşen Sayısı Tahmini

Figen Özen^{1,*}

¹Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Haliç Üniversitesi, İstanbul, Türkiye

Makale Tarihçesi

Gönderim: 10.01.2022
Kabul: 18.07.2022
Yayın: 15.12.2022

Araştırma Makalesi

Öz – Covid-19 içinde bulunduğumuz yüzyılın ilk pandemidir ve bundan önceki pandemilere kıyasla süresi, neden olduğu can kaybı, yarattığı psikolojik, sosyolojik ve ekonomik etkileri dolayısıyla farklılık göstermektedir. Bu süreçte virüs pek çok varyant üretmiştir ve üretmeye de devam etmektedir. Dünya üzerindeki hareketliliğin sıklığı ve miktarı düşünüldüğünde, bu durumun yakın gelecekte değişmesi mümkün gözükmemektedir. Pandeminin gidişatını anlamak, bundan sonraki olası pandemiler için hazırlıklı olmak konusunda faydalı olacaktır. Bu amaçla, T.C. Sağlık Bakanlığı tarafından yayınlanan günlük veri incelenmiş, farklı veri grupları üzerinde gerek özelliklerini anlama gerekse geleceğe yönelik tahmin gerçekleştirme amacıyla, güncel bir yaklaşım olan makine öğrenmesi yöntemleri kullanılmıştır. Kullanılan veri grupları oldukça karmaşık birer zaman serisi yapısındadır ve günlük vaka sayısı, ağır hasta sayısı, günlük vefat sayısı ve günlük iyileşen sayısı olarak seçilmiştir. Polinom regresyon, en küçük kareler polinom uyumu ve kübik eğri uyumu sonuçları ile tahminler bu makalede incelenmiştir. Sonuçlar gerek grafikler yoluyla gerekse zaman serisi tahmininde kabul görmüş bir performans kriteri olan Canberra uzaklığının ortalama, medyan, standart sapma ve toplam değerleriyle, sayısal olarak belirtilmiştir. Yukarıda belirtilen dört zaman serisi için en iyi sonuçların, kübik eğri uyumu yöntemiyle alındığı görülmektedir. Tahminlerde kullanılan eğrilerin dereceleri, zaman serisine göre değişiklik göstermektedir. Elde edilen tahmin sonuçları, zaman serisine bağlı olarak değişen yüksek doğruluk oranı sağlamıştır.

Anahtar Kelimeler – Covid-19, en küçük kareler polinom uyumu, kübik eğri uyumu, makine öğrenmesi, polinom regresyon

Estimation of Daily Cases, Deaths, Serious Patients and Recovering Patients of Covid-19 in Turkey with Machine Learning Methods

Department of Electrical and Electronics Engineering, Faculty of Engineering, Haliç University, İstanbul, Turkey

Article History

Received: 10.01.2022
Accepted: 18.07.2022
Published: 15.12.2022

Research Article

Abstract – Covid-19 is the first pandemic of the century and differs from previous pandemics due to its duration, loss of life, and psychological, sociological and economic effects. In this process, the virus has produced and continues to produce many variants. Considering the frequency and amount of mobility on Earth, this situation does not seem likely to change soon. Understanding the course of the pandemic will be helpful in being prepared for the next possible pandemics. To this end, the daily data published by the Turkish Ministry of Health was examined, and machine learning methods, which is an up-to-date approach, were used to understand the features and make predictions for the future on different data groups. The data groups used are in a very complex time series structure and were chosen as the number of daily cases, severe patients, deaths, and recoveries per day. The results of polynomial regression, least squares polynomial fit, and cubic spline fit, and estimations are shown in this article. The results are presented graphically, and by means of an accepted performance criterion in time series estimation, namely by the mean, median, standard deviation, and total values of the Canberra distance. It is seen that the best results for the time series mentioned above are obtained by the cubic spline fit method. The degrees of the curves used in the estimations vary according to the time series. The estimation results obtained provided a high accuracy rate that varies depending on the time series.

Keywords – Covid-19, cubic spline fit, least squares polynomial fit, machine learning, polynomial regression

¹  figenozen@halic.edu.tr

*Sorumlu Yazar

1. Giriş

Dünya Sağlık Örgütü tarafından açıklanan rakamlara göre, 29 Temmuz 2022 itibarıyla 572.239.451 doğrulanmış vaka ve 6.390.401 ölü sayısı ile, yirmi birinci yüzyılın şu ana dek en büyük pandemisi olan Covid-19, 2020 yılının ilk aylarından itibaren ülkemizde de etkili olmuştur. Dünya Sağlık Örgütü'nün istatistiklerinde 29 Temmuz 2022 tarihinde Türkiye için doğrulanmış vaka sayısı 15.524.071, vefat sayısı ise 99.184 olarak verilmiştir. Bu rakamlarla, Türkiye, vaka sayısı bakımından dünyada 10. sırada, vefat sayısı bakımından ise 19. sırada yer almaktadır. Türkiye'de her 100 kişiye düşen aşı dozu 25 Temmuz 2022 itibarıyla 177,3 olmuştur ve bu oranla, Türkiye ortalama aşı dozu bakımından 81. sıradadır. 25 Temmuz 2022 tarihine dek uygulanan toplam aşı dozu sayısı 12.248.795.623'tir. Dünya ortalaması 25 Temmuz 2022 tarihinde 157,15 olarak gerçekleşmiştir (World Health Organization, 2022). Tahminlere göre Covid-19 yayılımını ve ondan kaynaklanan ölümleri yakın bir tarihte durdurmak mümkün görünmemektedir.

Türkiye'de pandemi ile ilgili bilgiyi T.C. Sağlık Bakanlığı'nın web sitesinden takip etmek mümkündür. Bakanlığın verisi incelendiğinde, bütün veri çeşitlerinin aynı tarihte başlamadığı ve eşit sayıda bilgiye ulaşmanın mümkün olmadığı görülmektedir. Ayrıca, süreç boyunca Türkiye'de ve dünyada veri ilan standartlarının değişime uğradığı gözlenmektedir. Başlarda günlük verinin düzenli olarak yayınlandığı görülürken, süre uzadıkça, ayrıntılı olarak ilan edilen tabloların daha az veri çeşidi için düzenlendiği görülmektedir (T.C. Sağlık Bakanlığı, 2022).

Covid-19 salgınının başlamasından bu yana gerek zaman serisi bilgisinden yola çıkarak, gerekse görüntü işleme yöntemleriyle pandeminin geleceği hakkında çeşitli tahminler yürütülmeye çalışılmıştır. Bu çalışmanın konusu zaman serisi analizi ve tahmini olduğundan, aşağıda zaman serisi üzerine yapılan çalışmalara örnekler verilmiştir.

1.1. Covid-19 Zaman Serisi Konusunda Yapılan Çalışmalar

Gambhir, Jain, Gupta ve Tomer 154 günlük veriyle Hindistan'da hastalığın seyrini polinom regresyonu ile analiz ederek, 3 haftalık geleceği tahminde %93 başarı elde etmişlerdir (Gambhir vd., 2020). Mandayam, Rakhshith, Siddesha ve Niranjana John Hopkins Üniversitesi tarafından yayınlanan veriyle ve doğrusal regresyon ve destek vektör regresyonu ile tahmin yaptıklarında, doğrusal regresyonun daha iyi sonuç verdiği karar vermişlerdir. Bunun, verinin doğrusal yapısından kaynaklandığını belirtmişlerdir (Mandayam vd., 2020).

Kurniawan vd. Worldometers verisi ile 200 ülkeyi pandemilerinin benzerliği bazında kümelere ayırmışlardır (Kurniawan vd., 2020). Rustam vd. John Hopkins Üniversitesi tarafından yayınlanan veriyle, doğrusal regresyon, LASSO algoritması, destek vektör makineleri ve üstel yumuşatma yöntemlerini kullanarak, 10 gün içinde yeni vaka, vefat ve iyileşen sayılarını tahmin etmişlerdir. En iyi sonucun üstel yumuşatma algoritmasıyla elde edildiğini bildirmişlerdir (Rustam vd., 2020).

Ramchandani, Fan ve Mostafavi derin öğrenme yoluyla yaptıkları tahminde kullanılan özniteliklerin analizini yapmışlardır (Ramchandani vd., 2020). Yang ve Chen, ABD'de sınırlı sayıda eyaletin Twitter verisini kullanarak, ülkenin tamamındaki vaka sayısını regresyon modelleri ile tahmin etmeye çalışmışlardır (Yang ve Chen, 2020).

Singh ve Dalmia Hindistan için doğrusal regresyon ile vaka sayısı verildiğinde vefat sayısını tahmin etmişlerdir (Singh ve Dalmia, 2020). Bhadana, Jalal ve Pathak, Hindistan için sonraki 5 günde vaka, vefat ve iyileşen sayısını doğrusal regresyon, karar ağacı, LASSO, destek vektör makineleri ve rastgele orman algoritmaları ile hesaplamışlardır. Polinom regresyonunun en iyi sonucu verdiğini belirtmişlerdir (Bhadana vd., 2020).

Hazarika ve Gupta Brezilya, Hindistan, Peru, Rusya ve ABD verisini kullanarak, dalgacık bağlantılı rastgele vektör fonksiyonel bağlantı ağı ile Covid 19 yayılımı tahmin edilmiştir (Hazarika ve Gupta, 2020). Seveli ve Başer, John Hopkins Üniversitesi verisiyle ve Facebook Prophet modeliyle vaka, vefat ve iyileşen sayılarını tahmin etmişlerdir (Seveli ve Başer, 2020). Leon, Iqbal, Azim ve Mamun, Bangladeş verisini kullanarak polinom regresyon, destek vektör regresyonu, Holt Winter, ARIMA ve Facebook Prophet modelleriyle vaka ve vefat sayılarını tahmin etmişlerdir, En yakın sonucun Facebook Prophet modeliyle elde edildiğini belirtmişlerdir (Leon vd., 2021).

Kumari vd. Hindistan verisini kullanarak çoklu regresyon ve otoregresyon ile 30 gün sonrası için vaka, vefat ve iyileşen sayısını tahmin etmişlerdir (Kumari vd., 2021).

Gupta, Gupta, Kumar ve Sardana, Hindistan için rastgele orman, destek vektör makineleri, karar ağacı ve yapay sinir ağı modelleriyle vaka, vefat ve iyileşen sayısını tahmin etmişlerdir. En yakın sonuçları rastgele orman modeliyle aldıklarını belirtmişlerdir (Gupta vd., 2021). Yudistra, Sumitro, Nahas ve Riama Covid 19 yayılımına etki eden unsurları evrişimli uzun kısa süre bellekli model ile incelemişlerdir (Yudistira vd., 2021).

ArunKumar vd. pandemiden çokça etkilenen 16 ülkeyi seçerek 60 günlük vaka, vefat ve iyileşen sayısını ARIMA ve SARIMA modelleriyle tahmin etmişlerdir. SARIMA model tahminlerinin daha gerçekçi olduğunu belirtmişlerdir (ArunKumar vd., 2021). Kumar ve Susan, parçacık sürü optimizasyonu ve bulanık zaman serisi tahminini birleştirerek 10 ülke için vaka sayısı tahminini gerçekleştirmişlerdir (Kumar ve Susan, 2021).

Yukarıdaki çalışmalar, yapıldığı ülke için geçerlidir ve başarılıdır. Ancak her ülkenin pandemi yanıtı kendine özgü bir yapı göstermektedir. Bu nedenle, tek bir model oluşturup, her ülke için bir açıklama getirmek mümkün değildir. Türkiye'deki durumu inceleyen çalışmalara ilişkin örnekler arasında (Koçak, 2020), (Ergül, Yavuz, Aşık ve Kalay, 2020), (Taşdelen ve Yıldırım, 2020), (Akay ve Akay, 2021), (Karcioğlu vd., 2021) yer almaktadır. Koçak, çeşitli AR (otoregresif) modelleri kıyaslamış ve sonuçlarını 7 Nisan 2020 tarihinde varolan veri için belirtmiştir (Koçak, 2020). Ergül vd., 10 Nisan 2020 tarihine dek varolan veri ile Türkiye'deki pandemi seyrini 22 ülke ile karşılaştırmışlar ve en iyi zaman serisi modellemesini Box-Cox yöntemiyle elde ettiklerini ifade etmişlerdir (Ergül, Yavuz, Aşık ve Kalay, 2020). Taşdelen ve Yıldırım, ilk iki ayın verisini kullanarak Poisson regresyon yöntemiyle çalışmışlar ve bazı dönemlerde tahminlerin daha başarılı sonuçlar verdiğini belirtmişlerdir (Taşdelen ve Yıldırım, 2020). Akay ve Akay, 11 Mart-24 Ağustos 2020 aralığında ARIMA modeliyle çalışmışlar, iki haftalık tahmin modeli oluşturduklarını belirtmişlerdir (Akay ve Akay, 2021). Karcioğlu, Tanışman ve Bulut, günlük vaka ve vefat sayılarında ARIMA modelinin, günlük iyileşen sayılarında LSTM modelinin daha iyi sonuç verdiğini belirtmişlerdir (Karcioğlu vd., 2021).

Sözü geçen çalışmalarda kullanılan veri, pandemi hala sürmekte olduğundan, kısıtlıdır ve öte yandan pandemiye ilişkin zaman serisi, çeşitli toplumsal gelişmelerin de etkisiyle günden güne değişim göstermektedir. Dolayısıyla, daha güncel veriyle yapılan çalışmalara ihtiyaç bulunmaktadır.

Bu çalışma, Türkiye'deki Covid-19 salgınının seyrini, T.C. Sağlık Bakanlığı tarafından yayınlanan günlük veriyi baz alarak incelemek ve günlük vaka, ağır hasta, vefat ve iyileşen sayıları konusunda gidişatı tahmin etmek ve buna ek olarak veri karakteristiğini incelemek için yapılmıştır. Yukarıda belirtilen ve Türkiye verisi için gerçekleştirilen çalışmalardaki verinin zaman kısıtı nedeniyle, hem Covid-19 pandemisinin nasıl geliştiğine, hem de gelecekteki olası pandemilerin seyrinin nasıl olabileceğine dair bilgi ve fikir vermesi açısından böyle bir çalışmanın fayda sağlayacağı düşünülmektedir.

Yukarıda verilen örneklerde kullanılan yöntemlerin basit regresyon modellerinden başlayıp LSTM gibi daha karmaşık olanlarına dek geniş bir skalada bulunduğu görülmektedir. Bu çalışmada, Türkiye'ye ait pandemi verisini mümkün olduğunca basit ve açıklanabilir modellerle ifade etmek amacı güdülmüştür. Kullanılan yöntemler, makine öğrenmesi yöntemlerinden polinom regresyon, en küçük kareler polinom uyumu ve kübik eğri uyumudur. Bu yöntemler, karmaşık yapıdaki veriyi mümkün olduğunca basit ve bilgisayar yardımıyla hızlı bir şekilde ifade edebilmek ve bu konuda yapılan diğer çalışmalara bir alternatif sunmak için tercih edilmiştir. Daha karmaşık yöntemler kullanılarak elde edilen sonuçlarda açıklanabilirlik problemiyle karşılaşmaktadır. İkinci bölümde, çalışmada kullanılan yöntemler açıklanmaktadır.

2. Materyal ve Yöntem

Bu çalışma, Türkiye'de Covid-19 hastalığının seyrini izlemek için, T.C. Sağlık Bakanlığı tarafından yayınlanan veri baz alınarak gerçekleştirilmiştir (T.C. Sağlık Bakanlığı, 2022). Bu veriyi anlamlı bir şekilde ifade ve tahmin edebilmek amacıyla, çeşitli makine öğrenmesi yöntemleri kullanılmıştır. Kullanılan yöntemlerin geçerliliği gerek görsel gerekse sayısal yöntemlerle incelenmiş ve karşılaştırılmıştır.

Bu çalışmada incelenen veri kümelerinin gerçek ve tahmini değerlerini karşılaştırmak amacıyla, makine öğrenmesi yöntemleri simülasyon yoluyla uygulanmıştır ve çeşitli tahmin yöntemleri denenmiştir. Ancak gerek sayısal performans kriterleri gerekse görsel olarak, grafikler yardımıyla ulaşılan sonuçların incelenmesiyle, üç yöntemin daha anlamlı sonuç verdiği görülmüştür. Bunlar polinom regresyon, en küçük kareler polinom uyumu ve kübik eğri uyumudur.

Performansın değerlendirilmesi için bazı çalışmalarda yapıldığı gibi normalizasyona başvurulmamış ve gerçek ölçek üzerinden çalışılmıştır. Literatürde toplam sayıların tahminine yönelik çeşitli çalışmalar bulunmaktadır ancak toplam sayılar yüksek olduğu ve tanım gereği artış trendinde olduğu için buralarda yapılan makul seviyeli hatalar, sonuçta bir problem olarak görülmeyebilir. Öte yandan günlük verideki dalgalı ve değişken

yapı ile ilgili çalışma yapıldığında, daha küçük hatalarda bile performans düşüşü gözle görülür hale gelmektedir. Bu tür bir yaklaşım, daha gerçekçi bir sonuç doğurduğu için bu çalışmanın verisi günlük seçilmiştir.

İzleyen paragraflarda, polinom regresyon, en küçük kareler uyumu ve kübik eğri uyumu yöntemleri hakkında bilgi verilmekte, bir sonraki bölümde ise alınan sonuçlar detaylandırılmaktadır. Zaman serisi verisi için daha farklı yöntemler de kullanmak mümkündür, bu çalışma için doğrusal regresyon, Bayes regresyonu, sinüzoidal uyum fonksiyonları ile de çalışılmıştır, ancak Covid-19 veri seti için anlamlı sonuç üretmedikleri görülmüştür. Bu yaklaşımlardan olumlu sonuç alınmaması, verinin oldukça nonlineer yapıda olmasından ve sözü geçen uyum fonksiyonlarının bu tür nonlineer yapıları ifade etmekte zayıf kalmasından kaynaklanmaktadır.

2.1. Polinom Regresyon

Polinom regresyon metodu, veri noktalarını en iyi şekilde modelleyebilecek bir polinom ifadesi bulmayı amaçlar. Ancak, incelenen veri setine benzer durumlarda çözümün bulunması pek kolay değildir. Bunun nedeni, hem çok sayıda veri noktası kullanılması, hem de karakteristiğın zaman içinde, varyantlar, kapanmalar dolayısıyla kişiler arası temasın azalması, kontrollü normalleşme, aşuların sisteme dahil edilmesi gibi etkenler yüzünden sık sık dramatik değişikliklere uğramasıdır. Bu tür etkilerin yapıyı değiştirmedığı durumlarda, veri kümesi n noktadan oluşuyorsa, $n - 1$ dereceli bir polinomla bütün noktaları içeren bir ifadeye ulaşılabilir (Ertel, 2017). Ancak bu yaklaşım gereksiz karmaşıklıkta bir sonuç doğuracaktır. Bunun yerine, mümkün olduğunca düşük dereceli bir polinom kullanılmalıdır.

Genel olarak, polinom regresyon kullanılarak yapılan bir tahmin, Eşitlik 2.1'deki modelle ifade edilebilir:

$$\hat{y}(n) = w_0 + w_1x(n) + w_2x^2(n) + \dots + w_dx^d(n), \quad n = 1, 2, 3, \dots \quad (2.1)$$

Modelde $\{w_0, w_1, \dots, w_d\}$ olmak üzere, $d+1$ ağırlık parametresi kullanılmaktadır. Denklemden $x(n)$, n anındaki veriyi, $\hat{y}(n)$, n anındaki tahmin değerini, d ise kullanılan modelin derecesini simgelemektedir (Aggarwal, 2018). Veri noktası sayısından daha az dereceli bir polinom kullanıldığında, hata olması kaçınılmazdır. Dolayısıyla, gerçek değer $y(n)$ ile tahmin edilen değer $\hat{y}(n)$ arasında fark oluşur. Önemli olan, bunun kabul edilebilir sınırlar içinde tutulmasıdır.

Polinom regresyon uygulamalarında verinin üsleri kullanılmakta ve görünürde doğrusal olmayan bir yaklaşım izlenimi uyandırmaktadır. Ancak probleme hesaplanması gereken katsayılar açısından bakıldığında, polinom regresyonun doğrusal bir regresyon olduğu anlaşılmaktadır. Zaman serisi probleminin bu şekilde çözümü, doğrusal tahmin ile gerçek değer arasındaki karesel hatayı minimize eden bir çözümdür ve Eşitlik 2.2'de gösterilen ifadeyi küçültmeyi amaçlar:

$$\sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.2)$$

Burada y_i gerçek değeri, \hat{y}_i tahmin edilen değeri, N ise veri setindeki toplam veri sayısını simgelemektedir. Gerçekleştirilen minimizasyon işlemi, Eşitlik 2.1'deki ağırlıkları güncellemek içindir.

2.2. En Küçük Kareler Polinom Uyumu

Bu yöntem, Eşitlik 2.2'yi küçültmeyi amaçlar, ancak kullandığı yaklaşım Eşitlik 2.1'den farklıdır ve Eşitlik 2.3 ile ifade edilmektedir:

$$\hat{y}(n) = w_0x(n-d) + w_1x(n-d+1) + \dots + w_dx(n), \quad n = 1, 2, 3, \dots \quad (2.3)$$

Burada $x(n)$, n anındaki veriyi, $\hat{y}(n)$, n anındaki tahmin değerini, d ise kullanılan modelin derecesini simgelemektedir (Theodoridis ve Koutroumbas, 2009).

2.3. Kübik Eğri Uyumu

Bu yöntem, verilen noktaların aralarındaki ilişkileri üçüncü dereceden kübik eğriler kullanarak ifade etmeye yarar. Parçalı süreklilik içerir, veriyi çeşitli parçalara ayırarak inceler. Parçalara ilişkin sınır değerler düğüm noktaları adını alır ve kübik eğriler arasındaki geçişleri yumuşatmak için bu değerlerde ikinci türevler sıfıra eşitlenir. Modelin karmaşıklığı, kullanılan düğüm noktalarının sayısı ile artar. Eşitlik 2.4'te tahmin değerinin hesaplanması gösterilmektedir:

$$\hat{y}(n) = w_0 + w_1x(n) + w_2x^2(n) + w_3x^3(n) + w_4[x(n) - \alpha_1]_+^3 + w_5[x(n) - \alpha_2]_+^3 + \dots, n = 1, 2, \dots \quad (2.4)$$

Burada α_i , i. düğüm noktasını simgelemektedir (Harrell Jr., 2015). Eşitlik 2.4'te kullanılan notasyonun açıklaması Eşitlik 2.5'tedir:

$$[x(n) - \alpha_i]_+ = \begin{cases} x(n) - \alpha_i, & x(n) - \alpha_i > 0 \\ 0, & x(n) - \alpha_i \leq 0 \end{cases} \quad (2.5)$$

Eğer kullanılan düğüm sayısı m ise, $m + 4$ adet regresyon katsayısı hesaplanmalıdır. Ağırlık parametrelerini simgeleyen $\{w_0, w_1, \dots, w_d\}$ çeşitli optimizasyon yöntemleri kullanılarak hesaplanabilir. Düğüm noktalarının yerleri, incelenen eğrideki değişimlerle uyumlu olacak şekilde, optimizasyon algoritmalarıyla belirlenebilir. Ancak bu tür bir yaklaşım, anlık veriyi tahmine dahil etmek konusunda iyi bir yaklaşım değildir. Bu nedenle, daha sık kullanılan yöntem, belli sayıda düğüm noktası kullanmak şeklindedir.

2.4. Canberra Uzaklığı

Zaman serilerinin tahmininde başarıyı ölçmek için kullanılan bir yöntemdir. Öklid uzaklığının tekilliklere olan hassasiyetini yenmek için tercih edilmektedir (Zhao vd., 2021). Burada Covid-19 verisinde bulunan tekillikler dolayısıyla tercih edilmiştir. Canberra uzaklığı, gerçek veriye ne kadar yaklaşıldığını ölçmek için Eşitlik 2.6'daki hata kriterini kullanır:

$$e(n) = \frac{|y(n) - \hat{y}(n)|}{|y(n)| + |\hat{y}(n)|} \quad (2.6)$$

Burada $y(n)$, n anındaki gerçek değeri, $\hat{y}(n)$ ise tahmin edilen değeri simgelemektedir. Uzaklık formülü, yapısı gereği bir normalizasyon içermekte ve değerler 0 ve 1 arasında değişmektedir. Bu nedenle yorumlanması kolaydır. Canberra uzaklığının ortalamasını, standart sapmasını hesaplamak, tahminin başarısı hakkında bilgi verir. Canberra uzaklığı, çeşitli çalışmalarda kullanılmıştır (Al-wakeel, Wu ve Jenkins, 2017), (Saxena, Kaur ve Bhatnagar, 2019), (Badre ve Thepade, 2016), (Phiri vd., 2021).

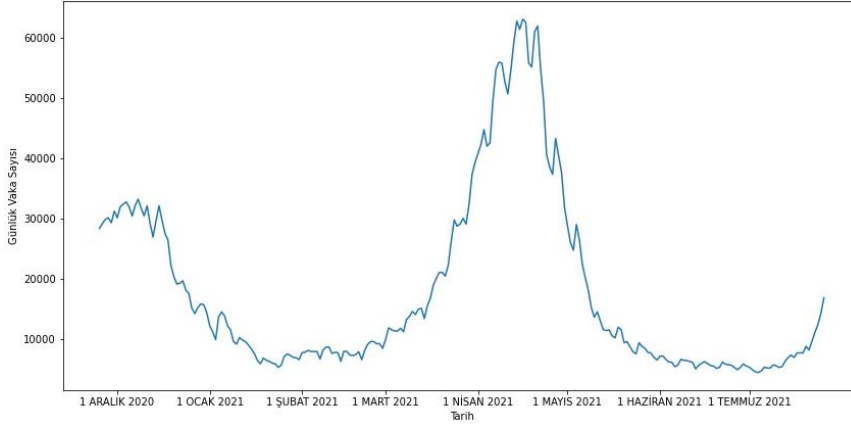
3. Bulgular ve Tartışma

Günlük vaka, ağır hasta, vefat ve iyileşen veri kümelerinin karakteristikleri birbirinden farklı olduğundan, ulaşılan sonuçların da spesifik veri kümesi koşullarında değerlendirmesi gerekmektedir. İncelenen zaman zarfında Covid-19 için alfa, beta ve delta varyantlarının etkilerini görmek mümkündür. Kullanılan verinin son zamanlarında en baskın olan varyantın delta olduğu bilinmektedir. Yayınlanan istatistik bilgileri her zaman bütün veriyi içermediğinden, farklı tarih aralıkları kullanmak gerekmiştir.

Bu bölümde yer alan ve tahmin içeren bütün grafiklerde kırmızı noktalar gerçek değerleri, mavi çizgiler ise tahmini değerlerin eğrisini temsil etmektedir.


3.1. Günlük Vaka Sayısı Bulguları

Gerçekleşen günlük vaka sayısı verisinin grafiği Şekil 1'de gösterilmiştir. Değerlerin geniş bir skalada oluştuğu ve 60.000 sınırının da ötesine geçebildiği gözlemlenmektedir. Günlük vaka verisi toplam 244 gün için değerlendirilmiştir. Burada hem zaman zaman uygulanan sokağa çıkma kısıtlamalarının, hem de verinin son dönemlerine denk gelen aşı uygulamalarının etkilerini gözlemlemek mümkündür.

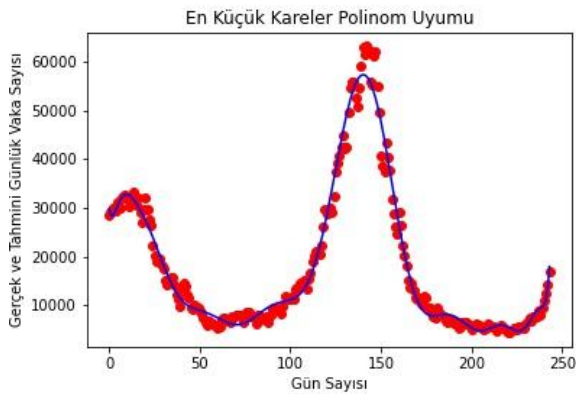


Şekil 1. Günlük vaka sayısı

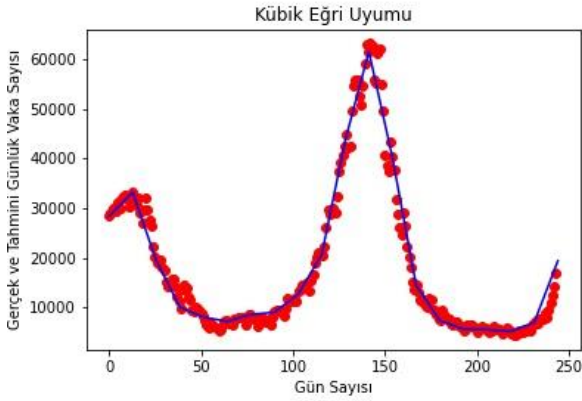
Günlük vaka sayısının tahmini değerlerine ulaşmak için kullanılan ilk yöntem polinom regresyondur. Elde edilen sonuç Şekil 2’de gösterilmiştir. Polinom regresyon için kullanılan derece 10’dur. Küçük değerler kullanıldığında son derece karmaşık bir karakteristiğe sahip olan eğriyi gerçekçi biçimde tahmin edebilmek mümkün değildir, çok yüksek değerler kullanıldığında ise benzer şekilde karakteristikten uzaklaşmaktadır. İkinci tahmin yöntemi olarak en küçük kareler polinom uyumu kullanılmıştır. Sonuçta elde edilen grafik, Şekil 3’te gösterilmiştir. Burada model derecesi 18 seçilmiştir ve polinom regresyon tahmininden daha iyi sonuç elde edilmiştir. En büyük farkın pik noktası civarında olduğu görülmektedir. Bunun yanında ani düşüşlerde de tahmin polinom regresyona göre daha isabetlidir. Tahmin için kullanılan son yöntem, kübik eğri uyumudur. Sonuç Şekil 4’te gösterilmiştir. 244 veriden oluşan küme, Eşitlik 2.4 ve 2.5’te belirtildiği biçimde, 20 eşit parçaya ayrılarak, her parça üzerinde üçüncü dereceden eğri kullanımıyla bir uyum oluşturulmaya çalışılmıştır. Sonucun hem pik hem de dip noktalar dahil, önceki iki tahminden daha iyi olduğu görülmektedir.



Şekil 2. Polinom regresyon ile günlük vaka tahmini



Şekil 3. En küçük kareler polinom uyumu ile tahmin



Şekil 4. Kübik eğri uyumu ile günlük vaka tahmini

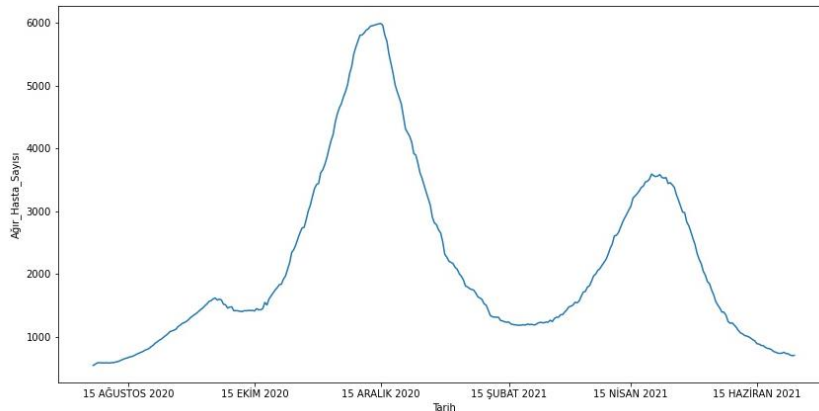
Yapılan tahmin çalışmalarını sayısal açıdan karşılaştırmak için Canberra uzaklığı kullanılmıştır. Tablo 1’de her üç yöntem için hesaplanan ortalama, medyan, toplam Canberra uzaklıkları ve standart sapma değerleri verilmiştir. Toplam uzaklık rakamı en düşük olan kübik eğri uyumu yaklaşımıdır ve bu durum, Şekil 4 ile görsel açıdan da desteklenmektedir.

Tablo 1
Günlük vaka tahmini sayısal performans karşılaştırması

Yöntem	Ortalama	Medyan	Standart Sapma	Toplam
Polinom regresyon	0.38	0.42	0.19	92.47
En küçük kareler polinom uyumu	0.05	0.04	0.04	12.69
Kübik eğri uyumu	0.41	0.47	0.23	8.25

3.2. Ağır Hasta Sayısı Bulguları


Gerçekleşen günlük ağır hasta sayısı verisinin grafiği Şekil 5’te gösterilmiştir. Değerlerin geniş bir skalada oluştuğu ve 6.000 sınırını zorladığı gözlemlenmektedir. Günlük ağır hasta verisi, toplam 340 gün için değerlendirilmiştir. Buradaki veri setinin vaka sayısına ilişkin veri setinden daha yumuşak bir yapısı olduğu gözlemlenmektedir.



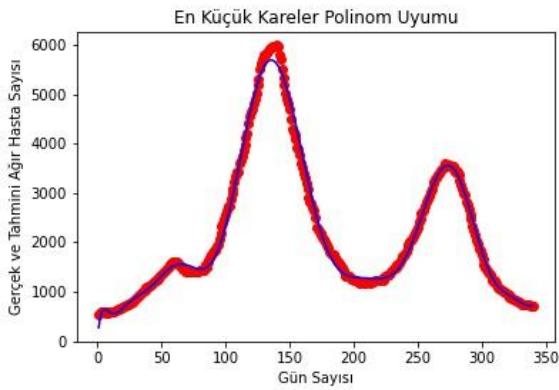
Şekil 5. Günlük ağır hasta sayısı

Polinom regresyon yöntemiyle tahminde ulaşılan sonuç Şekil 6’da gösterilmiştir. Kullanılan derece 8’dir. Şekil 1 ve 5 karşılaştırıldığında, ağır hasta sayısının daha yumuşak bir eğri çizdiği ve daha düşük derecele tahmin yapılabileceği görülmektedir. En küçük kareler polinom uyumu ile elde edilen grafik, Şekil 7’de gösterilmiştir.


Burada model derecesi, günlük vaka sayısının tahminine benzer şekilde, 18 seçilmiştir ve paralel biçimde, polinom regresyon tahmininden daha iyi sonuç elde edilmiştir. En büyük fark, iki pik noktasından daha yüksek olanı civarındadır, ani düşüşlerde tahmin daha isabetlidir. Kübik eğri uyumunun sonucu Şekil 8’de gösterilmiştir. 340 veriden oluşan küme 34 eşit parçaya ayrılarak, her parça üzerinde bir uyum oluşturmaya çalışılmıştır. Sonucun hem pik hem de dip noktalar dahil, önceki iki tahminden daha iyi olduğu görülmektedir.



Şekil 6. Polinom regresyon ile günlük ağır hasta tahmini



Şekil 7. En küçük kareler polinom uyumu ile tahmin



Şekil 8. Kübik eğri uyumu ile günlük ağır hasta tahmini

Ağır hasta tahmin çalışmalarını karşılaştırmak için, Canberra uzaklığı değerleri Tablo 2’de verilmiştir. Toplam uzaklık rakamı en düşük olan kübik eğri uyumu yaklaşımıdır.


Tablo 2

Ağır hasta tahmini sayısal performans karşılaştırması

Yöntem	Ortalama	Medyan	Standart Sapma	Toplam
Polinom regresyon	0.38	0.34	0.22	129.96
En küçük kareler polinom uyumu	0.02	0.02	0.02	7.53
Kübik eğri uyumu	0.01	0.01	0.01	0.45


3.3. Vefat Sayısı Bulguları

Gerçekleşen günlük vefat sayısı verisinin grafiği Şekil 9’da gösterilmiştir. Değerlerin en yüksek olduğu günlerde 400 sınırını zorladığı ve eğrinin düzensiz bir karakteristiğe sahip olduğu gözlemlenmektedir. Günlük vefat verisi, toplam 487 gün için değerlendirilmiştir.




Şekil 9. Günlük vefat sayısı


Polinom regresyon yöntemiyle tahminde ulaşılan sonuç Şekil 10’da gösterilmiştir. Kullanılan derece 15’dir. Gerçeğe yakın bir tahmin yapmak mümkün olmamıştır. Bunu karakteristiğinin aşırı değişkenliğine bağlamak mümkündür. En küçük kareler polinom uyumu ile elde edilen grafik, Şekil 11’de gösterilmiştir. Burada model derecesi, 17 seçilmiştir ve diğer çalışmalarla aynı şekilde, polinom regresyon tahmininden daha iyi sonuç elde edilmiştir. En büyük fark, iki en yüksek pik noktası civarındadır, ani düşüşlerde tahminde gecikme gözlenmektedir. Kübik eğri uyumunun sonucu Şekil 12’de gösterilmiştir. 487 veriden oluşan küme, 40 eşit parçaya ayrılarak, her parça üzerinde bir uyum oluşturmaya çalışılmıştır. Sonucun hem pik hem de dip noktalar dahil, önceki iki tahminden daha iyi olduğu görülmektedir, ayrıca gecikme sorunu ortadan kalkmıştır.



Şekil 10. Polinom regresyon ile günlük vefat tahmini



Şekil 11. En küçük kareler polinom uyumu ile tahmin



Şekil 12. Kübik eğri uyumu ile günlük vefat tahmini

Vefat tahmin çalışmalarını karşılaştırmak için, Canberra uzaklığı değerleri Tablo 3'te verilmiştir. Toplam uzaklık rakamı en düşük olan kübik eğri uyumu yaklaşımıdır ve bu durum, Şekil 12 ile uyum içindedir.


Tablo 3

Vefat tahmini sayısal performans karşılaştırması

Yöntem	Ortalama	Medyan	Standart Sapma	Toplam
Polinom regresyon	0.33	0.35	0.22	160.44
En küçük kareler polinom uyumu	0.07	0.06	0.06	35.55
Kübik eğri uyumu	0.31	0.25	0.22	12.27


3.4. İyileşen Sayısı Bulguları

Gerçekleşen günlük iyileşen sayısı verisinin grafiği Şekil 13'te gösterilmiştir. Değerlerin en yüksek olduğu günlerde 400 sınırını zorladığı ve eğrinin düzensiz bir karakteristiğe sahip olduğu gözlemlenmektedir. Günlük vefat verisi, toplam 479 gün için değerlendirilmiştir.




Şekil 13. Günlük iyileşen sayısı


Polinom regresyon yöntemiyle tahminde ulaşılan sonuç Şekil 14'te gösterilmiştir. Kullanılan derece 15'tir, ancak tıpkı vefat sayısında olduğu gibi, gerçeğe yakın bir tahmin yapmak mümkün olmamıştır. Bunu, benzer şekilde, karakteristiğın aşırı değişkenliğine bağlamak mümkündür. En küçük kareler polinom uyumu ile elde edilen grafik, Şekil 15'te gösterilmiştir. Burada model derecesi, ağır hasta tahmininde olduğu gibi, 17 seçilmiştir ve polinom regresyon tahmininden daha iyi sonuç elde edilmekle beraber, tatminkar olmaktan uzaktır. En büyük fark, pik noktaları civarındadır. Kübik eğri uyumunun sonucu Şekil 16'da gösterilmiştir. 479 veriden oluşan küme, 40 eşit parçaya ayrılarak, her parça üzerinde bir uyum oluşturmaya çalışılmıştır. Sonucun hem pik hem de dik noktalar dahil, önceki iki tahminden daha iyi olduğu görülmektedir.



Şekil 14. Polinom regresyon ile günlük iyileşen tahmini



Şekil 15. En küçük kareler polinom uyumu ile günlük iyileşen tahmini



Şekil 16. Kübik eğri uyumu ile günlük iyileşen tahmini

İyileşen tahmin çalışmalarını karşılaştırmak için, Canberra uzaklığı değerleri Tablo 4’te verilmiştir. Toplam uzaklık rakamı en düşük olan, kübik eğri uyumu yaklaşımıdır ve sonuç, Şekil 16 ile uyum içindedir.

Tablo 4

İyileşen tahmini sayısal performans karşılaştırması

Yöntem	Ortalama	Medyan	Standart Sapma	Toplam
Polinom regresyon	0.45	0.44	0.22	215.74
En küçük kareler polinom uyumu	0.20	0.16	0.17	96.27
Kübik eğri uyumu	0.39	0.33	0.28	15.79

İncelenen zaman serilerinin birbirinden farklı yapısı dolayısıyla kullanılan modellerin dereceleri farklılıklar göstermektedir. Parametreler, karşılaştırma için kolaylık sağlaması açısından Tablo 5’te toplu halde gösterilmiştir. Tabloda görülen parametreler, benzetim çalışmaları sırasında optimize edilerek kararlaştırılmıştır.

Tablo 5

Kullanılan modellerin dereceleri

Zaman Serisi	Veri sayısı	Yöntem	Model Derecesi
Vaka sayısı	244	Polinom regresyon	10
		En küçük kareler polinom uyumu	18
		Kübik eğri uyumu	20
Ağır hasta sayısı	340	Polinom regresyon	8
		En küçük kareler polinom uyumu	18
		Kübik eğri uyumu	34
Vefat sayısı	487	Polinom regresyon	15
		En küçük kareler polinom uyumu	17
		Kübik eğri uyumu	40
İyileşen sayısı	479	Polinom regresyon	15
		En küçük kareler polinom uyumu	17
		Kübik eğri uyumu	40

Bu çalışmada, Türkiye’de meydana gelen Covid-19 vakalarının karakteristik yapısı anlaşılmaya çalışılmıştır. Zaman serilerinin incelenmesiyle, zaman içerisinde yayılımın oldukça karmaşık bir yapıyı takip ettiği anlaşılmıştır. Hiç kuşkusuz, gerek varyantların çeşitliliği, gerekse alınan önlemlerin etkisi, karakteristiklerin karmaşık yapısına katkıda bulunmaktadır. Karantina uygulaması, nispeten başlarda gündeme gelmiştir. Maske kullanımı ilk vakanın görülmesinden bir süre sonra başlamıştır. Aşı uygulaması, bundan aylar sonra gündeme gelmiştir. Ayrıca zaman zaman gerçekleşen tam ve kısmen kapanmaların etkisi de söz konusudur. Dolayısıyla, çalışmaya konu olan karakteristikler, sadece basit birer zaman eğrisi olmaktan öte, çok yönlü tıbbi ve sosyal olguları da temsil etmektedir. Değerlendirme bu düşüncelerin ışığında yapılmalıdır. Elbette ki, etki eden unsurlar ayrıştırılmaz ve birbirini doğrusal olmayan biçimlerde etkileyen özelliktedir.

Günlük vaka, ağır hasta, vefat ve iyileşen karakteristikleri birbirine benzememektedir. Bunları, 1, 5, 9 ve 13 numaralı şekillerden görmek mümkündür. Çalışmada kullanılan yöntemlerden kübik eğri uyumunun en iyi sonuçları verdiği görülmüştür. Bu çalışma veri karakteristikleri ile ilgili olarak gerçekleştirilmiştir, ancak karakteristiklere etki eden maske kullanımının zorunlu hale gelmesi, sokağa çıkma kısıtlamaları gibi unsurlar birer parametreye dönüştürülmemiştir. Bu konuların Ergül vd.’nin çalışmasında olduğu gibi (Ergül vd., 2020) ayrıca incelenmesi gerekmektedir.

4. Sonuçlar

Bu çalışmada, Türkiye’de Covid-19 vakalarının karakteristik yapısı anlaşılmaya çalışılmıştır. T.C. Sağlık Bakanlığı tarafından yayınlanan günlük veri ışığında günlük vaka, ağır hasta, vefat ve iyileşen sayılarının veri karakteristiği incelenmiş, polinom regresyon, en küçük kareler polinom uyumu ve kübik eğri uyumu yöntemleri ile tahmin yapılmıştır. En iyi sonuç, uyum esnekliği ve verideki değişimleri takip etmeye yönelik olarak daha fazla sayıda parametre kullanması, dolayısıyla daha fazla serbesti derecesine sahip olması sebebiyle kübik eğri uyumu yaklaşımıyla elde edilmiştir. Canberra uzaklığının bu çalışmada anlamlı olup olmadığını saptayabilmek amacıyla, görsel olarak performansın yakın olduğu izlenimini yaratan günlük ağır hasta sayısına ilişkin ortalama mutlak yüzde hata hesaplanmıştır. Bu değer, en küçük kareler polinom uyumu için %4.37, kübik eğri uyumu için ise %2.20 olmuştur. Dolayısıyla ağır hasta günlük verisi için en iyi sonucun %97.8 başarı oranıyla kübik eğri uyumu tarafından elde edildiği sonucuna varılmıştır. Bu kıyaslama, Canberra uzaklığı hesaplarıyla uyum içindedir. Bundan sonraki çalışmada, bu çalışmaya konu olan dönemde gerçekleşen farklı sosyal olguların zaman serilerine etkileri incelenmeye çalışılacaktır. Bu şekilde daha az hata içeren tahminler yapılabilir. Bu yaklaşımda, hesaplama zamanının artacağı göz önünde bulundurulmalıdır. Sonuçta, benzer uygulamalarda harcanan çaba ve programın çalışması için gereken zamanın da elde edilen doğruluğa ek olarak, birer kritere dönüştüğü bilinmektedir. Ayrıca bir sonraki aşamada, başka ülkelerden örnekler seçilerek karşılaştırmalar yapılması hedeflenmektedir.

Yazar Katkıları

Figen Özen: Araştırmayı yapmış, veriyi ayıklamış, gerekli analizi, programların yazılmasını, değerlendirmelerin yapılmasını ve makalenin yazılmasını gerçekleştirmiştir.

Çıkar Çatışması

Yazar çıkar çatışması bildirmemiştir.

Kaynaklar

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Springer.
- Akay, S. ve Akay, H. (2021). Time series model for forecasting the number of COVID-19 cases in Turkey. *Turkish Journal of Public Health*, 19(2), 140–145. doi:https://doi.org/10.20518/tjph.809201
- Al-wakeel, A., Wu, J. ve Jenkins, N. (2017). k -means based load estimation of domestic smart meter measurements. *Applied Energy*, 194, 333–342. Doi:https://doi.org/10.1016/j.apenergy.2016.06.046
- ArunKumar, K. E., Kalaga, D. V., Sai Kumar, C. M., Chilkoor, G., Kawaji, M. ve Brenza, T. M. (2021). Forecasting the dynamics of cumulative COVID-19 cases (confirmed, recovered and deaths) for top-16 countries using statistical machine learning models: Auto-Regressive Integrated Moving Average (ARIMA) and Seasonal Auto-Regressive Integrated Moving Averag. *Applied Soft Computing*,

- 103(December 2019), 107161. doi: <https://doi.org/10.1016/j.asoc.2021.107161>
- Badre, S. R. ve Thepade, S. D. (2016). Novel video content summarization using Thepade's sorted n-ary block truncation coding. *Procedia - Procedia Computer Science*, 79, 474–482. doi: <https://doi.org/10.1016/j.procs.2016.03.061>
- Bhadana, V., Jalal, A. S. ve Pathak, P. (2020). A comparative study of machine learning models for Covid-19 prediction in India. *IEEE 4th Conference on Information & Communication Technology (CICT)*. doi: <https://doi.org/10.1109/CICT51604.2020.9312112>
- Ergül, B., Yavuz, A. A., Aşık, E. G. ve Kalay, B. (2020). Dünya'da ve Türkiye'de Nisan ayı itibariyle COVID-19 salgın verilerinin istatistiksel değerlendirilmesi. *Anadolu Kliniği Tıp Bilimleri Dergisi*, 25(1), 130–141. doi: <https://doi.org/10.21673/adoloklin.719629>
- Ertel, W. (2017). *Introduction to artificial intelligence* (2nd ed.). Springer.
- Gambhir, E., Jain, R., Gupta, A. ve Tomer, U. (2020). Regression analysis of COVID-19 using machine learning algorithms. *2020 International Conference on Smart Electronics and Communication, Icosec*, 65–71. doi: <https://doi.org/10.1109/ICOSEC49089.2020.9215356>
- Gupta, V. K., Gupta, A., Kumar, D. ve Sardana, A. (2021). Prediction of COVID-19 confirmed, death, and cured cases in India using random forest model. *Big Data Mining and Analytics*, 4(2), 116–123. doi: <https://doi.org/10.26599/BDMA.2020.9020016>
- Harrell Jr., F. E. (2015). *Regression modeling strategies* (2nd ed.). Springer.
- Hazarika, B. B. ve Gupta, D. (2020). Modelling and forecasting of COVID-19 spread using wavelet-coupled random vector functional link networks. *Applied Soft Computing Journal*, 96, 106626. doi: <https://doi.org/10.1016/j.asoc.2020.106626>
- Karcıoğlu, A. A., Tanışman, S. ve Bulut, H. (2021). Türkiye'de COVID-19 bulaşısının ARIMA modeli ve LSTM Ağı Kullanılarak zaman serisi tahmini. 32, 288–297. doi: <https://doi.org/10.31590/ejosat.1039394>
- Koçak, M. (2020). A comparison of time-series models in predicting COVID-19 cases. *Türkiye Klinikleri Biyoistatistik Dergisi*, 12(1), 89–96. Doi: <https://doi.org/10.5336/biostatic.2020-75402>
- Kumar, N. ve Susan, S. (2021). Particle swarm optimization of partitions and fuzzy order for fuzzy time series forecasting of COVID-19. *Applied Soft Computing*, 110, 107611. doi: <https://doi.org/10.1016/j.asoc.2021.107611>
- Kumar, S., Rup, S. ve Swamy, M. N. S. (2021). An improved scheme for multifeature-based foreground detection using challenging conditions. *Digital Signal Processing*, 113, 103030. doi: <https://doi.org/10.1016/j.dsp.2021.103030>
- Kumari, R., Kumar, S., Poonia, R. C., Singh, V., Raja, L., Bhatnagar, V. ve Agarwal, P. (2021). Analysis and predictions of spread, recovery, and death caused by COVID-19 in India. *Big Data Mining and Analytics*, 4(2), 65–75. doi: <https://doi.org/10.26599/BDMA.2020.9020013>
- Kurniawan, R., Abdullah, S. N. H. S., Lestari, F., Nazri, M. Z. A., Mujahidin, A. ve Adnan, N. (2020). Clustering and correlation methods for predicting coronavirus COVID-19 risk analysis in pandemic countries. *2020 8th International Conference on Cyber and IT Service Management, CITSM 2020*. doi: <https://doi.org/10.1109/CITSM50537.2020.9268920>
- Leon, M. I., Iqbal, M. I., Azim, S. M. ve Al Mamun, K. A. (2021). Predicting COVID-19 infections and deaths in Bangladesh using machine learning algorithms. *2021 International Conference on Information and Communication Technology for Sustainable Development, ICICT4SD 2021 - Proceedings*, 70–75. doi: <https://doi.org/10.1109/ICICT4SD50815.2021.9396820>
- Mandayam, A. U., Rakshith, A. C., Siddesha, S. ve Niranjan, S. K. (2020). Prediction of Covid-19 pandemic based on Regression. *Proceedings - 2020 5th International Conference on Research in Computational Intelligence and Communication Networks, ICRCICN 2020*, 1–5. doi: <https://doi.org/10.1109/ICRCICN50933.2020.9296175>
- Phiri, C. C., Valle, C., Botzheim, J., Ju, Z. ve Liu, H. (2021). Fuzzy rule-based model for outlier detection in a topical negative pressure wound therapy device. *ISA Transactions*, 117, 16–27. doi: <https://doi.org/10.1016/j.isatra.2021.01.046>
- Ramchandani, A., Fan, C. ve Mostafavi, A. (2020). DeepCOVIDNet: An interpretable deep learning model for predictive surveillance of COVID-19 using heterogeneous features and their interactions. *IEEE Access*, 8, 159915–159930. doi: <https://doi.org/10.1109/ACCESS.2020.3019989>
- Rustam, F., Reshi, A. A., Mehmood, A., Ullah, S., On, B. W., Aslam, W. ve Choi, G. S. (2020). COVID-19 future forecasting using supervised machine learning models. *IEEE Access*, 8, 101489–101499.

- doi:<https://doi.org/10.1109/ACCESS.2020.2997311>
- Saxena, R., Kaur, S. ve Bhatnagar, V. (2019). Identifying similar networks using structural hierarchy. *Physica A*, 536, 121029. doi: <https://doi.org/10.1016/j.physa.2019.04.265>
- Sevli, O. ve Başer, V. G. (2020). Covid- 19 salgınına yönelik zaman serisi verileri ile Prophet model kullanarak makine öğrenmesi temelli vaka tahminlemesi. *European Journal of Science and Technology*. 19, 827–835. Erişim Linki:<https://dergipark.org.tr/en/pub/ejosat/issue/54511/766623>
- Singh, M. ve Dalmia, S. (2020). Prediction of number of fatalities due to Covid-19 using Machine Learning. *2020 IEEE 17th India Council International Conference, INDICON 2020*. doi:<https://doi.org/10.1109/INDICON49873.2020.9342390>
- T.C. Sağlık Bakanlığı. (2022). *Covid 19*. Erişim Linki:<https://covid19.saglik.gov.tr/TR-66935/genel-koronavirus-tablosu.html>
- Taşdelen, B. ve Yıldırım, D. D. (2020). Türkiye ' de COVID - 19 Vaka Sayılarının Poisson Regresyon ile Tahmini ve Alınan Önlemlerin İnsidans Hızı Tahminlerine Etkisi. *Türkiye Klinikleri Biyoistatistik Dergisi*, 12(3), 293–302. doi: <https://doi.org/10.5336/biostatic.2020-77595>
- Theodoridis, S. ve Koutroumbas, K. (2009). *Pattern Recognition* (4th Ed). Academic Press, Elsevier.
- Vakula Rani, J. ve Jakka, A. (2020). Forecasting COVID-19 cases in India using machine learning models. *Proceedings of the International Conference on Smart Technologies in Computing, Electrical and Electronics, ICSTCEE 2020*, 466–471. doi: <https://doi.org/10.1109/ICSTCEE49637.2020.9276852>
- World Health Organization. (2022). *Data Table*. <https://covid19.who.int/>
- Yang, Z. ve Chen, K. (2020). Machine Learning Methods on COVID-19 Situation Prediction. *Proceedings - 2020 International Conference on Artificial Intelligence and Computer Engineering, ICAICE 2020*, 78–83. doi: <https://doi.org/10.1109/ICAICE51518.2020.00021>
- Yudistira, N., Sumitro, S. B., Nahas, A. ve Riama, N. F. (2021). Learning where to look for COVID-19 growth: Multivariate analysis of COVID-19 cases over time using explainable convolution–LSTM. *Applied Soft Computing*, 109, 107469. doi: <https://doi.org/10.1016/j.asoc.2021.107469>
- Zhao, F., Gao, Y., Li, X., An, Z., Ge, S. ve Zhang, C. (2021). A similarity measurement for time series and its application to the stock market. *Expert Systems With Applications*, 182(November 2020), 115217. doi: <https://doi.org/10.1016/j.eswa.2021.115217>