

Derleme Makale

Bulaşıcı Hastalıkların Öngörü Modelleri: Bir Derleme Çalışması¹

Forecasting Models of Infectious diseases: A Review Study

Yeliz ZOĞAL Ankara Hacı Bayram Veli Üniversitesi Lisansüstü Eğitim Fakültesi Ekonometri Bölümü y.zogal@gmail.com https://orcid.org/0000-0002-8940-3337	Atilla GÖKÇE Prof. Dr., Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü atilla.gokce@hbv.edu.tr https://orcid.org/0000-0001-8287-4278
---	---

Makale Geliş Tarihi	Makale Kabul Tarihi
04.01.2023	03.03.2023

Öz

Aralık 2019'da Çin'in Wuhan şehrinde başlayan Covid-19 salgını, dünya genelinde hızla yayılmıştır. Ülkelerin sağlık sistemlerinin ve ilgili kurumlarının hazırlıksız yakalanması, süreci belirli bir süre için içinden çıkılamaz bir hale sokmuştur. Bu durum bilimsel alanlardaki faaliyetleri de etkilemiş ve farklı alanlardaki araştırmacıları bulaşıcı hastalıkların öngörü tahminlemesine yönelik modelleme çalışmalarına sebebiyet vermiştir. Öngörü içeren bu bilimsel yayınlar, çoğunlukla tıp ve doğa bilimleri dergilerinden temin edilmiştir. Bu çalışma, literatürde 2000 ile 2022 yılları arasında yer alan çoğunlukla Covid-19 çalışmalarını kapsayan ve buna ek olarak diğer salgın hastalıkların tahmin çalışmalarını da içerecek şekilde oluşturulmuştur. Genel olarak, tahmin modelleri SIR model grubu, lojistik model grubu, zaman serisi analizleri ve makine öğrenimi şeklinde dört ana grup içerisinde toplanmaktadır. Bu dört gruba ek olarak, her birinin kendi içerisinde alt kategorileri bulunmaktadır. Bu çalışma ayrıca yayılım mekanizmasının tahmininde sık kullanılan modelleri açıklayarak, çalışmalar hakkında teorik bilgi sunmayı amaçlamaktadır. SIR model grubu bulaşıcı hastalıkların özelliklerine göre şekillenebilmekte, lojistik modeller bulaşıcı hastalıkların veri yapıları ile benzerlik göstermekte, zaman serisi analizi değişkenin gecikmeli değerlerini kullanmakta ve Prophet modeli trend, mevsimsel ve tatil günlerini modele eklemektedir. Sonuç olarak, bu modellerin güçlü ve zayıf yanları özelliklerine göre tespit edilmiştir.

Anahtar Kelimeler: Covid-19, SIR model, Lojistik Model, Prophet Model, Öngörü

Abstract

The Covid-19 outbreak, which started in Wuhan, China, in December 2019, has spread rapidly worldwide. The unpreparedness of countries' health systems and relevant institutions made the process unmanageable for a certain period. This situation has also affected the activities in scientific fields and has led researchers in different fields to modelling studies for the prediction of infectious diseases. These scientific publications containing predictions were mainly obtained from medical and natural science journals. This study was created to cover mostly Covid-19 studies in the literature, and also included other epidemic prediction studies between 2000 and 2022.

¹ Bu makale, Ankara HBVÜ Lisansüstü Eğitim Enstitüsü Ekonometri doktora programında Prof. Dr. Atilla GÖKÇE'nin danışmanlığında hazırlanan "Bulaşıcı Hastalıkların Öngörü Modellemesi: COVID-19 Çalışması" adlı doktora tezinden yararlanılarak yazılmıştır.

Önerilen Atıf/Suggested Citation

Zoğal, Y. & Gökçe A., 2023 Bulaşıcı Hastalıkların Öngörü Modelleri: Bir Derleme Çalışması, *Üçüncü Sektör Sosyal Ekonomi Dergisi*, 58(1), 388-412

Forecasting models are categorised into four groups: SIR model group, logistic model group, time series analysis and machine learning. In addition to these four groups, each has its sub-categories. It also aims to provide information about the studies by describing the models commonly used to estimate the propagation mechanism. SIR model group can be shaped according to infectious diseases, logistic models are similar to data structures of infectious diseases, time series analysis uses lagged values of the variable and Prophet model adds trend, seasonal and holidays to the model. As a result, the strengths and weaknesses of these models are identified according to their characteristics.

Keywords: Covid-19, SIR model, Logistics model, Prophet Model, Forecasting

1. Giriş

Aralık 2019'da Dünya Sağlık Örgütü (DSÖ), Çin'in Hubei eyaletinin Wuhan şehrinde yeni bir koronavirüs olan Şiddetli Akut Solunum Sendromu ile ilişkili koronavirüs 2'nin (Covid-19) hızla yayılmaya başladığını ve virüsün diğer birçok ülkeye de hızla yayılmasının beklendiğini bildirmiştir. 13 Ocak 2020 tarihinde Çin'in dışında ilk defa Tayland'da Covid-19 vakası kayıtlara alınmıştır. Daha sonra, 20 Ocak 2020'de Güney Kore'de, 21 Ocak 2020'de Amerika Birleşik Devletleri'nde, 25 Ocak 2022'de de Avustralya ve Fransa'da ilk vakalar görülmeye başlanmıştır. Bu durum virüsün artık kıtalar arası sızdığının göstermiştir. Bir ay gibi kısa bir süre içerisinde (30 Ocak 2020) Dünya Sağlık Örgütü tarafından uluslararası kamu sağlığı acil durumu ilan edilmiştir (Bag ve Sade, 2020).

Ülkelerin salgına hazırlıksız yakalanması, başta sağlık sektörü olmak üzere birçok alanı derinden etkilemiş ve bu sebeple salgının yayılım mekanizmasının anlaşılması önemli hale gelmiştir. Literatürde salgınların tahmini için kullanılan modeller yapıları göre farklılıklar göstermektedir. Ancak, günümüzde Covid-19 tahminlemesi birçok farklı alan araştırmacısı tarafından farklı modellerle de ele alınmaktadır. Örneğin, SIR modeli pek çok araştırmacı tarafından ele alınan, hastalık yayılımı için kullanılan matematiksel bir modeldir. SIR, "Susceptible" (duyarlı), "Infected" (enfekte) ve "Recovered" (iyileşmiş) kelimelerinin baş harflerinin birleşiminden oluşur. Bu modele göre bir toplumda insanlar ya sağlıklı, enfekte olmuş ya da iyileşmiş kişilerden biri olarak sınıflandırılır. SIR modeli, epidemiyoloji ve halk sağlığı alanlarında önemli bir araçtır ve özellikle COVID-19 pandemisi sırasında sıkça kullanılmıştır. SIR modelinin yanı sıra, sıklıkla kullanılan bir diğer model grubu lojistik modeller grubudur. Birbirlerinden türetilen bu modellerin temelinde lojistik büyüme modeli yer almaktadır. Lojistik büyüme modeli, bir nüfusun belirli bir kaynak (bizim makalemizde virüsün yayılımı) için sınırlı bir kapasiteye sahip olduğu ve bu kaynağın tükenmeden önce nüfusun artış hızının yavaşlayacağı varsayımına dayanan bir istatistiksel modeldir. Model, yavaşlayan büyümenin doğal bir sonucu olarak ortaya çıkan sınırlı kaynaklara dayanmaktadır. Lojistik modelden türetilen bir diğer model Genelleştirilmiş Lojistik (Büyüme) Modelidir (GLM) ve lojistik modelin doğrusal olmayan doğasına uygun olarak daha fazla esneklik sağlayan daha geniş bir denklem formuna sahiptir. Bu nedenle, GLM, lojistik modelden daha geniş bir sınıfta değişkenlerin etkisini modeller ve daha fazla esneklik sağlar. Lojistik büyüme modelinde türetilen bir diğer model ise Richards Modelidir. Richards (Büyüme) Modeli, biyolojik ve ekonomik sistemlerin büyüme ve yayılma süreçlerini matematiksel/istatistiksel olarak modellenmesinde kullanılan sigmoid fonksiyonlarını içeren bir parametrik modeldir. Model, genellikle bir organizmanın büyümesi, bir popülasyonun artışı veya bir hastalığın yayılması gibi süreçleri açıklamak için kullanılır. Salgın hastalıkların öngörü tahminlemesinde sıklıkla kullanılan bir diğer modelde ARIMA modelidir. ARIMA (Autoregressive Integrated Moving Average) modeli, zaman serilerindeki trend, dönemsel ve rasgele değişimleri yakalamak ve gelecekteki değerleri tahmin etmek için kullanılan bir modeldir. Prophet modeli ise, Facebook tarafından geliştirilmiş açık kaynaklı bir zaman serisi tahmin modelidir. Bu model, genellikle mevsimsel trendlere ve tatil etkilerine sahip günlük, haftalık veya aylık zaman serileri için kullanılır. Prophet modeli, trendlere, mevsimsel değişimlere ve tatil etkilerine otomatik olarak uyum sağlayabilen bir esneklik sağlar. Araştırmalarda fazlaca öngörü modeli kullanılmasına rağmen çalışmalarda sıklıkla kullanılan bu modellerin veri uyumu, sonuçları farklılık göstermektedir. Bu çalışmanın amacı, Covid-19 başta olmak üzere, bulaşıcı hastalıkların tahmin modellerine yönelik bazı önemli bilimsel yayınları gözden geçirerek, sık tercih edilen tahmin modellerini güçlü ve zayıf yönlerini kapsayacak şekilde açıklayarak, sistematik bir analiz sunmaktadır.


Çalışmanın bundan sonraki kısmında, incelenen bilimsel yayınlar hakkında bilgiler verilerek sınıflandırılacaktır. Üçüncü bölümde ise, yayınlarda sık kullanılan modeller açıklanarak, diğer

modellerle ilişkileri incelenecektir. Çalışmanın sonucunda, modellerin güçlü ve zayıf yanları tartışılacak, gelecekte konu hakkında çalışma yapan araştırmacılara öneriler sunulacaktır.

2. Sınıflandırma


Bu çalışmada, 2000 – 2020 yılları arasında bazı bulaşıcı hastalıklar (Dang Humması, Ebola, Ailevi Akdeniz Ateşi, Domuz Gribi, Hepatit C, Kızamık, Veba, Çiçek Hastalığı, Sarı Humma, Grip, Zika Virüsü, AIDS, Kolera, SARS, Şap Hastalığı) ile ilgili yayınlar, 2020 – 2022 yılları arasında ise Covid - 19 ile ilgili yayınlar kullanılmıştır. Yayınlar, Google Scholar ve Pubmed veri tabanlarındaki önde gelen multidisipliner, tıp, doğa bilimleri, mühendislik ve istatistik dergilerinde aranmıştır. İngilizce makale başlıklarında “covid-19” ve “pandemic” kelimeleri; anahtar kelimeler bölümünde ise “forecasting model” kelime öbeği taranmıştır.

Çalışmalar büyük çoğunluğu yayınlanmış (ön onaylı) makalelerden oluşmaktadır. Ancak bunun yanı sıra çalışma, kitap incelemesi, ön (yayınlanmamış) makale ve konferans bildirileri ile çeşitlendirilmiştir. Yıllara göre verilen detaylar grafik 1’de gösterilmektedir.




Grafik 1: Çalışmaların Yıllara Göre Özellikleri

İncelenen yayınlarda kısa, uzun ve kısa-uzun dönem vaka öngörü tahminleri sağlanmış ve ağırlıklı kısa dönem öngörü tahminleri ele alınmıştır. Bunun sebebi, kısa dönem öngörülerini ele alan yayınların hükümetlerin alacağı önlemler, önlemlerin sıklığı ve/veya katılığı hakkında bilgi vermesidir. Bunun dışında kısa-uzun dönem vaka öngörü tahminleri kullanan çalışmaları ise, kısa dönemde elde edilebilecek sonuçlarla beraber, salgının tahminen ne zaman biteceği veya salgına ait dalga'nın başlarında iken ne zaman zirve yapacağı konusunda bilgi vermesidir. Yayınlarda kullanılan günlük ve kümülatif veriler Dünya Sağlık Örgütü, Johns Hopkins Üniversitesi ve öngörüsü sağlanacak ülkelerin sağlık kuruluşlarına ait kaynaklardan elde edilmiştir. Elde edilen öngörülerle hazırlanan yayınlar çoğunlukla tıp alanında yayın yapan dergilerde yayınlanmış olup grafik 2’de gösterilmektedir. Burada multidisipliner olarak ele alınan kısım ise diğer başlıklarla benzer şekilde doğa bilimleri, istatistik, matematik, mühendislik ve tıp alanlarının en az ikisi ile ilgili yayın yapan dergileri kapsamaktadır.



Grafik 2: Bilimsel Yayın Alanları

Salgın hastalık öngörü modelleri matematiksel modeller, istatistiksel modeller, zaman serisi analizleri ve makine öğrenimi modelleri şeklinde dört ana kategoride toplanmaktadır (Şekil 1). Salgın hastalıkların modellenmesinde SIR (matematiksel) modeli literatürde pek çok kez kullanılmıştır. Bu model, bulaşıcı hastalığın özelliklerine ve hastalığa karşı alınan önlem-tedavilere göre farklılaştırılabilmektedir. Lojistik fonksiyonundan elde edilen Genelleştirilmiş Lojistik, Richards, Tsouloris & Wallace, Gompertz ve Blumberg modelleri ise istatistiksel modellere örneklerdir. Bu modeller bulaşıcı hastalığa ait verilerinden büyüme eğrileri oluşturularak tahmin sağlayan ve özellikle erken dönem tahminlerde kullanılan modellerdir. Zaman serisi analizlerine, ARIMA modeli, Markov Zinciri ve Gri Model örnek olarak gösterilebilir. ARIMA modeli, öngörüye ait tahminleri salgın hastalığa ait değişkenin gecikmeli değerleri ile sağlayan bir modeldir. Son olarak, makine öğrenimi modelleri günümüzde yaygın olarak kullanılmaktadır. Covid-19 tahmininde en sık kullanılan makine öğrenimi modeli, Prophet modelidir. Bunun yanı sıra Random Forest, LSTM, RNN kullanılan diğer makine öğrenimi öngörü modelleridir.



Şekil 1: Tahmin Modelleri

3. Ana Araştırma Modelleri

Şekil 1’de sunulan salgın hastalık tahmin modellerinden önde gelen dört ana model grubu (SIR, Lojistik, Genelleştirilmiş Lojistik, Richards, ARIMA ve Prophet modelleri) incelenmiştir.

SIR Modeli

SIR modeli, epidemiyoloji ve halk sağlığı gibi alanlarda kullanılan en temel modellerden biridir ve hastalık yayılımını anlamak ve kontrol altına almak için kullanılmaktadır. SIR modelinde, N sayıda bireyin olduğu toplumlarda bireyler t zamanında üç ana gruptan birinde yer almaktadır.

$$S(t) + I(t) + R(t) = N \quad 1$$

Duyarlı (S - Susceptible), hastalığa henüz yakalanmamış ancak yakalanma ihtimali olan sağlıklı kişileri; enfekte (I – Infected), hastalığa yakalanmış ve yakalanma ihtimali olan kişileri de enfekte edebilen kişileri; iyileşmiş (R – Recovered) hastalığa yakalanmış ve bağışıklık kazanarak iyileşmiş kişileri göstermektedir.

$$s(t) = \frac{S}{N} \quad \frac{dS}{dt} = -\beta I S \quad 2$$

$$i(t) = \frac{I}{N} \quad \frac{dI}{dt} = \beta I S - \gamma I \quad 3$$

$$r(t) = \frac{R}{N} \quad \frac{dR}{dt} = \gamma I \quad 4$$

$$R_0 = \frac{\beta}{\gamma} \quad 5$$

Burada, β hastalığı bulaştırma oranı, γ ortalama iyileşme hızı, R_0 ise hastalığın artış (ivme) oranıdır. SIR modeli ile tahminleme sağlandığında eğer $\beta \geq \gamma$ ise, R_0 artacak ve salgın hastalığın ülke genelinde durumu kötüye gittiği; $\beta \leq \gamma$ ise, salgının ülke genelinde kontrol altına alınmaya başlandığı anlaşılmaktadır.

Modelin bazı varsayımları şu şekildedir:

- Toplam nüfus sabit sayılmaktadır. Doğum, ölüm (Covid-19 hariç) ve göç gibi değişkenlerin etkisi göz ardı edilmektedir.
- Enfekte olduktan sonra iyileşen bireylerin virüse karşı tam bağışıklık kazandığı kabul edilmektedir.
- Virüsün kuluçka süresinin olmadığı, bireyin enfekte olur olmaz hastalandığı ve başka bireyleri de enfekte edebilir hale geldiği kabul edilmektedir.
- Bulaşıcı hastalığa sebep olan virüsün ömrü sınırlı kabul edilmektedir.

SIR modeli, popülasyonun enfekte olabilen, enfekte olan ve kurtulan alt gruplarından oluşan temel bir epidemiyolojik modeldir. SIR modelinin geniş bir uygulama yelpazesi vardır ve çeşitli değişikliklerle birçok varyasyonu geliştirilmiştir. Bunlardan bazıları SIRD, SEIR, SEIRD, MSIR vb. gibi modellerdir. Örneğin, SIRD modeli, enfekte olabilen, enfekte olan, kurtulan ve ölen alt gruplarını içeren bir SIR modeli iken, SEIR modeli, enfeksiyonun gizli veya kuluçka dönemi alt grubunu da ekleyerek genişletilmiş bir SIR modelidir. Bu çeşitlilik, SIR modelinin geniş bir uygulama yelpazesine sahip olduğunu ve farklı koşullar altında farklı varyasyonların daha uygun olabileceğini göstermektedir.

SIR modeli literatürde birçok araştırmacı tarafından kullanılmaktadır. Örneğin, (Andrews ve Basu, 2011) çalışmasında SIR modelini kolera salgınının tahmini için kullanılmış ve o dönem için vaka sayılarında artış beklendiğini açıklanmıştır.

SIR modelinin en önemli özelliği, bulaşıcı hastalıkların fiziksel özelliklerine, hükümetlerce alınan önlem, tedavi ve aşı özelliklerine göre farklılaştırabilmesidir. Bu bir nevi ele alınan varsayımların esnetilmesidir. Örneğin, bulaşıcı hastalığın sadece iyileşme ile değil, ölümle de sonuçlanabildiği durumlar için, SIRD modeli geliştirilmiştir. Bu model, (Caccavo 2020) çalışmasında kullanılmış olup, İtalya’daki salgının, Çin’e göre daha ağır gittiğini, aynı şekilde ölüm tahmin sonuçlarının daha ağır olduğunu göstermiştir. Bulaşıcı hastalığın tahmininde toplumun sadece iki bölümden oluştuğunu varsayan SI ve SIS modelleri (Satsuma, Willox, Ramani, Grammaticos ve Carstea, 2004) çalışmasında

teorik olarak açıklanmıştır. Virüse maruz kalanların denkleme eklendiği SEIR modeli (Lekone ve Finkenstädt, 2006) çalışmasında ebola için, (Yang, Wang, 2020) ve (Şahinbaş ve Çatak, 2021) çalışmalarında ise Covid-19 tahmini için kullanılmıştır. Çalışmalar modelin parametreler (hükümetler tarafından alınan önlemler vb.) eklenerek geliştirilmesi gerektiği sonucuna ulaşmıştır. (Hethcote, 2000) çalışmasında, SIR, SEIR, SEIS modellerinin yanı sıra, geçici bağışıklığa sahip yeni doğan bebeklerin dahil edildiği MSEIR modelini teorik çerçevede incelemiştir. Benzer şekilde (Brauer, 2006) çalışmasında SI, SIN, SEIN, SAIN, SAQIJR, SVIN modelleri ile tedavi ve aşı süreçlerinin dahil edildiği SIR modellerini ele almıştır.

Çalışmaların ortak sonucu olarak, bulaşıcı hastalıkların tahminlemesinde SIR modelleri, hastalığın fiziksel özelliklerine göre ne kadar özelleştirilirse o kadar gerçekçi tahmin verdiği; veri sayısı yani hastalığın zaman içerisindeki seyrine ilişkin bilgisi ne kadar çok olursa modelin o kadar gerçekçi ve ileriye dönük tahminler sağladığı görülmektedir.

SIR modeli tahminlemelerinde, modelin bulaşıcı hastalığa uyarlanması konusunda büyük avantaj sağlasa da kendi içerisinde güçsüz yanları da bulunmaktadır. (Ioannidis, Cripps ve Tanner, 2022) çalışmasında yanlış modelleme, yanlış ve gerçeğe uyumsuz varsayımlar, tahmincilerin yüksek hassasiyetli olması, henüz yapısı tam belirlenmeyen salgın hastalığın ayırt edici özelliklerinin modellere dahil edilememesi, belirleyici parametre eksikliği ve raporlama hatalarının gerçekten uzak tahminlemelere sebep olduğunu göstermektedir.

Lojistik (Büyüme) Modeli

Lojistik model, ilk olarak 1845 yılında Belçikalı matematikçi Pierre-Francois Verhulst tarafından geliştirilmiştir. Verhulst-Pearl lojistik büyüme modeli olarak da bilinen lojistik fonksiyon, 1838 ve 1847 yılları arasında tanıtılmıştır. Verhulst bu fonksiyonu, nüfus artışını daha iyi modellemek için üstel büyüme modelinin bir modifikasyonu olarak geliştirmiştir. İlk olarak 1830'ların ortalarında fonksiyon hakkında kısa bir not yayınlamış, ardından 1844'te genişletilmiş bir analiz yayınlamış ve fonksiyona bu adı vermiştir. Üçüncü makale, Belçika nüfus artışı modelindeki düzeltme terimini ayarlanmıştır. Lojistik büyüme modeli, biyolojik popülasyonların yanı sıra ekonomi, finans ve diğer alanlarda da kullanılmaktadır. Model, bir değişkenin (genellikle nüfus) artış hızının başlangıçta hızlanarak başladığını, ancak zamanla artış oranının yavaşladığını öngörür. Bu yavaşlama, kaynakların tükenmesine veya kaynaklara erişimdeki kısıtlamalara bağlı olabilir. Model, bir S-curve (S eğrisi) olarak bilinen şekle benzer bir eğri çizer ve maksimum kapasiteye ulaşıldığında büyümenin duracağı veya geriye döneceği bir denge noktası belirler.

$$\frac{dC}{dt} = rC \left(1 - \frac{C}{K}\right) \quad 6$$

Eşitlikte; $C(t)$ toplam vaka sayısını, r büyüme oranını veya popülasyonun içsel büyüme hızını, K , taşıma kapasitesini göstermektedir. Yani, modelin yapısı gereği, büyüme, zaman içerisinde doygunluk seviyesine ulaşacak ve olaya ait toplam rakam artık daha fazla artmayacaktır. Bu modelin çözümü denklem 7'de gösterilebilir.

$$C(t) = \frac{KC_0}{(K-C_0)e^{-rt}-C_0} \quad 7$$

Burada, C_0 başlangıç zamanındaki vaka sayısı, yani popülasyon büyüklüğüdür. Büyüme oranı $r > 0$ olması halinde vaka sayıları tam kapasiteye kadar artacağını ifade etmektedir. Aksi durumda, yani $r < 0$ iken, büyüme hızının azaldığı anlaşılmaktadır. Yavaşlayan büyüme hızı sifıra yaklaşabilir ancak hiçbir zaman sifıra eşit olmamaktadır. Modelin iki özelliği aşağıda verilmiştir.

- Popülasyon eninde sonunda tam kapasiteye ulaşacaktır. Bu varsayım, bu modelden sonra aktarılabilecek olan Genelleştirilmiş Büyüme ve Richards Modeli için de geçerlidir.

$$\lim_{t \rightarrow \infty} C(t) = K \quad 8$$

- Büyüme hızının maksimum olduğu nokta, tam kapasitenin bükülme noktası olan $K/2$ noktasıdır.

(Batista, 2020), (Shen, 2020) ve (Miranda ve Devezas 2022) çalışmalarında farklı ülkeler için lojistik modeli ile Covid-19 vaka sayılarını tahminlemiştir. Yine aynı şekilde (Balak, Inan, Ganau, Zoia, Sonmez, Kurt, Akgül ve Tez, 2021) çalışmasında 1 Temmuz 2020 itibariyle dünya genelinde en yüksek vaka sayısına sahip yirmi ülkenin kısa ve uzun dönemlik öngörü tahminleri bu model ile elde edilmiştir.

Lojistik model tahminleri, (Almeshal, Almazrouee, Alenizi ve Alhajeri, 2020) çalışmasında Kuveyt'e ait Covid-19 verileri için SIR modeli ile, (Zhou, Ma, Hong, Su, Ma, He, Jiang, Liu, Shan, Zhu, Zhang ve Long, 2020) çalışmasında SEIR, düzeltilmiş SEIR modelleri ile karşılaştırılarak, tahminler elde edilmiştir. Düzeltilmiş SEIR modelinin görece daha iyi sonuçlar sağlandığı aktarılmıştır. (Husniah ve Supriatna, 2021) çalışmasında lojistik model ve Morgan, Mercer ve Flodin modeli (lojistik model ailesinden) Covid-19 tahmini sağlamıştır. Vakaların kümülatif artış şeklinin modellerle uyuşmasından ötürü, sonuçların gerçeğe yakın doğrulukta olduğu belirtilmiştir.

Genelleştirilmiş Lojistik (Büyüme) Modeli

Genelleştirilmiş lojistik büyüme modeli ilk defa Nelder tarafından 1961 yılındaki çalışmasında geliştirilmiştir (Nelder, JA 1961). Model, lojistik modelin geliştirilmiş hali olarak oluşturulmuştur. Genelleştirilmiş lojistik büyüme modeli (GLM), lojistik büyüme modeline benzer bir matematiksel modeldir. GLM, bir fenomenin belirli bir davranışını matematiksel olarak tanımlamak için kullanılır ve verilerin zaman içindeki değişimini açıklamak için kullanılabilir.

$$\frac{dC}{dt} = rC^{\alpha} \left(1 - \left(\frac{C}{K}\right)^{\beta}\right)^{\gamma} \quad 9$$

Modelde, α , β ve γ üstsel parametreleri eklenmiştir. Modelin bükülme (point of inflection) noktasındaki popülasyon $\left(1 + \beta\gamma/\alpha\right)^{-1/\beta}$, dır. Bu noktadaki maksimum büyüme hızı ise şu şekildedir.

$$\left(\frac{dK}{dt}\right)_{max} = rK^{\alpha} \left(\frac{\alpha}{\alpha+\beta\gamma}\right)^{\alpha/\beta} \left(\frac{\beta\gamma}{\alpha+\beta\gamma}\right)^{\gamma} \quad 10$$

GLM, lojistik büyüme modeline benzer şekilde bir sigmoid şeklindeki eğriyi takip eder ve sınırlı büyümeyi öngörür. Ancak, GLM, birkaç değişkeni ve bunların etkileşimlerini hesaba katarak daha fazla esneklik sağlar. GLM, verilerin modellenmesinde kullanılan birçok farklı teknik içerir. Genellikle, GLM, maksimum olabilirlik tahmini yöntemi ile parametrelerin tahmin edilmesiyle kullanılır. Ancak, diğer tahmin yöntemleri de kullanılabilir.

Richards Büyüme Modeli

Richards, (Ludwig) von Bertalanffy tarafından ele alınan bitki büyüme hızını modelleyen denklemini geliştirerek adını taşıyan Richards ve Gompertz modelini geliştirilmiştir (Richards, 1959). Richards Büyüme Modeli, sigmoid fonksiyonunu kullanarak veri setindeki büyüme oranını açıklayan bir doğrusal olmayan regresyon modelidir. Richards büyüme modeli, istatistiksel olarak tanımlanmış bir modeldir ve verilerin sigmoidal (S şeklinde) bir eğriye sahip olduğu durumlarda kullanılır. Bu model, lojistik büyüme modelinin genişletilmiş halidir. Richards modeli, genişletilmiş lojistik modeline benzer şekilde, sigmoid bir eğri kullanır ve üç parametre ile tanımlanır: maksimum büyüme hızı, doyumluk noktası ve büyüme başlangıç noktası. Bu üç parametre, Richards modelinin kullanıldığı farklı sistemlerde farklı isimlerle anılabilir. Örneğin, popülasyon büyümesi durumunda, maksimum büyüme hızı doğal büyüme oranı, doyumluk noktası taşıma kapasitesi ve büyüme başlangıç noktası ise başlangıç popülasyonudur.

$$\frac{dC}{dt} = rC \left(1 - \left(\frac{C}{K}\right)^{\beta}\right) \quad 11$$

Modelde, lojistik modelden farklı olan β üstel parametre eklenmiş olup genelleştirilmiş lojistik modele göre $\alpha = \gamma = 1$ durumudur. Modele ait çözüm aşağıdaki gibidir.

$$C(t) = \frac{KC_0}{\left[N_0^{\beta} + (K^{\beta} - N_0^{\beta})e^{-\beta rt}\right]^{1/\beta}} \quad 12$$

Modelde bükülme noktası, $\left(1/1 + \beta\right)^{\frac{1}{\beta}}$ ve modelin maksimum büyüme oranı $rK\beta / (1 + \beta)^{1+(1+\beta)}$ ’dır.

Bu model, diğer büyüme modellerinden farklı olarak asimptotik davranışlarını kontrol etmek için birden fazla parametre kullanır. Bu sayede, modellerin verileri daha iyi uydurması ve tahmin yapması beklenir.

(Lee, Lei, ve Mallick, 2020) ve (Nuraini, Khairudin, ve Apri, 2020) çalışmasında Richards modeliyle, (Zreiq, Kamel, Boubaker, Al-Shammary, Algahtani ve Alshammari, 2020) çalışmasında Genelleştirilmiş Richards Modelini Suudi Arabistan verileriyle ve (Aviv-Sharon ve Aharoni, 2020) çalışmasında Genelleştirilmiş Lojistik ve Richards Modeliyle Covid-19 öngörü tahminleri elde edilmiştir. (Chowell, Palacio, Ospina, Pell, Tariq, Dahal, Moghadas, Smirnova, Simenson ve Viboud, 2016) çalışmasında zika virüsü tahmini için Genelleştirilmiş Richards Modeli kullanılmıştır.

Tıpkı SIR modeller grubundaki gibi, lojistik model grubunda da üstsel katsayılarla farklı modeller oluşturulmuştur. Genelleştirilmiş Richards, Blumberg, Tsoularis & Wallace ve Gompertz Modelleri bunlardan bazılarıdır. (Darti, Habibah, Astutik, Kusumawinahyu, Marsudi, Suryanto, 2021), (Roosa, Lee, Luo, Kirpich, Rothenber, Hyman, Yan ve Chowell, 2020), (Wu, Darcet, Wang ve Sornette, 2020), (Abusam, Abusam, ve Al-Anzi, 2020), (Roosa, Tariq, Yan, Hyman ve Chowell, 2020), (Chowell 2017), (Bürger, Chowell ve Lara-Diaz, 2019), (Pell, Kuang, Viboud ve Chowell, 2016), (Chowell, Tariq, ve Hyman, 2019), (Chowell, Luo, Sun, Roosa, Tariq ve Viboud, 2020), (Medina-Mendieta, Cortés-Cortés ve Cortés-Iglesias, 2020), (Simpson, Browning, Warne, Maclaren ve Baker, 2022) çalışmalarında, birden fazla lojistik model grubunu tahminleme için kullanmıştır. Çalışmalara ait detaylar Ek Tablo 1’de verilmiştir.

Çalışmalarda, lojistik (büyüme) modelinden elde edilen bazı başka modeller de bulunmaktadır. Gompertz, Morgan, Mercer ve Flodin (MMF), Blumberg, Tsoularis-Wallace, Von Bertalanffy vb.dir. Gompertz modeli, bir fenomenin (genellikle hastalık veya ölüm oranları) zamanla nasıl değiştiğini modellemek için kullanılan bir modeldir. Bu model, 1825 yılında Benjamin Gompertz tarafından insan ölüm oranlarını modellemek için geliştirilmiştir ve daha sonra biyolojik ve tıbbi alanlarda geniş bir kullanım alanı bulmuştur. Gompertz modeli, aşırı yaşlanma teorisine dayanır ve bir kişinin ölüm riskinin yaşla birlikte arttığını öngörür. Matematiksel olarak, Gompertz modeli, ölüm oranının yaşa göre üstel bir şekilde arttığını ifade eder. Bu modele göre, ölüm oranı sabit bir hızda artmaz, bunun yerine yaş arttıkça artan bir hızda artar. Morgan, Mercer ve Flodin (MMF) modeli, salgınların yayılımını modellemek için birinci ve ikinci türevli Gompertz fonksiyonlarına dayanır. Salgının başlangıcından itibaren belirli bir süre geçtikten sonra, enfekte olan birey sayısındaki artış hızı azalır ve daha yavaş bir şekilde artar. Bu nedenle, MMF modeli, salgın başlangıcındaki hızlı artışı ve daha sonra yavaşlama eğilimini yakalamak için tasarlanmıştır. Blumberg modeli, ilk olarak 1974 yılında Robert L. Blumberg tarafından geliştirilmiştir. Model, bireyler arasındaki temasın ve enfeksiyon riskinin zamanla nasıl değiştiğini gösterir ve bağımsız değişkenler olarak enfekte olan kişilerin sayısı, bağışıklık kazanan kişilerin sayısı ve savunmasız kişilerin sayısı gibi faktörleri kullanır. Bu faktörlere dayanarak, model bir enfeksiyonun yayılma hızını ve nihai boyutunu tahmin etmek için kullanılır. Tsoularis-Wallace modeli, literatürde zaman serilerinin düzeltilmesinde sıklıkla kullanılan bir yöntemdir. Bu model, bir dizi veri içindeki dalgalanmaları ele alarak trendleri belirlemeye yardımcı olan ARIMA (Otomatik Regresyonlu Entegre Hareketli Ortalama) modellerini kapsamaktadır. Tsoularis-Wallace modeli, ARIMA modelleri üzerinde optimize edilmiş bir puanlama kriteri kullanarak en uygun parametreleri seçer ve daha doğru tahminler sağlamaya çalışır. Bu yöntem, özellikle ekonomik veriler gibi karmaşık zaman serileri analizinde kullanışlıdır.

Çalışmalarda lojistik grubu modelleri, bulaşıcı hastalıkların erken dönemlerinde görece daha az veri ile ortaya çıkardığı tahminlerle daha gerçekçi bir sunuş sergilemektedir. Modeller, kendi içlerinde verinin yapısına göre daha iyi veya daha kötü tahmin sonuçları verdiğinden birbirleri arasında sadece ele alınan veri için karşılaştırılmalıdır.

ARIMA

Box ve Jenkins (1976) tarafından geliştirilen ARIMA modeli, içerisinde otoregresif (AR) ve hareketli ortalama (MA) modellerini barındıran ve zaman serisi tahmin modelleri içerisinde en çok bilinen ve kullanılan doğrusal bir modeldir (Box ve Jenkins, 1976). ARIMA modeli, verinin geçmiş değerlerine

bağlı olarak gelecek değerlerine ilişkin öngörü sağlayan bir modeldir. $ARIMA(p, d, q)$ olarak gösterilen süreç aşağıdaki gibidir.

$$z_t = \mu + \alpha_t + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad 13$$

Burada, p modelin otoregresif bileşenin derecesini, q modelin hareketli ortalama bileşenin derecesini, d ise zaman serisi verilerinin durağan hale getirmek için gereken fark alma sayısını ifade etmektedir. Modelde kullanılacak verinin durağan olması beklenmektedir ve durağan bir veri $E(Y_t) = \mu$, $var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$ ve $\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$ olan beyaz gürültü (white noise) sürecine sahip bir seridir. Ayrıca model, mevsimlik etkileri yakalayabilen SARIMA modeli olarak dönüştürülebilir. "S" harfi, mevsimsel bileşeni temsil eder ve genellikle aylık, haftalık veya günlük veriler için kullanılır. SARIMA, gelecekteki değerleri tahmin etmek veya geçmiş verilere uydurmak için kullanılır ve özellikle zaman serilerindeki mevsimsel desenleri modellemek için uygundur.

Çalışmalarda, zaman serisi öngörü analizi olarak Markov Zinciri, geçmiş durumların gelecekteki durumları tahmin etmek için kullanılabileceği bir olasılık modelleme tekniğidir. Bir Markov zinciri, sonraki durumun yalnızca mevcut durumla ilgili olduğu bir dizi durum kümesinden oluşur. Bu, bir durumdan diğerine geçişlerin önceki durumlardan bağımsız olduğu anlamına gelir. Gri model ise, gri sistem teorisi olarak da bilinen bir zaman serisi analiz yöntemidir. 1982 yılında Çinli bilim adamı DJ Deng tarafından geliştirilmiştir. Verileri düşük miktarda gürültü içeren durumlarda etkili olabilen bir modeldir. Gri model, sınırlı veri kümeleri ile uğraşmak için özellikle yararlıdır ve büyük veri kümeleri kullanılarak yapılan analizlere kıyasla daha az veri gerektirir.

ARIMA modeli, bulaşıcı hastalıklara ait verilerin öngörülmesinde sıklıkla kullanılmaktadır. (Ceylan, 2020), (Liu, Liu, Jiang ve Yang, 2011), (He ve Tao, 2018), (Benvenuto, Giovanetti, Vassallo, Angeletti ve Ciccozzi, 2020), (Earnest, Chen, Ng ve Sin, 2005), (Deb ve Majumdar, 2020), (Akhtar ve Rozi, 2009), (Schaffer, Dobbins, ve Pearson, 2021), (Oshinubi, Rachdi, ve Demongeot, 2021), (Demongeot, Oshinubi, Rachdi, Hobbad, Alahiane, Iggu, Gaudart, Ouassou, 2022), (Bayyurt ve Bayyurt, 2020) çalışmaları ARIMA modelini kullanarak bulaşıcı hastalıkların öngörü sonuçları elde etmişlerdir. Çalışmalara ait detaylar Ek Tablo 1’de verilmiştir.

ARIMA modeli, (Perez, Chinarro, Otin, Martin, Diaz ve Mouhaffel, 2020) çalışmasında Gompertz Model ile, (Abuhasel, Khadr, ve Alquraish, 2022) çalışmasında SIR modeli ile, (Anirudh, 2020) çalışmasında SIR, SEIR, SIRD ve diğer kompartman modeller ile karşılaştırılarak kullanılmıştır.

ARIMA modelleri, verinin zamana bağlı davranışına göre tahminleme sağlamaktadır. Bu sebeple, durağan olmayan gözlemlerdeki aşırı değişiklikler modeli daha kararsız hale getirebilir.

Prophet (Peygamber) Modeli

Prophet modeli, Facebook tarafından 2018 yılında geliştirilen bir makine öğrenimi modelidir. Model, üç farklı bileşenden oluşmaktadır.

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad 14$$

Burada $y(t)$ vaka sayılarını, $g(t)$ trendi, yani zaman serisinin periodik olmayan değişikliklerini yakalayan trend fonksiyonunu, $s(t)$ mevsimsellik, yani zaman serisinin periyodik değişiklikleri yakaladığı kısmı ve $h(t)$ düzensiz aralıklarla meydana gelen tatil günlerini (bulaşıcı hastalık için kapanma dönemleri düşünülebilir, çünkü bu dönemdeki önlemler verilere yansıtacaktır) temsil edildiği kısmı ve ε_t model tarafından karşılanamayan veya ele alamadığı kendine özgü değişiklikleri içeren hata terimini ifade etmektedir (Taylor ve Letham, 2018, sf. 39). Modelde ele alınan fonksiyonlar şu şekildedir:

$$g(t) = \frac{C}{1 + \exp(-k(t-m))} \quad 15$$

Facebook’daki büyümenin doğal ekosistemdeki artışa (tıpkı vaka artışları gibi) benzemesinden ötürü, lojistik büyüme modeli eklenerek trenddeki artış yakalanmaya çalışılmıştır. Burada C taşıma kapasitesini, k büyüme oranını, m dengeleyici parametreyi (offset parameter) temsil etmektedir.

$$s(t) = \sum_{n=1}^{\infty} a_n \cos \frac{2n\pi t}{p} + b_n \sin \frac{2n\pi t}{p} \quad 16$$

Zaman serileri, temsil ettikleri insan davranışlarının sonucu olarak genellikle çok dönemli mevsimselliğe açıktır. Bu beş günlük bir çalışma haftası da olabilir, tatil programları veya her yıl takip eden okul tatilleri de olabilir (Taylor ve Letham, 2018, sf. 41). Yani, Prophet, uzun vadeli trendleri, haftalık ve yıllık sezonluk desenleri, tatil dönemlerini ve diğer etkileri modeller. Bu nedenle, genellikle çok iyi tahmin performansı sergiler. Bu periyodik etkileri yakalayabilmek için Fourier modeli kullanılmıştır. Burada p , zaman serisinin düzenli olarak sahip olması beklenen periyodik dönemdir.

$$h(t) = Z(t)\kappa \quad 17$$

$$Z(t) = [i(t \in D_1), \dots, i(t \in D_i)] \quad 18$$

Yılbaşı tatilleri, dini anlamda önemli günler veya ülke çapında etki yaratabilecek olaylar, zaman serisi modelleri için öngörülebilir şoklardır. Bu sebeple bu tür tatillerin model üzerindeki etkisi günlük bazda eklenmiştir. Modelde her bir i tatili için D_i tanımlanmıştır. Böylece o zaman serisi aralığı bu döneme denk gelmesi halinde, o tatilin varlığı temsil etmektedir. κ , parametresi ise, o tatilin zaman serisi içerisinde günün değişmesi halinde tahminde karşılık gelen değişiklik parametresi olarak tanımlanmıştır. Prophet modeli, değişken zaman aralıklarında ve eksik verilerle çalışabilen esnek bir modeldir.

Çalışmalarda, Prophet modelin yanı sıra bazı diğer makine öğrenimi modelleri de yer almaktadır. LSTM (Long Short-Term Memory) modeli, yapay sinir ağları temelli bir derin öğrenme modelidir. LSTM, özellikle zaman serileri, doğal dil işleme ve benzeri problemler gibi bellek gerektiren görevlerde sonuç vermektedir. Yani, LSTM, hücrelerden oluşan bir ağ yapısına sahiptir ve bu hücreler birbirleriyle bağlantılıdır. Her hücre, girdi verilerini alır, geçmiş durumlarını hatırlar ve çıktı üretir. Random forest (rastgele orman) modeli, birçok karar ağacının bir araya gelerek oluşturduğu bir topluluk (ensemble) öğrenme yöntemidir. Her bir ağaç, aynı veri kümesi üzerinde eğitilir ve tahmin sonuçları birleştirilerek daha doğru ve güvenilir bir tahmin yapılması amaçlanır. Random forest, hem sınıflandırma hem de regresyon problemleri için kullanılabilir. Regresyon problemlerinde ise modele verilen özellik vektörlerine dayanarak nesnelerin bir sayısal değerini tahmin eder. RNN (Recurrent Neural Network) modeli, yapay sinir ağları temelli bir modeldir ve özellikle zaman serilerinde, doğal dil işleme ve ses tanıma gibi sıralı verilerin işlenmesinde kullanılır. RNN'ler, verinin geçmişine ve şimdiki durumuna bağlı olarak çıktılar üretir ve girdi olarak aldığı sıralı verilerin boyutunu değiştirmeden işleyebilir. Bu özellikleri sayesinde, RNN'ler daha geleneksel makine öğrenimi algoritmalarından daha iyi sonuçlar verir. RNN'ler, özellikle LSTM ve GRU (Gated Recurrent Unit) gibi gelişmiş varyasyonlarıyla birlikte kullanıldığında, zaman serileri tahmini, dil modelleri, çeviri ve görüntü tanıma gibi birçok uygulamaya için başarılı sonuçlar verir.

Günümüzde, makine öğrenmesi yöntemleri bulaşıcı hastalık tahminlerinde de kullanılmaya başlanmıştır. Yapısal özelliği gereği sık kullanılan Prophet modeli tatmin edici sonuçlar vermektedir. (Wang, Yan, Wang, Yang, Li, Gong, Wu, Zhai, Zhang ve Wang, 2022) çalışmasında ARIMA, SARIMA modeli, Prophet modeli; (Sardar, Akbar, Leiva, Alsanad ve Mishra, 2022) çalışmasında ARIMA, Prophet Modeli, GLMNet, Random forest ve XGBoost modelleri; (Sah, Surendiran, Dhanalakshmi, Mohanty, Alenezi ve Polat, 2022) çalışmasında ARIMA, Prophet Modeli, LSTM, LSTM-GRU ve RNN modelleri; (Devaraj, Elavarasan, Pugazhendhi, Shafiullah, Ganesan, Jeysree, Khan ve Hossain, 2021) çalışmasında ARIMA, LSTM, SLSTM, Prophet Model; (Ribeiro, Silvaa, Mariani ve Coelho, 2020) çalışmasında ARIMA, CUBIST, Random Forest, RIDGE ve SVR; (Furtado, 2021) çalışmasında SEIR, polinom regresyon, ARIMA ve Prophet modelleri beraber ele alınmıştır.

Prophet model, içerisinde hem lojistik hem de Fourier barındırdığı için gözlemlerdeki periodik dalgalar daha kolay yakalamaktadır. Bu sebeple verilerin durağanlık şartı bulunmadan tahminlemeye olanak sağlamaktadır.

4. Tartışma ve Sonuç

Bulaşıcı hastalıklar her zaman insanları ve ülkeleri etkilemiştir. Dünyanın hazırlıksız yakalandığı Covid-19 salgını sağlık sistemlerini ve sektörleri olumsuz yönde etkilemiştir. Covid-19 sürecinde ülkelerin salgına hazırlıksız yakalanması salgının yayılımına ait öngörülerini zorunlu hale getirmiştir. Bu sebeple dünya genelinde birçok farklı alanda öngörü çalışmaları ele alınmıştır. Bu çalışma, Covid-19 ve diğer

bazı bulaşıcı hastalıklarla ilgili ele alınan öngörü çalışmalarını inceleyerek, buralarda tercih edilen modelleri ve bu modellerle ilgili bilgileri kapsayacak şekilde sistematik bir analiz içermektedir.

“Forecasting” ve “Covid-19” anahtar kelimeleri kullanılarak 2000-2022 yılları arasında yayınlanan bir grup çalışma incelenmiştir. Bu çalışmalar çoğunlukla tıp alanında olan bilimsel makaleleri kapsamaktadır.

Yayınlarda ele alınan modeller dört ana grupta toplanmaktadır. Bunlar sırasıyla; matematiksel (SIR grubu üzerinde durulmuştur) modelleri, istatistiksel modeller, zaman serisi analizi ve makine öğrenimi yöntemleridir (Prohet model üzerinde durulmuştur).

SIR model grubu, ülke nüfusunu belirli gruplara ayırarak diferansiyel çözümlerle bulaşıcı hastalığa ait öngörü, lojistik modeller bulaşıcı hastalıkların veri yapıları ile benzerlik göstererek şekilde sigmoid yapıda büyüme ile öngörü, zaman serisi analizi ele alınan değişkenin gecikmeli değerleri ile öngörü ve prophet modeli ise olaya ait periodik olmayan değişiklikleri ele alan trend, periyodik olan değişiklikleri mevsimsel ve düzensiz aralıklarla oluşan (tatil) günlerini denkleme koyduğu model ile öngörü sağlamaktadır. Bu modeller, bazı zayıf ve güçlü yanlarına göre seçimlerinde farklılık göstermektedir.

SIR modeli, popülasyon davranışını anlamak için oldukça basit bir çerçeve sunduğundan epidemiyolojik süreci anlamak için gereken temel değişkenleri ve etkileşimleri temsil etmektedir. Bu yüzden, SIR modeli, epidemiyolojik sürecin farklı değişkenlere duyarlılığını anlamak için kullanılmaktadır (Şahinbaş ve Çatak, 2021). Aynı zamanda model, epidemiyolojik sürecin çeşitli değişkenlere (örneğin enfeksiyon oranları, enfekte kişilerin davranışları, aşılama vb.) duyarlılığını anlamak için de kullanılabilir ve çeşitli epidemiyolojik senaryoları modellemek için esnetilebilir (Yang vd., 2020), (Brauer, 2006; Abolmaali ve Shirzaei, 2021; Zhou vd., 2020; Blackwood ve Childs, 2018; Furtado, 2021). Bu avantajların yanı sıra, SIR modeli, bazı varsayımlara dayandırıldığı ve kısıtlamalar içerdiği için gerçek dünya karmaşıklıklarını tam olarak yansıtmaz. Dolayısıyla, gerçek hayatta gözlenen davranışları veya trendleri tam olarak tahmin etmek bazen mümkün olmayabilir. Örneğin, hastalığın tüm bireyler arasında eşit şekilde yayıldığı ve her bireyin aynı derecede hassas olduğu varsayılır. Bu durum, modeli kısıtlamaktadır.

Lojistik model grubu, erken dönem pandemide hesaplamaları hızlı bir şekilde gerçekleştirilebilir, çünkü diğer modellere göre daha az veri ile sonuçlar sağlamaktadır (Miranda ve Devezas, 2022). Aynı zamanda veriye uygun şekilde uyarlanabilen esnek bir modeldir. Kısaca, Lojistik model, doğru bir şekilde yapılandırıldığında, özellikle erken dönem de öngörülebilir sonuçlar verir (Pell vd., 2018; Batista vd., 2020). Bu model, veri setlerindeki trendleri doğru bir şekilde tahmin edebilir (Medina-Mendieta vd., 2020). Özellikle Richards modeli geniş bir yelpazedeki veri setleri için yüksek doğruluk sağlar. Bu model, belirli bir zamanda büyüme hızının en yüksek olduğu noktayı tespit etmek için tasarlanmıştır (Viboud, Simonsen ve Chowell 2016; Wang, Wu, ve Yang, 2012). Bunların aksine, sadece iki sabit nokta (doğum oranı ve ölüm oranı) üzerinden modelleme yapar. Bu nedenle gerçek hayattaki tüm faktörleri hesaba katamaz. Lojistik model, veri setindeki ilk verilerin başlangıç noktasına bağlıdır. Bu yüzden başlangıç noktası değişirse, model sonuçları da değişir. Aynı zamanda bir popülasyonun sonsuza kadar büyüyebileceğini varsayar. Ancak, sınırlı bir kaynak bulunan durumlarda, bu doğru değildir ve bir noktada büyüme duracaktır. Özellikle, salgın ileriki sürecinde, oluşabilecek bir tedavi veya aşı aşamasını modele eklemekte mümkün olmayacağından, öngörü sonuçlarını sağlıklı veremeyebilir.

ARIMA model, verilerin zamana bağlı davranışlarına göre sonuçlar vermekte olup durağan zaman serilerinde özellikle kısa dönemde anlamlı sonuçlar vermektedir (Ceylan, 2020; Liu vd., 2011; Perez vd., 2020; Earnest vd., 2005; Abuhasel vd., 2022; Bayyurt ve Bayyurt, 2020; Deb ve Majumdar, 2020; Akhtar ve Rozi, 2009). Aynı zamanda, zaman serilerinin özellikle trendlerinin veya mevsimselliklerinin tahmin edilmesi için uygundur (He ve Tao, 2018). Ancak, diğer tür örüntüler (örneğin, kalıcı veya geçici değişiklikler) için uygun değildir. Aynı zamanda, zaman serilerindeki bir değişikliğin nedenini belirlemezler. Diğer değişkenlerin (örneğin, piyasa koşulları veya hava durumu) zaman serilerine olan etkilerini yansıtmazlar. Bu nedenle, ARIMA modelleri yalnızca birçok değişkene bağlı olmayan zaman serileri için en uygun seçimdir.

Prophet model, veri setlerindeki değişen trendleri ve diğer etkileri kolayca modelleyebilir (Wang vd., 2022; Devaraj vd., 2021). Yani, zaman serisi verilerindeki trendleri, haftalık etkileri ve diğer faktörleri tahmin edebilir ve aykırı değerlere karşı dirençlidir (Sardar vd., 2022). Bu avantajlar, Prophet modelinin

kullanımını kolaylaştırmaktadır ancak, yalnızca trendleri ve haftalık/yıllık düzenlilikleri modelleyebilir. Diğer düzenlilikler veya dalgalanmalar için uygun değildir ve sonuçları yorumlama konusunda bazı zorluklar sunabilir. Özellikle, tahmin aralıkları ve değişkenler arasındaki ilişkilerin anlaşılması bazı durumlarda zor olabilir.

Modellerin zayıf yanlarının yanı sıra, bulaşıcı hastalıkların öngörü tahmin sonuçlarının elde edilmesinde, seçilen modellerden bağımsız olarak vaka tanımlarındaki farklılıklar, yanlış modellemeler, test protokolü ve kapasitesinin farklılığı, yetersiz veri, raporlama sistemi ve verilerin yayınlanma zamanındaki farklılıkları da öngörülerini olumsuz yönde etkilenmektedir. Sonuç olarak teorik temelde yapılacak bazı geliştirmelerle daha uygun öngörüler sağlamaya açık olan bu modeller öngörü tahminlerinde politika sağlayıcılara yol göstermektedir (Benvenuto vd., 2020; Ioannidis vd., 2022; Caccavo, 2020; Simpson vd., 2022). Sonuç olarak, modeller salgının hangi aşamasında olunduğuna, hastalığın fiziksel özelliklerine, hastalığın iyileştirilmesinde tedavi veya aşının varlığına, verinin sayısına, durağan olmasına veya mevsimsellik içerip içermediğine göre seçilerek daha gerçekçi tahmin sonuçları sağlanabilir.

Kaynakça

- Abolmaali, S. ve Shirzaei, S. 2021. “A Comparative Study of SIR Model, Linear Regression, Logistic Function and ARIMA Model for Forecasting COVID-19 Cases”. *AIMS Public Health* 8(4):598-613. doi: 10.3934/publichealth.2021048.
- Abuhasel, K. A., Khadr, M. ve Alquraish, M. M. 2022. “Analyzing and Forecasting COVID -19 Pandemic in the Kingdom of Saudi Arabia Using ARIMA and SIR Models”. *Computational Intelligence* 38(3):770-83. doi: 10.1111/coin.12407.
- Abusam, A., Razan A. ve Al-Anzi, B. 2020. “Adequacy of Logistic Models for Describing the Dynamics of COVID-19 Pandemic”. *Infectious Disease Modelling* 5:536-42. doi: 10.1016/j.idm.2020.08.006.
- Akhtar, S. ve Rozi, S. 2009. “An Autoregressive Integrated Moving Average Model for Short-Term Prediction of Hepatitis C Virus Seropositivity among Male Volunteer Blood Donors in Karachi, Pakistan”. *World Journal of Gastroenterology* 15(13):1607. doi: 10.3748/wjg.15.1607.
- Almeshal, A. M., Almazrouee, A. I., Alenizi, M. R. ve Alhajeri, S. N. 2020. “Forecasting the Spread of COVID-19 in Kuwait Using Compartmental and Logistic Regression Models”. *Applied Sciences* 10(10):3402. doi: 10.3390/app10103402.
- Andrews, J. R. ve Basu, S. 2011. “Transmission Dynamics and Control of Cholera in Haiti: An Epidemic Model”. *The Lancet* 377(9773):1248-55. doi: 10.1016/S0140-6736(11)60273-0.
- Anirudh, A. 2020. “Mathematical Modeling and the Transmission Dynamics in Predicting the Covid-19 - What next in Combating the Pandemic”. *Infectious Disease Modelling* 5:366-74. doi: 10.1016/j.idm.2020.06.002.
- Aviv-Sharon, E. ve Aharoni, A. 2020. “Generalized Logistic Growth Modeling of the COVID-19 Pandemic in Asia”. *Infectious Disease Modelling* 5:502-9. doi: 10.1016/j.idm.2020.07.003.
- Bag, M., ve Sade, G. “Dünyada Covid-19: İlk 4 ayında neler yaşandı? Salgının seyri ne durumda?”
- Balak, N., Inan, D., Ganau, M., Zoia, C., Sönmez, S., Kurt, B., Akgül, A. ve Tez, M. 2021. “A Simple Mathematical Tool to Forecast COVID-19 Cumulative Case Numbers”. *Clinical Epidemiology and Global Health* 12:100853. doi: 10.1016/j.cegh.2021.100853.
- Batista, M. 2020. “Estimation of the Final Size of the Coronavirus Epidemic by the Logistic Model”. *MedRxiv*. 15.
- Bayyurt, L. ve Bayyurt, B. 2020. Forecasting of COVID-19 Cases and Deaths Using ARIMA Models. preprint. *Infectious Diseases*. doi: 10.1101/2020.04.17.20069237.
- Benvenuto, D., Giovanetti, M., Vassallo, L., Angeletti, S. ve Ciccozzi, M. 2020. “Application of the ARIMA Model on the COVID-2019 Epidemic Dataset”. *Data in Brief* 29:105340. doi: 10.1016/j.dib.2020.105340.

- Blackwood, J. ve Childs, L. 2018. "An Introduction to Compartmental Modeling for the Budding Infectious Disease Modeler". *Letters in Biomathematics* 5(1). doi: 10.30707/LiB5.1Blackwood.
- Box, G. E. P. ve Jenkins, G. M. 1976. *Time Series Analysis: Forecasting and control*. Rev. ed. San Francisco: Holden-Day.
- Brauer, F. 2006. "Some Simple Epidemic Models". *Mathematical Biosciences and Engineering* 3(1):1-15. doi: 10.3934/mbe.2006.3.1.
- Bürger, R., Chowell, G., Lara-Díaz, L. Y. 2019. "Comparative Analysis of Phenomenological Growth Models Applied to Epidemic Outbreaks". *Mathematical Biosciences and Engineering* 16(5):4250-73. doi: 10.3934/mbe.2019212.
- Caccavo, D. 2020. Chinese and Italian COVID-19 Outbreaks Can Be Correctly Described by a Modified SIRD Model. preprint. *Epidemiology*. doi: 10.1101/2020.03.19.20039388.
- Ceylan, Z. 2020. "Estimation of COVID-19 Prevalence in Italy, Spain, and France". *Science of The Total Environment* 729:138817. doi: 10.1016/j.scitotenv.2020.138817.
- Chowell, G., Hengartner, N. W., Castillo-Chavez, C., Fenimore, P. W. ve Hyman, J. M. 2004. "The Basic Reproductive Number of Ebola and the Effects of Public Health Measures: The Cases of Congo and Uganda". *Journal of Theoretical Biology* 229(1):119-26. doi: 10.1016/j.jtbi.2004.03.006.
- Chowell, G., Luo, R., Sun, K., Roosa, K., Tariq, A. ve Viboud, C. 2020. "Real-Time Forecasting of Epidemic Trajectories Using Computational Dynamic Ensembles". *Epidemics* 30:100379. doi: 10.1016/j.epidem.2019.100379.
- Chowell, G. 2017. "Fitting Dynamic Models to Epidemic Outbreaks with Quantified Uncertainty: A Primer for Parameter Uncertainty, Identifiability, and Forecasts". *Infectious Disease Modelling* 2(3):379-98. doi: 10.1016/j.idm.2017.08.001.
- Chowell, G., Abdirizak, F., Lee, S., Lee, J., Jung, E., Nishiura, H. ve Viboud, C. 2015. "Transmission Characteristics of MERS and SARS in the Healthcare Setting: A Comparative Study". *BMC Medicine* 13(1):210. doi: 10.1186/s12916-015-0450-0.
- Chowell, G., Hincapié-Palacio, D., Ospina, J., Pell, B., Tariq, A., Dahal, S., Moghadas, S., Smirnova, A., Simonsen, L. ve Viboud, C. 2016. "Using Phenomenological Models to Characterize Transmissibility and Forecast Patterns and Final Burden of Zika Epidemics". *PLoS Currents*. doi: 10.1371/currents.outbreaks.f14b2217c902f453d9320a43a35b9583.
- Chowell, G., Tariq, A. ve Hyman, J. M. 2019. "A Novel Sub-Epidemic Modeling Framework for Short-Term Forecasting Epidemic Waves". *BMC Medicine* 17(1):164. doi: 10.1186/s12916-019-1406-6.
- Darti, İ., Habibah, U., Astutik S., Kusumawinahyu, W. M., Marsudi, Suryanto A., 2021. "Comparison of Phenomenological Growth Models in Predicting Cumulative Number of COVID-19 Cases in East Java Province, Indonesia". *Communications in Mathematical Biology and Neuroscience*. doi: 10.28919/cmbn/5338.
- Deb, S. ve Majumdar, M. 2020. "A Time Series Method to Analyze Incidence Pattern and Estimate Reproduction Number of COVID-19".
- Demongeot, J., Oshinubi, K., Rachdi, M., Hobbad, L., Alahiane, M., Iggui, S., Gaudart, J. ve Ouassou, I. 2022. "The Application of ARIMA Model to Analyze COVID-19 Incidence Pattern in Several Countries". *Journal of Mathematical and Computational Science*. doi: 10.28919/jmcs/6541.
- Devaraj, J., Elavarasan, R. M., Pugazhendhi, R., Shafiullah, G. M., Ganesan, S., Jeysree, A. K., Khan, I. A. ve Hossain, E. 2021. "Forecasting of COVID-19 Cases Using Deep Learning Models: Is It Reliable and Practically Significant?" *Results in Physics* 21:103817. doi: 10.1016/j.rinp.2021.103817.

- Diaz Perez, F. J., Chinarro, D., Pino Otin, R., Díaz Martín, R., Diaz, M. ve Guardiola Mouhaffel, A. 2020. "Comparison of Growth Patterns of COVID-19 Cases through the ARIMA and Gompertz Models. Case Studies: Austria, Switzerland, and Israel". *Rambam Maimonides Medical Journal* 11(3):e0022. doi: 10.5041/RMMJ.10413.
- Earnest, A., Chen, M. I., Ng, D. ve Sin, L. Y. 2005. "Using Autoregressive Integrated Moving Average (ARIMA) Models to Predict and Monitor the Number of Beds Occupied during a SARS Outbreak in a Tertiary Hospital in Singapore". *BMC Health Services Research* 5(1):36. doi: 10.1186/1472-6963-5-36.
- Furtado, P. 2021. "Epidemiology SIR with Regression, Arima, and Prophet in Forecasting Covid-19". *The 7th International conference on Time Series and Forecasting*. MDPI.
- He, Z. ve Tao, H. 2018. "Epidemiology and ARIMA Model of Positive-Rate of Influenza Viruses among Children in Wuhan, China: A Nine-Year Retrospective Study". *International Journal of Infectious Diseases* 74:61-70. doi: 10.1016/j.ijid.2018.07.003.
- Hethcote, H. W. 2000. "The Mathematics of Infectious Diseases". *SIAM Review* 42(4):599-653. doi: 10.1137/S0036144500371907.
- Husniah, H. ve Supriatna, A. K. 2021. "How Good or Bad Is the Prediction of Black-Box COVID-19 Models After One Year Has Lapped?" 9.
- Ioannidis, J. P. A., Cripps, S. ve Tanner, M. A. 2022. "Forecasting for COVID-19 Has Failed". *International Journal of Forecasting* 38(2):423-38. doi: 10.1016/j.ijforecast.2020.08.004.
- Lee, S. Y., Lei, B. ve Mallick, B. 2020. "Estimation of COVID-19 Spread Curves Integrating Global Data and Borrowing Information" editör A. M. Samy. *PLOS ONE* 15(7):e0236860. doi: 10.1371/journal.pone.0236860.
- Lekone, P. E. ve Finkenstädt, B. F. 2006. "Statistical Inference in a Stochastic Epidemic SEIR Model with Control Intervention: Ebola as a Case Study". *Biometrics* 62(4):1170-77. doi: 10.1111/j.1541-0420.2006.00609.x.
- Liu, Q., Liu, X., Jiang, B. ve Yang, W. 2011. "Forecasting Incidence of Hemorrhagic Fever with Renal Syndrome in China Using ARIMA Model". *BMC Infectious Diseases* 11(1):218. doi: 10.1186/1471-2334-11-218.
- Ma, J. 2020. "Estimating Epidemic Exponential Growth Rate and Basic Reproduction Number". *Infectious Disease Modelling* 5:129-41. doi: 10.1016/j.idm.2019.12.009.
- Medina-Mendieta, J., Cortés-Cortés, M. ve Cortés-Iglesias, M. 2020. "COVID-19 Forecasts for Cuba Using Logistic Regression and Gompertz Curves". *MEDICC Review* 22(3):32. doi: 10.37757/MR2020.V22.N3.8.
- Miranda, L. C. M. ve Devezas, T. 2022. "On the Global Time Evolution of the Covid-19 Pandemic: Logistic Modeling". *Technological Forecasting and Social Change* 175:121387. doi: 10.1016/j.techfore.2021.121387.
- Mizumoto, K., Kagaya, K., Zarebski, A. ve Chowell, G. 2020. "Estimating the Asymptomatic Proportion of Coronavirus Disease 2019 (COVID-19) Cases on Board the Diamond Princess Cruise Ship, Yokohama, Japan, 2020". *Eurosurveillance* 25(10). doi: 10.2807/1560-7917.ES.2020.25.10.2000180.
- Nelder, J. A. 1961. "The fitting of a generalization of the logistic curve". *International Biometric Society* 17(1):89-110.
- Nguyen, T. T., Nguyen, Q. V. H., Nguyen, D. T., Yang, S., Eklund, P. W., Huynh-The, T., Nguyen, T. T., Pham, Q. V., Razzak, I. ve Hsu, E. B. 2022. "Artificial Intelligence in the Battle against Coronavirus (COVID-19): A Survey and Future Research Directions". *arXiv*.

- Nuraini, N., Khairudin, K. ve Apri, M. 2020. "Modeling Simulation of COVID-19 in Indonesia Based on Early Endemic Data". *Communication in Biomathematical Sciences* 3(1):1-8. doi: 10.5614/cbms.2020.3.1.1.
- Oshinubi, K, Rachdi, M. ve Demongeot, J. 2021. "Analysis of Reproduction Number R_0 of COVID-19 Using Current Health Expenditure as Gross Domestic Product Percentage (CHE/GDP) across Countries". *Healthcare* 9(10):1247. doi: 10.3390/healthcare9101247.
- Pell, B., Kuang, Y., Viboud, C. ve Chowell, G. 2018. "Using Phenomenological Models for Forecasting the 2015 Ebola Challenge". *Epidemics*. 22:62-70. doi: 10.1016/j.epidem.2016.11.002.
- Ribeiro, M. H. D. M., Silva, R. G., Mariani, V. C. ve Coelho, L. S. 2020. "Short-Term Forecasting COVID-19 Cumulative Confirmed Cases: Perspectives for Brazil". *Chaos, Solitons & Fractals* 135:109853. doi: 10.1016/j.chaos.2020.109853.
- Richards, F. J. 1959. "A Flexible Growth Function for Empirical Use". *Journal of Experimental Botany* 10(2):290-301. doi: 10.1093/jxb/10.2.290.
- Roosa, K., Lee, Y., Luo, R., Kirpich, A., Rothenberg, R., Hyman, J. M., Yan, P. ve Chowell, G. 2020. "Real-Time Forecasts of the COVID-19 Epidemic in China from February 5th to February 24th, 2020". *Infectious Disease Modelling* 5:256-63. doi: 10.1016/j.idm.2020.02.002.
- Roosa, K., Lee, Y., Luo, R., Kirpich, A., Rothenberg, R., Hyman, J. M., Yan, P. ve Chowell, G. 2020. "Short-Term Forecasts of the COVID-19 Epidemic in Guangdong and Zhejiang, China: February 13–23, 2020". *Journal of Clinical Medicine* 9(2):596. doi: 10.3390/jcm9020596.
- Roosa, K., Tariq, A., Yan, P., Hyman, J. M. ve Chowell, G. 2020. "Multi-Model Forecasts of the Ongoing Ebola Epidemic in the Democratic Republic of Congo, March–October 2019". *Journal of the Royal*. 12.
- Saez, M., Tobias, A., Varga, D. ve Barceló, M. A. 2020. "Effectiveness of the Measures to Flatten the Epidemic Curve of COVID-19. The Case of Spain". *Science of The Total Environment* 727:138761. doi: 10.1016/j.scitotenv.2020.138761.
- Sah, S., Surendiran, B., Dhanalakshmi, R., Mohanty, S. N., Alenezi, F. ve Polat, K. 2022. "Forecasting COVID-19 Pandemic Using Prophet, ARIMA, and Hybrid Stacked LSTM-GRU Models in India" editör A. Korobeinikov. *Computational and Mathematical Methods in Medicine* 2022:1-19. doi: 10.1155/2022/1556025.
- Sardar, I., Akbar, M. A., Leiva, V., Alsanad, A. ve Mishra, P. 2022. "Machine Learning and Automatic ARIMA/Prophet Models-Based Forecasting of COVID-19: Methodology, Evaluation, and Case Study in SAARC Countries". *Stochastic Environmental Research and Risk Assessment*. doi: 10.1007/s00477-022-02307-x
- Satsuma, J., R. Willox, A. Ramani, B. Grammaticos, ve A. S. Carstea. 2004. "Extending the SIR Epidemic Model". *Physica A: Statistical Mechanics and Its Applications* 336(3-4):369-75. doi: 10.1016/j.physa.2003.12.035.
- Schaffer, A. L., Dobbins, T. A. ve Pearson, S. A. 2021. "Interrupted Time Series Analysis Using Autoregressive Integrated Moving Average (ARIMA) Models: A Guide for Evaluating Large-Scale Health Interventions". *BMC Medical Research Methodology* 21(1):58. doi: 10.1186/s12874-021-01235-8.
- Schuppert, A., Polotzek, K., Schmitt, J., Busse, R., Karschau, J. ve Karagiannidis, C. 2021. "Different Spreading Dynamics throughout Germany during the Second Wave of the COVID-19 Pandemic: A Time Series Study Based on National Surveillance Data". *The Lancet Regional Health - Europe* 6:100151. doi: 10.1016/j.lanepe.2021.100151.
- Shen, C. Y. 2020. "Logistic Growth Modelling of COVID-19 Proliferation in China and Its International Implications". *International Journal of Infectious Diseases* 96:582-89. doi: 10.1016/j.ijid.2020.04.085.

- Simpson, M. J., Browning, A. P., Warne, D. J., Maclaren, O. J. ve Baker, R. E. 2022. "Parameter Identifiability and Model Selection for Sigmoid Population Growth Models". *Journal of Theoretical Biology* 535:110998. doi: 10.1016/j.jtbi.2021.110998.
- Şahinbaş, K. ve Çatak, F. 2021. "SEIR Based Epidemic Modeling of COVID-19 in Turkey". *European Journal of Science and Technology*. doi: 10.31590/ejosat.842560.
- Taylor, S. J., ve Letham, B. 2018. "Forecasting at Scale". *The American Statistician* 72(1):37-45. doi: 10.1080/00031305.2017.1380080.
- Viboud, C., Simonsen, L. ve Chowell, G. 2016. "A Generalized-Growth Model to Characterize the Early Ascending Phase of Infectious Disease Outbreaks". *Epidemics* 15:27-37. doi: 10.1016/j.epidem.2016.01.002.
- Wang, X. S., Wu, J. ve Yang, Y. 2012. "Richards Model Revisited: Validation by and Application to Infection Dynamics". *Journal of Theoretical Biology* 313:12-19. doi: 10.1016/j.jtbi.2012.07.024.
- Wang, Y, Yan, Z., Wang, D., Yang, M., Li, Z., Gong, X., Wu, D., Zhai, L., Zhang, W. ve Wang, Y. 2022. "Prediction and Analysis of COVID-19 Daily New Cases and Cumulative Cases: Times Series Forecasting and Machine Learning Models". *BMC Infectious Diseases* 22(1):495. doi: 10.1186/s12879-022-07472-6.
- Wu, K., Darcet, D., Wang, Q. ve Sornette, D. 2020. "Generalized Logistic Growth Modeling of the COVID-19 Outbreak: Comparing the Dynamics in the 29 Provinces in China and in the Rest of the World". *Nonlinear Dynamics* 101(3):1561-81. doi: 10.1007/s11071-020-05862-6.
- Yang, C. ve Wang, J. 2020. "A Mathematical Model for the Novel Coronavirus Epidemic in Wuhan, China". *Mathematical Biosciences and Engineering* 17(3):2708-24. doi: 10.3934/mbe.2020148.
- Zhou, X., Ma, X., Hong, N., Su, L., Ma, Y., He, J., Jiang, H., Liu, C., Shan, G., Zhu, W., Zhang, S. ve Long, Y. 2020. Forecasting the Worldwide Spread of COVID-19 Based on Logistic Model and SEIR Model. preprint. *Epidemiology*. doi: 10.1101/2020.03.26.20044289.
- Zreiq, R., Kamel, S., Boubaker, S., Al-Shammary, A. A., Algahtani, F. D., Alshammari, F. 2020. "Generalized Richards Model for Predicting COVID-19 Dynamics in Saudi Arabia Based on Particle Swarm Optimization Algorithm". *AIMS Public Health* 7(4):828-43. doi: 10.3934/publichealth.2020064.

EKLER**Tablo 1:** Bilimsel Yayınlar

Makalenin Adı	Yıl	Bulaşıcı Hastalık	Model	Ülke	Tarih
(Zreiq vd., 2020)	2020	Covid-19	Genelleştirilmiş Richards Modeli	Suudi Arabistan	2 Mart - 10 Ekim 2020
(Lee vd., 2020)	2020	Covid-19	Richards Büyüme Modeli	İngiltere, Rusya, ABD, Brezilya, Almanya, Çin, Hindistan ve Güney Kore	22 Ocak - 14 Mayıs 2020
(Aviv-Sharon ve Aharoni, 2020)	2020	Covid-19	Genelleştirilmiş Lojistik Modeli, Richards Modeli	Çin, İran, Filipinler, Tayvan	Her ülke için farklı tarih aralığı seçilmiştir.
(Anirudh, 2020)	2020	Covid-19	SIR, SEIR, SEIRU, SIRD, SLIAR, SIDARTHE Modeli ve ARIMA	Çin ve Çin'de bazı bölgeler, Hindistan, İtalya, İspanya, Fransa, ABD ve ABD'de bazı bölgeler	Her ülke için farklı tarih aralığı seçilmiştir.
(Husniah ve Supriatna, 2021)	2021	Covid-19	Verhulst Lojistik Modeli	Endonezya	2 Mart - 30 Eylül 2020
(Darti vd., 2021)	2021	Covid-19	Richards Modeli, Genelleştirilmiş Richards Modeli, Blumberg Modeli, Tsoularis & Wallace Modeli ve Gompertz Modeli	Doğu Java	25 Mart - 31 Ekim 2020
(Roosa vd., 2020)	2020	Covid-19	Genelleştirilmiş Lojistik Model, Richards Modeli ve Salgın Alt Dalga Modeli	Çin	22 Ocak - 13 Şubat 2020
(Wu vd., 2020)	2020	Covid-19	Genelleştirilmiş Lojistik Model, Genelleştirilmiş Richards Modeli	Çin, Amerika Birleşik Devletleri, İngiltere, İspanya, İtalya, Almanya, Fransa, Avusturya, Belçika, Hollanda, İrlanda, Portekiz, İsviçre, Japonya, Türkiye, Kanada, Afganistan, Katar, Belarus, Pakistan, Rusya, Peru, Suudi Arabistan, Brezilya, Arjantin, Meksika, İsrail,	Her ülke için farklı tarih aralığı seçilmiştir.

				Hindistan, İsveç, Dominik Cumhuriyeti, Filipinler, İran	
(Nuraini vd., 2020)	2020	Covid-19	Richards Modeli	Çin, İtalya, İran, Güney Kore ve ABD	21 Ocak- 3 Ekim 2020
(Abusam vd., 2020)	2020	Covid-19	Lojistik Modeli, Verhulst ve Richards Modeli	Kuveyt	24 Şubat- Mart 2020
(Roosa vd., 2020)	2020	Ebola	Lojistik Model, Richards Modeli, Endemik Richards Modeli, Çift Lojistik Model ve Salgın Alt Dalga Modeli	Democratic Republic of the Congo	11 Mart- 23 Ekim 2019
(Chowell, 2017)	2017	Ebola	Genelleştirilmiş Büyüme Modeli, Genelleştirilmiş Richards Modeli, SEIR	Sierra Leone, Batı Afrika	2014-2016
(Bürger vd., 2019)	2019	Ebola, Veba, Kızamık, Çiçek Hastalığı, Sarı Humma, FMD, Grip, Zika Virüsü, VIH-AIDS, Kolera	Lojistik Model, Gompertz modeli, Genelleştirilmiş Lojistik Model, Genelleştirilmiş Gompertz Modeli	Gine'de bazı bölgeler, Liberya'de bazı bölgeler, Sierra'da bazı bölgeler, İngiltere'de bazı bölgeler, ABD'de bazı bölgeler, Kolombiya, Japonya ve Danimarka	Her ülke için farklı tarih aralığı seçilmiştir.
(Roosa vd., 2020)	2020	Covid-19	Genelleştirilmiş Lojistik Model, Richards Modeli ve Salgın Alt Dalga Modeli	Çin	22 Ocak - 9 Temmuz 2020
(Pell vd., 2018)	2016	Ebola	Lojistik Model, Richards Model ve Genelleştirilmiş Richards Modeli	Liberya	2015
(Chowell vd., 2019)	2019	SARS, Ebola, Veba	Lojistik Modeli, Richards Modeli	Singapur, Madagaskar, Demokratik Kongo Cumhuriyeti	Her ülke için farklı tarih

			ve Salgın Alt Dalga Modeli		aralığı seçilmiştir.
(Chowell vd., 2020)	2020	Ebola	Genelleştirilmiş Büyüme Modeli, Genelleştirilmiş Richards Modeli	Liberya	2014 - 2015
(Viboud, Simonsen ve Chowell 2016)	2016	Ebola, Grip, Çiçek Hastalığı, Şap Hastalığı (El-Ayak Hastalığı), HIV/AIDS	Genelleştirilmiş Epidemiyoloji Büyüme Modeli	Liberia, San Francisco, Uruguay, Japonya	Her ülke için farklı tarih aralığı seçilmiştir.
(Chowell vd., 2015)	2015	MERS ve SARS	Transmission Tree Analizi	Suudi Arabistan, Güney Kore, Kanada, Çin, Hong Kong, Singapur, Vietnam	Her ülke için farklı tarih aralığı seçilmiştir.
(Chowell vd., 2016)	2016	Zika Virüsü	Genelleştirilmiş Richards Modeli	Kolombiya	Ocak - Nisan 2016
(Chowell vd., 2004)	2004	Ebola	SEIR, Markov Zinciri Modeli	Uganda	20 Ağustos 2020 - 7 Ocak 2021
(Mizumoto vd., 2020)	2020	Covid-19	Hamiltonian Monte Carlo (HMC) Algoritması	Japonya	5 - 20 Şubat 2020
(Ceylan, 2020)	2020	Covid-19	ARIMA	İtalya, İspanya ve Fransa	21 Şubat - 15 Nisan 2020
(Liu vd., 2011)	2011	HFRS	ARIMA	Çin	1978-2008
(Perez vd., 2020)	2020	Covid-19	ARIMA ve Gompertz Modeli	Avusturya, İsviçre ve İsrail	Her ülke için farklı tarih aralığı seçilmiştir.
(He ve Tao, 2018)	2018	Grip	ARIMA	Çin	2007–2015
(Benvenuto vd., 2020)	2020	Covid-19	ARIMA		20 Ocak - 10 Şubat 2020
(Ioannidis vd., 2022)	2020	Covid-19	SIR Modeli	ABD'de bulunan bazı bölgeler	Her bölge için farklı tarih aralığı seçilmiştir.

(Yang vd., 2020)	2020	Covid-19	SEIR Modeli	Çin	31 Aralık 2019 - 28 Ocak 2020
(Brauer, 2006)	2006		SI, SIN, SEIN, SAIN,SAQIJR, SVIN		
(Almeshal vd., 2020)	2020	Covid-19	SIR ve Lojistik Model	Kuveyt	24 Şubat - 19 Nisan 2020
(Caccavo, 2020)	2020	Covid-19	SIRD modeli	İtalya ve Çin	22 Ocak - 17 Nisan 2020
(Abolmaali vd., 2021)	2021	Covid-19	SIR Model, Lineer Regresyon, Lojistik Model ve ARIMA	ABD, Brezilya, Hindistan ve Rusya	Mart - Nisan 2020.
(Wang vd., 2022)	2022	Covid-19	ARIMA, SARIMA ve Prophet modeli	ABD, Brezilya ve Hindistan	1 Mayıs 2020 - 30 Kasım 2021
(Ma, 2020)	2020	Ebola	SIR Modeli, SEIR Modeli	Çin	2014 - 2016
(Zhou vd., 2020)	2020	Covid-19	Lojistik Model, SEIR Modeli ve Genişletilmiş SEIR Modeli	İtalya, Güney Kore, İran, Fransa, ABD, Japonya, Almanya ve İspanya	23 Ocak - 20 Mart 2020
(Earnest vd., 2005)	2005	SARS	ARIMA	Singapur	14 Mart - 21 Nisan 2003
(Abuhasel vd., 2022)	2020	Covid-19	ARIMA and SIR modeli	İngiltere, Suudi Arabistan	2 Mart - 30 Haziran 2020
(Schuppert vd., 2021)	2021	Covid-19	Temel Bileşenler Analizi	Almanya	Ağustos 2020 - Ocak 2021 (2. Dalga)
(Satsuma vd., 2004)	2003		SIR Modeli, SI Modeli		
(Şahinbaş ve Çatak, 2021)	2022	Covid-19	SEIR Modeli	Türkiye	Şubat - Ekim 2020
(Batista vd., 2020)	2020	Covid-19	Lojistik Model	Çin, Güney Kore ve geri kalan tüm ülkeler	Her ülke için farklı tarih aralığı seçilmiştir.
(Hethcote, 2000)	2000	Bordetella hastalığı ve Kızamık	SIR, SEIR, MSEIR, SEIS Modeli	ABD, Nijerya	Her ülke için farklı tarih aralığı seçilmiştir.
(Medina-Mendieta vd., 2020)	2022	Covid-19	Lojistik Model ve Gompertz Modeli	Küba	16 Mart - 22 Nisan 2020

(Lekone ve Finkenstädt, 2006)	2006	Ebola	SEIR Modeli	Demokratik Kongo Cumhuriyeti	1 Mart - 16 Temmuz 1995
(Andrews ve Basu, 2011)	2011	Kolera	SIR Modeli	Haiti	31 Ekim 2010 - 24 Ocak 2011
(Saez vd., 2020)	2020	Covid-19	Genelleştirilmiş Lineer Model (Gauss)	İspanya	17 Ocak - 5 Nisan 2020
(Deb ve Majumdar, 2020)	2020	Covid-19	ARIMA	Çin, İtalya, ABD, İspanya, Almanya, İran, Fransa, Güney Kore, İsviçre, İngiltere, Hindistan ve Dünya	22 Ocak - 21 Mart 2020
(Blackwood ve Childs, 2018)	2018		SIR Modeli, SEIR Modeli		
(Akhtar ve Rozi, 2009)	2009	Hepatit C Virüsü	ARIMA	Pakistan	1998-2005
(Sardar vd., 2022)	2022	Covid-19	ARIMA, Prophet Modeli, GLMNet, Random forest ve XGBoost	SAARC ülkeleri	31 Ocak - 19 Temmuz 2020
(Sah vd., 2022)	2022	Covid-19	ARIMA, Prophet Modeli, LSTM, LSTM-GRU ve RNN Modeli	Hindistan	30 Ocak - 7 Aralık 2020
(Nguyen vd., 2022)	2022	Covid-19			
(Schaffer vd., 2021)	2021	Sağlık Politikaları	ARIMA	Avustralya	Ocak 2011 - Ocak 2014
(Furtado, 2021)	2021	Covid-19	SEIR, Polinom Regresyonu, ARIMA ve Prophet Modeli	ABD, İspanya, İtalya, Almanya, Fransa, İran, İngiltere, Türkiye, İsviçre, Belçika, Hollanda, Kanada, Avusturya, Portekiz, Güney Kore, Brezilya, İsrail, İsveç, Avustralya ve Norveç	Her ülke için farklı tarih aralığı seçilmiştir.
(Oshinubi vd., 2021)	2021	Covid-19	ARIMA	Gelişmiş Ülkeler	Birinci dalga için, Şubat ve Ağustos 2020; ikinci dalga için, 15 Ekim 2020 -

					22 Ocak 2021 kullanılmıştır.
(Demongeot vd., 2022)	2022	Covid-19	ARIMA	Fas, Fransa, İtalya, İspanya ve ABD	Ocak - Mayıs 2020
(Wang, Wu, ve Yang, 2012)	2012	H1N1, SARS ,Dang Humması, SARS	SIR Modeli ve Richards Modeli	Kanada, Singapur ve Tayvan	Her ülke için farklı tarih aralığı seçilmiştir.
(Simpson vd., 2022)	2021		Lojistik Model, Gompertz Modeli ve Richards Modeli		
(Balak vd., 2021)	2021	Covid-19	Verhulst–Pearl Lojistik Modeli	ABD, Brezilya, Rusya, Hindistan, İngiltere, Peru, Şili, İspanya, İran, İtalya, Meksika, Pakistan, Türkiye, Almanya, Suudi Arabistan, Fransa, Güney Afrika, Bangladeş, Kanada, Katar	Her ülke için farklı tarih aralığı seçilmiştir.
(Bayyurt ve Bayyurt, 2020)	2020	Covid-19	ARIMA	İtalya, İspanya ve Türkiye	2 Şubat - 27 Mart 2020
(Shen, 2020)	2020	Covid-19	Lojistik Modeli	Çin, Güney Kore ve İran	20 Ocak - 13 Mart 2020
(Devaraj vd., 2021)	2021	Covid-19	ARIMA, LSTM, SLSTM, Prophet Model		
(Miranda ve Devezas, 2022)	2022	Covid-19	Lojistik Model	ABD, Hindistan, Brezilya, Fransa, Rusya, İngiltere, Güney Afrika ve Türkiye	15 Şubat 2020 - 7 Ekim 2021
(Ribeiro vd., 2020)	2020	Covid-19	ARIMA, CUBIST, Random Forest, RIDGE ve SVR	Brezilya	5 Mart - 19 Nisan 2020

Review Article**Bulaşıcı Hastalıkların Öngörü Modelleri: Bir Derleme Çalışması***Forecasting Models of Infectious diseases: A Review Study*

Yeliz ZOĞAL Ankara Hacı Bayram Veli Üniversitesi Lisansüstü Eğitim Fakültesi Ekonometri Bölümü y.zogal@gmail.com https://orcid.org/0000-0002-8940-3337	Atilla GÖKÇE Prof. Dr., Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü atilla.gokce@hbm.edu.tr https://orcid.org/0000-0001-8287-4278
--	---

Extended Abstract

Infectious diseases have always affected people and countries. The Covid-19 pandemic caught the world unprepared, and negatively affected health systems and sectors. The fact that governments were caught unprepared for the epidemic during the Covid-19 process has made predictions about the spread of the epidemic mandatory. For this reason, forecasting studies have been addressed in many fields worldwide. This study examines the forecasting studies on Covid-19 and some other infectious diseases and obtains a systematic analysis to cover the preferred models and information about these models.

A group of studies published between 2000-2022 with the keywords "Forecasting" and "Covid-19" were examined. These studies are mainly in the fields of medicine and natural sciences. However, most analysed studies were classified as scientific and diversified with online articles, book reviews and conference papers.

In the publications analysed, short, long and short-long term case prediction estimates were provided and short-term prediction estimates were mainly discussed. This is because publications dealing with short-term forecasts provide information on the measures to be taken by governments and the frequency and/or stringency of the measures. The daily and cumulative data used in the publications were obtained from the World Health Organisation, Johns Hopkins University, and health institutions of the countries to be predicted.

The models considered in scientific studies are categorised into four main groups. These are, respectively, mathematical models (SIR group is focused on), statistical models, time series analysis and machine learning methods (Prophet model is focused on).

The SIR (mathematical) model has been used frequently in the literature to model epidemics. In the SIR model, in populations with N individuals, individuals are in one of three main groups at time t. Susceptible (S) refers to healthy people who have not yet contracted the disease but are likely to do so; infected (I) refers to people who have contracted the disease and can infect others who are likely to contract it; recovered (R) refers to people who have contracted the disease and have recovered through immunisation. The SIR model has some assumptions, such as the total population is not considered constant, individuals who recover after being infected are considered fully immune to the virus, and the virus has no incubation period. This model can be differentiated according to the characteristics of the infectious disease and the measures and treatments taken against the disease. This is a stretching of the assumptions. For example, for situations where infectious disease may result in recovery and death, the SIRD model or the SEIR model, in which those exposed to the virus are added to the equation, have

been developed. As a common result of the studies, it is seen that SIR models in the prediction of infectious diseases provide more realistic predictions the more customised they are according to the physical characteristics of the disease; the more the number of data, that is, the more information about the course of the disease over time, the more realistic and forward-looking predictions the model provides.

The Generalised Logistic, Richards, Tsouloris & Wallace, Gompertz and Blumberg models derived from the logistic function are examples of statistical models. These models that provide forecasts by creating growth curves from infectious disease data and are used especially in early-period forecasts.

The logistic model was first developed to model population growth.

$$C(t) = \frac{KC_0}{(K - C_0)e^{-rt} - C_0}$$

In the equation, $C(t)$ is the total number of cases, r is the growth rate or the intrinsic growth rate of the population, and K is the carrying capacity. That is, due to the structure of the model, growth will reach a saturation level over time, and the total number of cases will no longer increase. Here, C_0 is the number of cases at baseline, i.e. the population size. The point at which the population will eventually reach total capacity, the point at which the growth rate is maximised, is the $K/2$ point, which is the inflection point of total capacity. The generalised logistic growth model was first developed by Nelder in 1961.

$$\frac{dC}{dt} = rC^\alpha \left(1 - \left(\frac{C}{K}\right)^\beta\right)^\gamma$$

The exponential parameters α , β and γ are added to the model. Richards developed the Richards and Gompertz model, which bears his name, by improving the equation modelling plant growth rate considered by (Ludwig) von Bertalanffy (Richards, 1959).

$$\frac{dC}{dt} = rC \left(1 - \left(\frac{C}{K}\right)^\beta\right)$$

The Richards model is also a special version of the Generalised Logistic Model. In the studies, logistic group models present a more realistic presentation in the early stages of infectious diseases with relatively fewer data.

ARIMA model, Markov Chain and Grey Model are examples of time series analyses. The ARIMA model, developed by Box and Jenkins (1976), is a linear model that includes autoregressive (AR) and moving average (MA) models and is the most widely known and used time series forecasting model. The ARIMA model is a model that provides forecasts of the forecast with the lagged values of the epidemic variable. In ARIMA models, extreme changes in non-stationary observations can make the model more unstable.

Finally, machine learning models are widely used today. The prophet is a frequently used model, but also Random Forest, LSTM, and RNN are other machine learning prediction models. The Prophet model is a machine learning model developed by Facebook in 2018. The model consists of three different components. On the other hand, prophet model provides forecasting with a trend model that deals with non-periodic changes in the event and a model that includes seasonal and irregularly occurring (holiday) days in the equation of periodic changes. Since the Prophet model consists of both logistics and Fourier, it captures periodic waves in observations more easily. For this reason, it allows forecasting without the condition of stationarity of the data.

As a result of the examination of scientific studies, some strengths and weaknesses of the models emerge. The strengths of the SIR model are that it can be transformed according to the physical characteristics of the disease, the measures taken to prevent the epidemic can be added to the model, and it provides long-term healthy results with sufficient data. In addition, its assumptions, providing results with a large data set, and the high sensitivity of the estimators are presented as weaknesses. While the strength of the logistic model is that it provides forecasts with fewer parameters and data, its weakness is that it does not reflect the measures taken to prevent the epidemic and gives relatively higher

results in late-period forecasts. While the ability of the ARIMA model to construct seasonal and non-seasonal models is its strength, its sensitivity to non-stationary data is shown as its weakness. While the strengths of the Prophet model are that it captures seasonal and weekly periodic fluctuations, can add holidays to the model, and is robust to outliers and missing values, the difficulty of using the algorithm is identified as its weakness. In addition to the weaknesses of the models, differences in case definitions, inaccurate modelling, differences in testing protocol and capacity, insufficient data, reporting system, and differences in the timing of publication of data also affect the predictions negatively in obtaining the prediction results of infectious diseases, regardless of the selected models. As a result, the models provide policymakers with predictions under different conditions and guide policymakers with high-performance predictions that can be developed according to the stage, characteristics, recurring periods, and past values of the infectious disease.