



Journal of Turkish Operations Management

Amerika havayolu yolcu milinin LSTM ve AR modeli kullanılarak tahmini

Bülent Sezen¹, Nalan Yüce^{2*}

¹İşletme Bölümü, Sosyal Bilimler Enstitüsü, Gebze Teknik Üniversitesi, Kocaeli
e-mail: bsezen@gtu.edu.tr, ORCID No: <http://orcid.org/0000-0001-7485-3194>

²İşletme Bölümü, Sosyal Bilimler Enstitüsü, Gebze Teknik Üniversitesi, Kocaeli
e-mail: ciritnalan@gmail.com, ORCID No: <http://orcid.org/0000-0002-4538-0794>

*Sorumlu Yazar

Makale Bilgisi

Geliş: 14.12.2021
Revize: 08.09.2022
Kabul: 26.09.2022

Anahtar Kelimeler:

Havayolu yolcu mili,
LSTM modeli,
Zaman serileri

Özet

2019 yılında Çin'de ortaya çıkan Covid-19 salgını kısa sürede tüm Dünya'da yayılmıştır. Havayolu yolcu taşımacılığı da Covid-19 salgınından en yoğun etkilenen sektörlerden biridir. Havayolu yolcu mili metriği ile sektördeki hareketlilik ölçülebilmektedir. Bu çalışmada Amerika Birleşik Rezerv Ekonomik Veri (FRED) sisteminden alınan Amerika havayolu yolcu mili metriğine ait 2000 ile 2021 yılları arasında toplam 259 veri kullanılmıştır. Kullanılan veri setinin durağan özellik göstermediği ve mevsimselliğe sahip olduğu gözlemlenmiştir. Derin öğrenme metodlarından Tekrarlayan Sinir Ağlarının (RNN) Uzun Kısa Dönem Hafıza (LSTM) mimarisinin durağan olmayan veri seti ile çalışabilmesi ve mevsimsellik etkilerini hesaba katabiliyor olmasından ötürü bu çalışmada tercih edilmiştir. Covid-19 döneminde veri setinin eğiliminde meydana gelen ani değişimin LSTM mimarisinin performansına etkisini gözlemleyebilmek amacıyla hem Covid-19 dönemi verilerini içeren hem de içermeyen veri seti ile iki ayrı tahmin yapılmış ve sonuçlar kıyaslanmıştır. Bulgulara göre, Covid-19 dönemini içermeyen veri seti ile yapılan tahminlerde LSTM mimarisinin performansının çok daha yüksek olduğu görülmüştür. Aynı veri setinin Otoregresif Model (AR) ile de tahmini yapılmış ve sonuçlar kıyaslanmıştır. LSTM mimarisi ile 1960-2020 yılları arasında Türkiye'ye ait yolcu sayısı verileri ile tahmin yapılmıştır.

Estimation of American air passenger miles using the LSTM and AR Model

Article Info

Received: 14.12.2021
Revised: 08.09.2022
Accepted: 26.09.2022

Keywords:

Airline passenger mile,
LSTM model,
Time series

Summary

The Covid-19 epidemic, which emerged in China in 2019, spread all over the world in a short time. Air passenger transportation is one of the sectors most heavily affected by the Covid-19 epidemic. With the airline passenger mile metric, the mobility in the sector can be measured. In this study, a total of 259 data for the American airline passenger mile metric taken from the United Reserve Economic Data (FRED) system between 2000 and 2021 were used. It has been observed that the data set used does not show a static feature and has seasonality. Long Short-Term Memory (LSTM) architecture of Recurrent Neural Networks (RNN), which is one of the deep learning methods, was preferred in this study because it can work with non-stationary data set and can take seasonal effects into account. In order to observe the effect of the sudden change in the trend of the data set in the Covid-19 period on the performance of the LSTM architecture, two separate estimations were made with and without the Covid-19 period data, and the results were compared. According to the findings, it was seen that the performance of the LSTM architecture was much higher in the predictions made with the data set that did not include the Covid-19 period. The same data set was also estimated with the Autoregressive Model (AR) and the results were compared. With the LSTM architecture, estimations were made with the number of passengers in Turkey between the years 1960-2020.

1. Giriş

Covid-19 salgını 2019 Aralık ayından itibaren kısa sürede yayılarak, tüm Dünyada etkisini göstermiştir. Covid-19 ile en çok etkilenen sektörlerden birisi olan havayolu yolcu taşımacılığı bu çalışmada incelenmiştir. Havayolu yolcu mili verileri zamana bağlı değişen verilerdir. Zamana bağlı değişen veriler literatürde zaman serileri verileri olarak adlandırılmaktadır. Zaman serisi tahmini, aynı değişkenin geçmiş gözlemlerinin toplandığı ve altta yatan ilişkiyi tanımlayan bir model geliştirmek için analiz edildiği önemli bir tahmin alanıdır (Zhang, 2003). Son zamanlardaki gelişmeler ile zaman serileri tahmininde sık sık yapay sinir ağları kullanılmaktadır (Abbasimehr, Shabani ve Yousefi, 2020).

LSTM, derin öğrenme alanında kullanılan yapay bir Tekrarlayan Sinir Ağı (RNN) mimarisidir. Sıralı bir zaman serisi modeli oluşturmak için verimli bir algoritmadır (Luo, Zhang, Fu ve Rao, 2021). LSTM daha önceki verileri hafızaya alarak gelecek tahmini yapabilen bir mimardır (Chimmula ve Zhang, 2020). LSTM'ler, verilerin zamansal yönlerini modellemedeki doğal yeteneği nedeniyle makine çevirisi, dil modelleme, el yazısı tanıma, resim yazısı, konuşma tanıma, süreç tahmini ve tıbbi teşhiste yaygın olarak kullanılmaktadır (Somu, Raman ve Ramamritham, 2020). LSTM mimarisi literatürde farklı alanlarda kullanılarak zaman serisi tahminlerinde iyi bir yöntem olduğunu göstermiştir.

Tüm tahmin modelleri parametrik, parametrik olmayan ve hibrit modeller olarak sınıflandırılabilir. LSTM mimarisi parametrik olmayan modeller sınıfına girmektedir. Bu mimarinin diğer yöntemlere göre avantajları arasında arka plan için ön koşul gerektirmemesi, veriye dayalı otomatik prosedürler, durağan olmayan verileri iyi analiz etme, güçlü genelleme kapasitesi, karmaşık problemlerin çözümüne yakınsamadaki başarısı sayılabilir. Dezavantajları arasında da aşırı uydurma, yerel optimumlara kolayca düşme, kapsamlı veri gerektirmesi sayılabilir (Cao, Sun ve Li, 2021). Avantajları göz önünde bulundurularak bu çalışmada LSTM modeli kullanılmıştır.

Daha önce Choi ve Kim (2021) en yoğun havalimanlarından biri olan Hartsfield–Jackson Atlanta Uluslararası Havalimanı'nın (ATL) saatlik kalkış ve varış kapasitesini tahmin etmek için yapay sinir ağı algoritmaları (MLP, RNN ve LSTM) kullanmıştır. Tahmin için kurulan modeller, havalimanının 1 Ocak 2013 ile 31 Aralık 2017 arasında saatlik kapasite ve hava durumu verileri kullanılarak eğitilmiştir. Brown ve Kline (2020) yaptıkları çalışmada Amerikan havayolu sektörünün gelecek tahmininde dış faktörler karşısında yetersiz kaldıklarını ve Covid-19 salgınında da başarısız süreç yönetimi yaptıklarını göstermiştir. Hotle ve Mumbower (2021) Covid-19 döneminde Amerika havalimanlarındaki operasyonlarının nasıl etkilendiğini incelemiş, Mayıs 2020'deki uçuşların 2019 uçuşlarına göre %70 azaldığını göstermiştir.

Literatür incelediğinde ani değişimlerde havayolu sektörünün hazırlıksız yakalandığı ve büyük kayıplara uğradığı görülmektedir. Bu doğrultuda geleceğe yönelik tahmin metotları ile veriler incelenerek havayolu sektöründe gelecek projeksiyonunun daha iyi yapılması mümkün kılınabilir ve sektörün uğradığı hasar minimuma indirilebilir.

Bu çalışmada da LSTM mimarisinin Amerika havayolu yolcu milinde tahmin performansı incelenerek havayolu sektöründe gelecek projeksiyonu yapılması için doğru yöntemlerin bulunmasına destek sağlanmıştır. Veri seti Amerika Birleşik Rezerv Ekonomik Veri (FRED) sisteminden alınmıştır. FRED 96 kaynak ve 765.000'den fazla ekonomik zaman serisine sahip St. Louis Federal Rezerv Bankası'nın Araştırma bölümü tarafından sağlanan bir veri tabanıdır. 2000 ve 2021 yılları arasındaki Amerika havayolu yolcu mili sayısına ait 259 veri, bu çalışma kapsamında incelenmiştir. Havayolu yolcu mili, toplam uçulan mil ile toplam yolcu sayısının çarpımı ile elde edilir. Havayolu yolcu taşımacılığı için önemli bir metriktir. Bu çalışmada Covid-19 etkisindeki havayolu sektörü yapay sinir ağlarından LSTM mimarisi aracılığıyla incelenmiştir. Havayolu yolcu mili verisi yukarı yönde artış trendi göstermektedir. Yılın belli dönemlerinde artış belli dönemlerinde azalış göstermesiyle de mevsimsel etkiler barındırmaktadır. Veri seti Augmented Dickey-Fuller test ile analiz edilmiş, p değeri 0,97 olarak hesaplanmış ve durağan olmadığı görülmüştür. Mevsimsel ayrıştırma (decompose) ile veri ayrıştırılıp trend, mevsimsellik ve artık değerlerin grafikleri çizdirilmiştir. Bu grafikler sayesinde veri doğru yorumlanarak kurulacak modele temel oluşturulmuştur.

Covid-19 dönemini içeren ve Covid-19 dönemini içermeyen veri seti incelenerek gelecek bir yıla ait tahmin yapılmış ve sonuçlar kıyaslanmıştır. Çalışmanın amacı zaman serilerinde ani değişimlerde LSTM mimarisinin performansını incelemektir. RMSE değerleri Covid-19 dönemini içeren veri setinde $4,84E+07$ olarak, Covid-19 dönemini içermeyen veri setinde $2,3E+6$ olarak hesaplanmıştır. Buradan açıkça görülmektedir ki veri setinde ani değişim olduğunda LSTM mimarisinin başarı performansı büyük oranda düşmektedir. AR modeli ile de veri setinde tahmin yapılmış ve sonuçlar LSTM mimarisi ile kıyaslanmıştır. Daha başarılı sonuçlar veren LSTM mimarisi ile Türkiye için de yolcu sayısı tahmini yapılmıştır.

Çalışmanın devamında havayolu sektörüne ve zaman serileri tahmin yöntemlerine ilişkin literatüre, üçüncü bölümde yöntem, dördüncü bölümde problem uygulamasına ve beşinci bölümde ise sonuç kısmına yer verilmiştir.

2. Bilimsel Yazın Taraması

Yapılan çalışma Amerika havayolu yolcu mili sayısının gelecek dönem tahmini üzerine yoğunlaşmıştır. Literatürde birçok farklı yöntem ile zaman serileri analizi yapılmış ve geleceğe yönelik tahminlerde başarı gösterilmiştir.

Yang, Tang, Zeng, Lu ve Zhang (2021) yaptıkları çalışmada hava sahası yoğunluk indeksi tahmini için yeni bir model geliştirmiştir. Regresyon modelleri için, grafik evrişim ve LSTM mimarisi, uzay-zamansal özellik çıkarma ve hava sahası yoğunluk indeksi tahmini için entegre edilmiştir. Sınıflandırma modelleri için, XGBoost yöntemi ayrıca hava sahası yoğunluğu tanımlaması için dahil edilmiştir. Karami ve Kashef (2020) akıllı ulaşım planlaması için zaman serileri tahmininde derin öğrenme, ARIMA, Holt Winters' Exponential Smoothing gibi yöntemleri kıyaslamıştır. Gelecek yıllarda akıllı ulaşım planlamasında kullanılabilir çeşitli veri kaynakları, kurulabilecek modeller ve yeni iş fırsatları çalışma kapsamında belirtilmiştir. Bi, Li ve Fan (2021) yaptıkları çalışmada görüntü işlemede derin öğrenmenin faydalarından yararlanarak turizmde talep tahmini için farklı modeller kurarak kıyaslama yapmıştır. LSTM ve Evrişimli Sinirsel Ağ (CNN) yöntemleri birlikte kullanılarak, görüntü işleme de talep tahmini konusuna dahil edilmiştir. Cao, Sun ve Li (2021) yüksek hızlı tren taşımacılığı için talep tahmini yaparken artık bileşen imhasına dayalı olarak deterministik ve olasılıksal tahmin kapasitelerine sahip yeni bir sistem sunmaktadır. Abdar, Pourpanah, Hussain, Rezazadegan, Liu, Ghavamzadeh, Fieguth, Cao, Khosravi, Acharya, Makarenkov ve Nahavandi (2021) yaptıkları çalışmada derin öğrenmede belirsizliklerin nicelleştirilmesi için literatür taraması yapmış, teknikleri, uygulamaları ve zorlukları değerlendirmiştir. Alassafı, Jarrah ve Alotaibi (2021) yaptıkları çalışmada Malezya, Morokko ve Suudi Arabistan'daki Covid-19 vakalarının tahminini LSTM ve RNN yöntemleri ile yapmış ve sonuçları kıyaslamıştır. LSTM mimarisi ile çok daha doğru sonuçlar ortaya çıkartılmıştır. Hanson, Delibasi, Gatti ve Cohen (2021) ekonomik aktivitelerdeki değişikliklerin havayolu yolcu trafiğini nasıl etkilediğini incelemiştir. Kazanç ve havayolu taşımacılığı talebinin arasındaki nedensellik araştırılmıştır. Otoregresif dağıtılmış gecikmeler (ARDL) sınır testi ile kısa-uzun vadeli gelir esnekliklerinin talebe etkisi üzerine çalışılmıştır. Singh (2021) yaptığı çalışmada havayolu taşımacılığına duyulan bağlılığı literatürde bulunan etmenler aracılığıyla tahmin etmek için model geliştirmiştir. Havayolu yolcularından anket çalışmasıyla veri toplanmış ve yapay sinir ağları teorisi ile kıyaslamasını yapmıştır. Truong (2021) sinir ağları ve Monte Carlo simülasyonunu kullanarak Covid-19'un havayolu taşımacılığının orta ve uzun vadeli tahmini üzerine çalışmıştır. Grosche ve diğ. (2007) havayolu yolcu talebinin tahmini için ağırlık (gravity) modelini kullanmıştır. Modelde havayolu hizmet değişkenleri yerine uçulan şehirlerin genel ekonomik faaliyetlerini ve coğrafi özelliklerini değerlendirilmiştir. Solvoll, Mathisen ve Welde (2020) Norveç havalimanlarındaki hava trafiğini tahmin etmek üzere farklı modeller denemiş ve kıyaslamasını yapmıştır. Değişkenlik, analogi ve taşıma yöntemleri ile tahmin yapılarak ekonomik yararları kıyasla bölgesel etkilerin daha önemli olduğu vurgulanmıştır. Analogi yöntemlerinin esneklik yaklaşımına dayalı daha geleneksel yöntemlerden daha uygun olduğu görülmüştür. Iacus, Natale, Santamaria, Spyrtos ve Vespe (2020) Covid-19 dönemindeki havayolu yolcu trafiğini incelemiş ve gelecek dönem tahmini yapmıştır. 2010 yılından 2019 yılına o kadar olan havayolu verisi homojen olmayan Poisson süreci ile işlenmiş ve 2020 yılı için tahmin yapılmıştır. İç ve Civelek (2021) yaptıkları zaman serileri analizinde etmensel deney tasarım yöntemi ile gayrisafi yurtiçi hasılasının tahmini üzerinde çalışmıştır. Ünsal ve Kasap (2020) zaman serisi ve küme analizi kullanarak G20, AB ve OECD ülkelerindeki Covid-19 vakalarını incelemiştir. İncekara (2020) Türkiye doğalgaz talep tahmini için yaptığı çalışmada bulanık Analitik Hiyerarşik Proses ve TOPSIS modellerini kullanmıştır.


Tüm bu çalışmalar incelendiğinde havayolu taşımacılığının ileriye dönük projeksiyonunun tahminin kritik öneme sahip olduğu görülmüştür. Bu noktada da LSTM yöntemi ile başarılı tahmin sonuçları elde edilmeye çalışılmış ve havayolu sektörünün büyük zararlara uğramadan krizleri atlmasına destek olacak modeller geliştirilmiştir.

3. Yöntem

Derin öğrenme teknikleri makine öğrenimini, insan beyninin sinir ağlarından esinlenerek, makinelerin görevleri ayırt etmeyi öğrenebileceği yepyeni bir düzeye taşımıştır. Yapay sinir ağları insan beyninin çalışma prensibini taklit eder. Bu noktada yapılan hesaplamalar derin öğrenme kavramını ortaya çıkarmıştır. Derin öğrenmenin çıkış noktası algoritmalara dayalı sinir ağlarına bir matematiksel model oluşturulmasıdır.

Derin öğrenme yöntemlerinde tahmin yapmak için çeşitli mimarilerden faydalanılmaktadır. Bunlardan biri de LSTM mimarisidir. LSTM hafızasını kullanarak zaman serisi verilerinin tahmininde kullanışlıdır. LSTM mimarisi Tekrarlayan Sinir Ağları (RNN) modelinden türetilmiştir. LSTM mimarisinde, RNN'deki standart ileri beslemeli bağlantılara ek olarak, ünitelerde geri besleme bağlantıları bulunur.

Bir LSTM birimi, Şekil 1'de de görüleceği üzere bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısından oluşur. Hücre keyfi zaman aralıklarında değerleri hatırlar ve bu üç kapı hücreye giren ve çıkan bilgi akışını düzenler (Karami ve Kashef, 2020).



Şekil 1. LSTM yapısı

Aşağıda 1 numaralı denklemde, hücreye hangi bilgilerin aktarılması gerektiğini belirleyen giriş kapısının matematiksel ifadesi gösterilmektedir:

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (1)$$

Aşağıdaki 2 numaralı denklemde, hangi bilgilerin ihmal edileceğini belirleyen unutma kapısının matematiksel ifadesi gösterilmektedir.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2)$$

Güncelleme kapısı, aşağıdaki 3 ve 4 numaralı denklemlerle matematiksel olarak ifade edilen hücre durumunu günceller:

$$\tilde{c}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (4)$$

Çıkış kapısı, çıkışın güncellenmesinden ve önceki zaman adımının gizli katmanını güncellemekten sorumludur. Matematiksel ifade aşağıdaki 5 ve 6 numaralı denklemlerde gösterilmektedir:

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

Regresyon modeli için ortalama kare hatası üzerinde kayıp fonksiyonu olarak L2 düzenleme yöntemi uygulanmaktadır. Kayıp fonksiyonun matematiksel gösterimi 7 numaralı denklemde:

$$Loss_1 = \frac{1}{n} \sum_{i=1}^n (y_i' - y_i)^2 + \lambda \sum_k w_k^2 \quad (7)$$

BuHata! Başyuru kaynağı bulunamadı. numaralı denklemde y_i ve y_i' değerleri tahmin edilen ve gerçek değerleri, λ toplam kayıptaki düzenleme oranını, w ise regresyon modelinin eğitilebilir ağırlıklarıdır. Kurulan modelin tahmin performansı RMSE değeri hesaplanarak incelenebilmektedir. 8 numaralı denklemde RMSE değerinin matematiksel ifadesi görülmektedir. y_i ve y_i' değerleri tahmin edilen ve gerçek değerleri, n değeri örneklem büyüklüğünü göstermektedir.


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (8)$$

Bu çalışma kapsamında derin öğrenme mimarisi LSTM, zaman serilerinin incelenmesinde kullanılmıştır. Veri seti Amerika Birleşik Rezerv Ekonomik Veri (FRED) sisteminden alınmış olup Amerika Hava yolu Yolcu Mili'nin 2000 ve 2021 yılları arasında kapsamaktadır. Öncelikli olarak veri setinin trend ve mevsimsellik durumları incelenmiştir. Covid-19 salgını sebebiyle yolcu milindeki ani değişimin LSTM mimarisi üzerindeki değişimini incelemek için veri seti ikiye ayrılmıştır. Birinci uygulamada veri seti Covid-19 dönemini içeren şekilde, ikinci uygulamada Covid-19 dönemini içermeyen şekilde incelenmiştir. Her bir uygulamada son 12 ay test verisi olarak kullanılmıştır. Aylık bazlı değişen yolcu mili sayısı bu sayede iki farklı uygulama ile incelenmiştir. Veri setinin ilk 5 ayı Tablo 1'de görülmektedir. Her ay için toplam yolcu mili sayısı tabloda görülmektedir.

Tablo 1. Genel veri seti-Amerika


Ay	Yolcu mili (e+4)
2000-01-01	49843099
2000-02-01	49931931
2000-03-01	61478163
2000-04-01	58981617
2000-05-01	61223861

Veri setindeki özellikler ve değerleri Şekil 2, Şekil 3 ve Şekil 4'te görülmektedir. Şekil 2'de Covid-19 dönemini içeren yolcu mili veri seti aylık periyotlarla gösterilmiştir.




Şekil 2. Covid-19 dönemini içeren veri seti-Amerika

Şekil 3'te bu veri setine ait trend grafiği sunulmuştur. Trend grafiği incelendiğinde 2001-2002 yıllarında ve 2008-2009 yıllarında artan trendin yavaşladığını hatta azaldığını görüyoruz. Bu durumun o yıllarda yaşanan global ekonomik krizlerle ilgili olduğu düşünülmektedir. 2020 yılında görülen sert düşüş ise bu çalışmanın temelini oluşturmaktadır.



Şekil 3. Verinin trend grafiği

Şekil 4’te de veri setinin mevsimsellik grafiği görülmektedir. Mevsimsellik grafiğinde görüldüğü üzere veride bir döngüsellik söz konusudur. Veri seti incelendiğinde yaz aylarında yolcu milinde artış gözlemlenmiştir.



Şekil 4. Verinin mevsimsellik grafiği

AR modeli de genel tahmin modelleri kapsamında kullanılan bir yöntemdir. Bir otoregresyon modelinde, değişkenin geçmiş değerlerinin doğrusal bir kombinasyonu kullanılarak tahmin yapılır. AR modeli çoklu regresyon modelinde olduğu gibi bağımlı bir değişken ile bu değişkeni açıklayan bağımsız değişkenler arasındaki ilişkiyi ortaya koyan bir model olmayıp, aynı değişkenin belirli bir t dönemine ilişkin gözlem değeri ile ondan önceki dönemlere ait gözlem değerleri arasındaki ilişkiyi açıkladığı için çoklu regresyon modelinden ayrılır ve “otoregresif model” adını alır. Uygulamada da sıkça kullanılan bir yöntem olması sebebiyle bu çalışma kapsamında tercih edilmiştir. Otoresgresyon terimi, değişkenin kendisine karşı bir regresyonunu tanımlar. p düzeyindeki bir dizi gecikmeli değere karşı bir otoregresyon çalıştırılır.

Aşağıdaki 9 nolu denklemde c değeri sabiti, ϕ_1 ve ϕ_2 değerleri p mertebesine kadar olan gecikme katsayılarını, ε_t değeri ise beyaz gürültüyü göstermektedir.

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (9)$$

Örneğin bir AR(1) modeli aşağıdaki 10 numaralı denklemdeki gibi ifade edilebilmektedir.

$$y_t = c + \phi_1 y_{t-1} + \varepsilon_t \quad (10)$$

AR(2) modeli ise aşağıdaki 11 numaralı denklemdeki gibi ifade edilebilmektedir. Denklemler bu şekilde devam etmektedir.

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t \quad (11)$$

Genellikle otoregresif modelleri durağan verilerle sınırladığımız için gecikme katsayılarının genellikle birden küçük olduğuna dikkat edilmesi gereklidir. Örneğin AR(1) modelinde 12 numaralı denklem sağlanmalıdır.

$$-1 < \phi_1 < 1 \quad (12)$$

AR(2) modelinde ise 13 numaralı denklem gerekli şartları belirtmektedir.

$$-1 < \phi_2 < 1, \phi_1 + \phi_2 < 1, \phi_2 - \phi_1 < 1 \quad (13)$$


AR(3) modeli matematiksel olarak çok daha karışık ifade edilmektedir fakat mevcut istatistik modelleri tüm bu matematiksel hesaplamaları yapabilmektedir.

LSTM ve AR modelinin tahmin performansları kıyaslandıktan sonra Türkiye için de Devlet Hava Meydanları İşletmesi Genel Müdürlüğü, Sivil Havacılık Genel Müdürlüğü'nden alınan 1960-2020 yılları arasındaki yıllık havayolu yolcu sayısı verilerine göre tahmin yapılmıştır. Birinci uygulamada veri seti Covid-19 dönemini içeren şekilde, ikinci uygulamada Covid-19 dönemini içermeyen şekilde incelenmiştir. Her bir uygulamada son 12 yıl test verisi olarak kullanılmıştır. Veri setinin ilk 5 yılı Tablo 2'de görülmektedir.

Tablo 2. Genel veri seti-Türkiye

Yıl	Yolcu Sayısı
1960-12-31	713217
1961-12-31	788636
1962-12-31	729996
1963-12-31	821489
1964-12-31	842841

Şekil 5'te de 60 yıla ait Türkiye havayolu yolcu sayısı grafiği görülmektedir. Yolcu sayısındaki artış trendi grafikte açıkça görülmektedir.



Şekil 5. Türkiye havayolu yolcu sayısı grafiği


4. Bulgular ve Tartışma

Bu çalışmada, LSTM mimarisi ile 2000-2021 yılları aralığından oluşan Amerika havayolu yolcu mili zaman serisi verilerinin tahmini yapılmış ve AR modeli ile sonuçlar kıyaslanmıştır. Türkiye havayolu yolcu sayısı için de LSTM mimarisi ile tahmin çalışması yürütülmüştür. LSTM mimarisi ile zaman serisi verilerinin analizine yönelik literatürde çalışmalar mevcuttur. Bu çalışmada Python programlama diliyle Pandas, Numpy, Matplotlib, Stasmodels, Sklearn, Keras ve TensorFlow kütüphaneleri kullanılmıştır. Amerika Kurulan LSTM modeli tek katmanlı olup 150 nörondan oluşmakta ve çıkış katmanında tek bir çıkışı bulunmaktadır. Oluşturulan LSTM mimarisi aşağıdaki Tablo 3'te gösterilmiştir.


Tablo 3. Oluşturulan LSTM mimarisi-Amerika

Model: "sequential"		
Layer (type)	Output Shape	Param #
Lstm (LSTM)	(None, 150)	91200
Dense (Dense)	(None, 1)	151
Total params	91,351	
Trainable params	91,351	
Non-trainable params	0	

Amerika havayolu yolcu mili değerleri Covid-19 dönemini içeren ve Covid-19 dönemini içermeyen veri seti için 25 epoch ve 1 batch size değerleri kullanılarak eğitilmiştir. Bu parametre değerlerine göre sonuçlar aşağıdaki grafiklerde gösterilmiştir. Şekil 6'da görüldüğü üzere ilk 10 epoch değerine kadar hata dramatik olarak azalmakta fakat sonrasında büyük bir değişiklik göstermemektedir. Yani epoch sayısının daha fazla arttırılmasının modelin doğruluğu üzerinde fark edilir olumlu bir etkisi olmayacaktır.

**Şekil 6.** Covid dönemi hariç modelin loss değerleri

Şekil 7'de Covid dönemini kapsamayan veri seti ile yapılan tahmin sonuçları gösterilmiştir. Grafikte mavi çizgi orijinal veriyi gösterirken, turuncu çizgi ise tahmin sonucunu göstermektedir. Yapılan tahminin gerçek veriye paralel ve yakın sonuçlar verdiği anlaşılmaktadır.

**Şekil 7.** Covid dönemi hariç modelin tahmini-Amerika


Şekil 7'yi oluştururken kullanılan tahmin ve test verileri Tablo 4'te aşağıda paylaşılmıştır.

Tablo 4. Covid dönemi hariç modelin tahmin değerleri-Amerika

Ay	Yolcu mili(e+4)	Tahminler
2019-03-01	90478107	8.791079e+07
2019-04-01	86684142	8.680529e+07
2019-05-01	92977220	9.273014e+07


2019-06-01	98273616	9.974016e+07
2019-07-01	102295052	1.046480e+08
2019-08-01	98411628	1.009051e+08
2019-09-01	83814263	8.635440e+07
2019-10-01	88208329	8.969266e+07
2019-11-01	81010197	8.505415e+07
2019-12-01	90389595	8.695119e+07
2020-01-01	81537477	8.147397e+07
2020-02-01	74428909	7.633474e+07

Tablo 3'te gösterilen LSTM mimarisi Covid-19 dönemini de içeren veri seti için tekrar kullanılmıştır. Bu çalışma da 25 epoch değeri kullanılarak gerçekleştirilmiştir. Şekil 8'de de görüldüğü gibi ilk 10 epoch değerine kadar hata değeri hızlı bir düşüş göstermekte sonrasında bu düşüş azalmaktadır. Fakat Covid-19 dönemini içermeyen veri setinde olduğu gibi düzgün bir azalış eğilimi göstermediği saptanmıştır.



Şekil 8. Covid dönemi dahil modelin kayıp değerleri-Amerika

Şekil 9'da Covid-19 veri setini içeren modelin yaptığı tahminlerin gerçek veri ile karşılaştırmalı grafiği sunulmuştur. Mavi çizgi orijinal veriyi göstermekte iken, turuncu çizgi yapılan tahmini göstermektedir. Grafikte orijinal veri ile tahmin edilen veri arasında ciddi farklar olduğu görülmektedir.



Şekil 9. Covid dönemi dahil modelin tahmini-Amerika

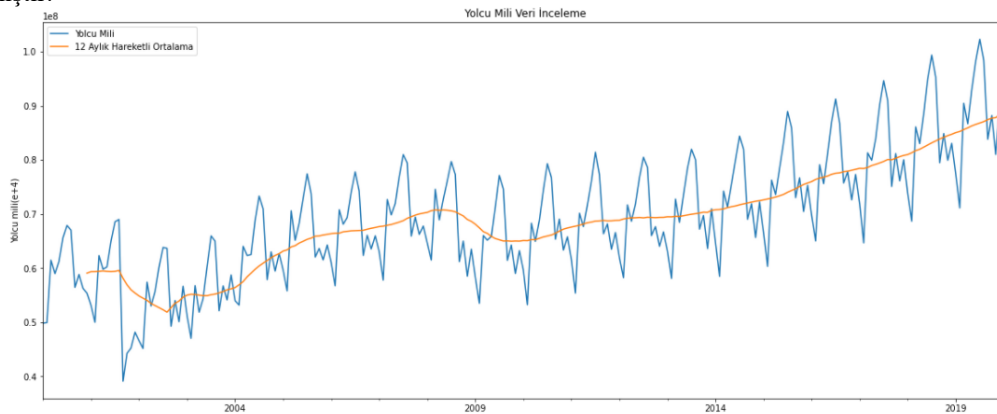
Şekil 9'u oluştururken kullanılan tahmin ve test verileri Tablo 5'te aşağıda paylaşılmıştır.

Tablo 5. Covid dönemi dahil modelin tahmin değerleri-Amerika

Ay	Yolcu mili(e+4)	Tahminler
2020-08-01	23886437	4.901438e+07
2020-09-01	23384462	6.787354e+07
2020-10-01	28273454	9.003389e+07


2020-11-01	28292601	9.921048e+07
2020-12-01	31081758	1.095932e+08
2021-01-01	28114490	1.027146e+08
2021-02-01	26550396	9.321919e+07
2021-03-01	42982241	7.896106e+07
2021-04-01	48137353	6.956822e+07
2021-05-01	58172779	6.367094e+07
2021-06-01	68903179	5.953058e+07
2021-07-01	78610304	5.676194e+07

AR modeli, ilk olarak Covid-19 dönemini içermeyen veri setinde maksimum olabilirlik (mle) yöntemi aracılığıyla çalıştırılmış ve farklı gecikme (lag) değerleri ile tahmin yapılmıştır. Test değerleri için son 1 yıllık veri kullanılmıştır. Bu tahminden önce de Şekil 10'da görüleceği üzere 12 aylık hareketli ortalama ile veri incelenmiştir.




Şekil 10. Covid dönemi hariç-12 aylık hareketli ortalama

Maksimum gecikme değeri 1 ve 2 olarak model çalıştırılmış ardından da T-istatistiği aracılığıyla model çalıştırıldığında maksimum gecikme değeri 14 olarak görülmüştür. Şekil 11'de de görüleceği üzere mavi renkli çizgi ana veri setini, kırmızı renkli çizgi maksimum gecikme değeri 14 olan modelin tahminini, yeşil renkli çizgi maksimum gecikme değeri 2 olan modelin tahminini, turuncu renkli çizgi de maksimum gecikme değeri 1 olan modelin tahminini göstermektedir. Test verisine en yakın sonucun maksimum gecikme değeri 14'te olduğu görülmektedir.




Şekil 11. Covid dönemi hariç modellerin tahmin değerleri

AR modeli, ikinci olarak Covid-19 dönemini içeren veri setinde maksimum olabilirlik (mle) yöntemi aracılığıyla çalıştırılmış ve farklı gecikme (lag) değerleri ile tahmin yapılmıştır. Test değerleri için son 1 yıllık veri kullanılmıştır. Şekil 12'de Covid döneminin dahil edildiği veri setinin 12 aylık hareketli ortalaması incelenmiştir.



Şekil 12. Covid dönemi dahil-12 aylık hareketli ortalama

Maksimum gecikme değeri 1 ve 2 olarak model çalıştırılmış ardından da T-istatistiği aracılığıyla model çalıştırıldığında maksimum gecikme değeri 14 olarak görülmüştür. Şekil 13'te görüleceği üzere görüleceği üzere mavi renkli çizgi ana veri setini, kırmızı renkli çizgi maksimum gecikme değeri 14 olan modelin tahminini, yeşil renkli çizgi maksimum gecikme değeri 2 olan modelin tahminini, turuncu renkli çizgi de maksimum gecikme değeri 1 olan modelin tahminini göstermektedir. Maksimum gecikme değeri 14'te test verisi ile büyük farklar mevcuttur.




Şekil 13. Covid dönemi dahil modellerin tahmin değerleri

Türkiye'ye ait havayolu yolcu sayısı Covid-19 dönemini içeren ve Covid-19 dönemini içermeyen 2 ayrı veri seti olarak, 25 epoch ve 1 batch size değerleri kullanılarak eğitilmiştir. Tablo 6'da görüleceği üzere kurulan LSTM modeli tek katmanlı olup 150 nörondan oluşmakta ve çıkış katmanında tek bir çıkışı bulunmaktadır. Şekil 14'te Covid-19 dönemini içermeyen veri seti kullanılarak son 12 aya ait tahmin değerleri ve test verileri görülmektedir. Mavi renkli çizgi orijinal veriyi, turuncu renkli çizgi tahmin değerlerini göstermektedir. 2016 yılına kadar modelin tahmin performansı iyi görünmektedir fakat sonrasında hata değeri artmıştır. Modelin RMSE değeri $7E+7$ olarak hesaplanmıştır.

Tablo 6. Oluşturulan LSTM mimarisi-Türkiye

Model: "sequential"		
Layer (type)	Output Shape	Param #
Lstm (LSTM)	(None, 100)	40800
Dense (Dense)	(None, 1)	101
Total params	40,901	
Trainable params	40,901	
Non-trainable params	0	




Şekil 14. Covid dönemi hariç modelin tahmini-Türkiye

Şekil 14'teki grafiği oluşturan tahmin ve test verileri Tablo 7'de görülmektedir.

Tablo 7. Covid dönemi hariç tahmin değerleri-Türkiye

Yıl	Yolcu Sayısı	Tahminler
2008-12-31	79438289	6.812055e+07
2009-12-31	85508508	7.434765e+07
2010-12-31	102800392	8.179747e+07
2011-12-31	117620469	9.102095e+07
2012-12-31	130351620	1.031828e+08
2013-12-31	149430421	1.186354e+08
2014-12-31	165720234	1.393961e+08
2015-12-31	181074531	1.676995e+08
2016-12-31	173743537	2.079297e+08
2017-12-31	193045343	2.658534e+08
2018-12-31	210498164	3.554585e+08
2019-12-31	208373696	5.104146e+08

Şekil 15'te Covid-19 dönemini içeren veri seti kullanılarak son 12 aya ait tahmin değerleri ve test verileri görülmektedir. Mavi renkli çizgi orijinal veriyi, turuncu renkli çizgi tahmin değerlerini göstermektedir. 2015 yılına kadar modelin tahmin performansı iyi görünmektedir fakat sonrasında hata değeri artmıştır. Modelin RMSE değeri $7,92E+8$ olarak hesaplanmıştır.



Şekil 15. Covid dönemi dahil modelin tahmini-Türkiye

Şekil 15'teki grafiği oluşturulan tahmin ve test verileri Tablo 8'de görülmektedir.

Tablo 8. Covid dönemi dahil tahmin değerleri-Türkiye

Yıl	Yolcu Sayısı	Tahminler
2009-12-31	85508508	8.941111e+07
2010-12-31	102800392	1.029353e+08
2011-12-31	117620469	1.215132e+08
2012-12-31	130351620	1.506113e+08
2013-12-31	149430421	1.948479e+08
2014-12-31	165720234	2.704819e+08
2015-12-31	181074531	4.129901e+08
2016-12-31	173743537	7.162584e+08
2017-12-31	193045343	1.388102e+09
2018-12-31	210498164	2.807325e+09
2019-12-31	208373696	5.669789e+09
2020-12-31	81616140	1.153224e+10

5. Sonuç

Bu çalışma ile derin öğrenme yaklaşımlarından LSTM mimarisi kullanılarak Covid-19 etkisindeki Amerika havayolu yolcu mili değerinin tahmini için bir model geliştirilmiştir. Geliştirilen modelde 2000 yılından 2021 yılına kadar olan veriler kullanılmış olup Covid-19 etkisinde LSTM mimarisinin çalışma performansı incelenmiştir. Kullanılan Amerika havayolu yolcu mili Covid dönemi dahil edilen veri 259 satırdan oluşmakta, $6,68E+7$ ortalama değerine ve $1,5E+7$ standart sapma değerine sahiptir. Diğer yandan Amerika havayolu yolcu mili Covid dönemi hariç tutulan veri 242 satırdan oluşmakta, $6,91E+7$ ortalama değerine ve $1,14E+7$ standart sapma değerine sahiptir. Türkiye için yolcu mili verilerine ulaşamamış olup, bunun yerine benzer nitelikli 1960 yılından 2020 yılına kadar olan yolcu sayısı verisi kullanılmıştır. Türkiye için Covid dönemi dahil edilen veri 61 satırdan oluşmakta, $4,29E+7$ ortalama değerine ve $5,95E+7$ standart sapma değerine sahiptir. Bunun yanında Covid dönemi hariç tutulan veri 60 satırdan oluşmakta, $4,22E+7$ ortalama değerine ve $5,98E+7$ standart sapma değerine sahiptir. Amerika'ya ait veriler aylık bazda olup, Türkiye'ye ait veriler ise yıllık bazdadır. Aylık çözünürlüğe sahip veri sayesinde Amerika için mevsimsel etkilerin de hesaba katılma fırsatı bulunmuş, fakat yıllık çözünürlükte olan Türkiye verisi için bu mümkün olmamıştır. Türkiye verisinin yıllık bazda olması daha az gürültüye sahip bir veri olmasını da sağlamıştır. Şekil 2 ve Şekil 5 kıyaslandığında bu durum açıkça görülmektedir. Amerika'ya ait veriler 2000 yılından itibaren başlamakta olup, Türkiye'ye ait veriler ise 1960 yılından başlamaktadır.

LSTM haricinde farklı bir model ile karşılaştırma amacıyla AR modeli ile de tahmin yapılmış ve bulgular LSTM ile elde edilen sonuçlar ile kıyaslanmıştır. Performansı yüksek olan LSTM mimarisi ile Türkiye havayolu yolcu sayısı için de tahmin yapılmıştır. LSTM ile yapılan çalışmada modelin performans metriği olarak ortalama kare hata (MSE) seçilmiş olup tek katmanlı 150 nörondan oluşan bir mimari kullanılmıştır. AR modeli ise maksimum olabilirlik yöntemi ile kurulmuş olup 14 maksimum gecikme sayısına sahiptir.



Amerika havayolu yolcu mili, LSTM mimarisi ile yapılan çalışma sonuçlarına göre Covid-19 dönemini içeren veri setinde kök ortalama kare hata (RMSE) değeri $4,84E+7$ olarak hesaplanmıştır. Covid-19 dönemini içermeyen veri setinde ise, kök ortalama kare hata (RMSE) değeri $2,3E+6$ olarak hesaplanmıştır. Veriler açıkça göstermektedir ki LSTM mimarisi ani değişimlerde düşük performans sergilemektedir.

Geçmiş verilerle eğitilen LSTM mimarisi trend ve mevsimsellik etkisi gösteren veri setlerinde yüksek performans sergileyerek, Covid-19 dönemini içermeyen Amerika Havayolu Yolcu Mili örneğinde olduğu gibi başarılı tahminler yapabileceğini kanıtlamıştır.

AR modeli ile yapılan çalışma sonuçlarına göre Covid-19 dönemini içeren veri setinde 14 maksimum gecikme sayısında kök ortalama kare hata (RMSE) değeri $1,2E+15$, Covid-19 dönemini içermeyen veri setinde ise RMSE değeri $2,6E+6$ olarak hesaplanmıştır. Tablo 9'da da görüleceği üzere, Covid-19 dönemini içeren ve içermeyen 2 ayrı veri setinde de LSTM modeli çok daha iyi sonuç vermiştir. Türkiye havayolu yolcu sayısı verileri için çalıştırılan LSTM mimarisi RMSE değerleri çok daha yüksek çıkmıştır. Veri sayısının az olması burada etken olmuştur.

Tablo 9. Yapılan tahminlerin Kök Ortalama Kare Hata değerleri

RMSE Değerleri	LSTM mimarisi	AR modeli
Covid Dönemi Hariç Veri Seti	2,3E+6	2,6E+6
Covid Dönemi Dahil Veri Seti	4,84E+7	1,2E+15

Tablo 10. LSTM ve AR modellerinin RMSE değerleri kıyaslaması-1**Tablo 11.** LSTM ve AR modellerinin RMSE değerleri kıyaslaması-2

Gelecek çalışmalarda veri setlerinde ani değişimlerde hangi derin öğrenme yaklaşımlarının başarılı olacağını araştırılması önerilmektedir. Farklı mimariler denenerek en yüksek performansı sergileyen yöntem ortaya çıkartılabilir. Hiper parametre optimizasyonu yapılarak mevcut veri seti için en uygun parametreler belirlenebilir. Buna ek olarak mevcut veri setini etkileyebilecek dış faktörler ile karşılaştırmalı, aynı anda birden fazla girdi kullanılarak da analizler yapılarak modeller zenginleştirilebilir.

Araştırmacıların Katkısı

Bu çalışmada; Nalan Yüce, problem verilerinin elde edilerek problemin çözülmesi, bilimsel yayın araştırması ve makalenin oluşturulması; Bülent Sezen, problem çözüm sürecinin takibi, kontrolü ve makalenin hazırlanması konularında katkı sağlamışlardır.

Çıkar Çatışması

Bu makalenin yazarları arasında herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

Abbasimehr, H., Shabani & M., Yousefi, M. (2020). An optimized model using LSTM network for demand forecasting. *Computers & Industrial Engineering*, 143 (2020), 106435. Doi: <https://doi.org/10.1016/j.cie.2020.106435>

Abdar, M., Pourpanah, F., Hussain, S., Rezazadegan, D., Liu, L., Ghavamzadeh, M., Fieguth, P., Cao, X., Khosravi, A., Acharya, U. R., Makarencov, V. & Nahavandi, S. (2021). A review of uncertainty quantification in deep learning: Techniques, applications and challenges. *Information Fusion*, 76 (2021), 243-297. Doi: <https://doi.org/10.1016/j.inffus.2021.05.008>

- Alassafi, M. O., Jarrah, M. & Alotaibi, R. (2021). Time series predicting of COVID-19 based on deep learning. *Neurocomputing*, 468 (2022), 335-344. Doi: <https://doi.org/10.1016/j.neucom.2021.10.035>
- Bi, J-W., Li, H. & Fan, Z-P. (2021). Tourism demand forecasting with time series imaging: A deep learning model. *Annals of Tourism Research*, 90 (2021), 103255. Doi: <https://doi.org/10.1016/j.annals.2021.103255>
- Brown, R. S. & Kline, W. A. (2020). Exogenous shocks and managerial preparedness: A study of U.S. airlines' environmental scanning before the onset of the COVID-19 pandemic. *Journal of Air Transport Management*, 89 (2020), 101899. Doi: <https://doi.org/10.1016/j.jairtraman.2020.101899>
- Cao, W., Sun, S. & Li, H. (2021). A new forecasting system for high-speed railway passenger demand based on residual component disposing. *Measurement*, 183 (2021), 109762. Doi: <https://doi.org/10.1016/j.measurement.2021.109762>
- Chimmula, V. K. R. & Zhang, L. (2020). Time series forecasting of COVID-19 transmission in Canada using LSTM networks. *Chaos, Solitons and Fractal*, 153 (2020), 109864. Doi: <https://doi.org/10.1016/j.chaos.2020.109864>
- Choi, S. & Kim, Y. J. (2021). Artificial neural network models for airport capacity prediction. *Journal of Air Transport Management*, 97 (2021), 102146. Doi: <https://doi.org/10.1016/j.jairtraman.2021.102146>
- Grosche, T., Rothlauf, F. & Heinzl, A. (2007). Gravity models for airline passenger volume estimation. *Journal of Air Transport Management*, 13 (2007), 175-183. Doi: <https://doi.org/10.1016/j.jairtraman.2007.02.001>
- Hanson, D., Delibasi, T. T., Gatti, M. & Cohen, S. (2021). How do changes in economic activity affect air passenger traffic? The use of state-dependent income elasticities to improve aviation forecast. *Journal of Air Transport Management*, 98 (2022), 102147. Doi: <https://doi.org/10.1016/j.jairtraman.2021.102147>
- Hotle, S. & Mumbower, S. (2021). The impact of COVID-19 on domestic U.S. air travel operations and commercial airport service. *Transportation Research Interdisciplinary Perspectives*, 9 (2021), 100277. Doi: <https://doi.org/10.1016/j.trip.2020.100277>
- Iacus, S. M., Natale, F., Santamaria, C., Spyros, S. & Vespe, M. (2020). Estimating and projecting air passenger traffic during the COVID-19 coronavirus outbreak and its socio-economic impact. *Safety Science*, 129 (2020), 104791. Doi: <https://doi.org/10.1016/j.ssci.2020.104791>
- İç, Y. T. ve Civelek, H. (2021). Development of a new model of gross domestic product forecasting. *Journal of Turkish Operations Management*, 5 (1), 564-575. Erişim adresi: <https://dergipark.org.tr/en/pub/jtom/issue/63460/883089>
- İncekara, Ç. Ö. (2020). Türkiye'nin elektrik üretiminde doğalgaz talep tahminleri. *Journal of Turkish Operations Management*, 4 (2), 494-508. Erişim adresi: <https://dergipark.org.tr/en/pub/jtom/issue/59336/851882>
- Karami, Z. & Kashef, R. (2020). Smart transportation planning: Data, models, and algorithms. *Transportation Engineering*, 2 (2020), 100013. Doi: <https://doi.org/10.1016/j.treng.2020.100013>
- Luo, J., Zhang, Z., Fu, Y., & Rao, F. (2021). Time series prediction of COVID-19 transmission in America using LSTM and XGBoost algorithms. *Results in Physics*, 27 (2021), 104462. Doi: <https://doi.org/10.1016/j.rinp.2021.104462>
- Singh, B. (2021). Predicting airline passengers' loyalty using artificial neural network theory. *Journal of Air Transport Management*, 94 (2021), 102080. Doi: <https://doi.org/10.1016/j.jairtraman.2021.102080>
- Solvoll, G., Mathisen, T. A. & Welde, M. (2020). Forecasting air traffic demand for major infrastructure changes. *Research in Transportation Economics*, 82 (2020), 100873. Doi: <https://doi.org/10.1016/j.retrec.2020.100873>
- Somu, N., Raman M R, G. & Ramamritham, K. (2020). A hybrid model for building energy consumption forecasting using long short term memory networks. *Applied Energy*, 261 (2020), 114131. Doi: <https://doi.org/10.1016/j.apenergy.2019.114131>
- Truong, D. (2021). Estimating the impact of COVID-19 on air travel in the medium and long-term using neural network and Monte Carlo simulation. *Journal of Air Transport Management*, 96 (2021), 102126. Doi: <https://doi.org/10.1016/j.jairtraman.2021.102126>

Ünsal, M. G. ve Kasap, R. (2020). Investigating Covid 19 data for G20, EU and OECD countries via using time series analysis & cluster analysis. *Journal of Turkish Operations Management*, 4 (2), 424-432. Erişim adresi: <https://dergipark.org.tr/en/pub/jtom/issue/59336/851834>

Yang, Z., Tang, R., Zeng, W., Lu, J. & Zhang, Z. (2021). Short-term prediction of airway congestion index using machine learning methods. *Transportation Research Part C*, 125 (2021), 103040. Doi: <https://doi.org/10.1016/j.trc.2021.103040>

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50 (2003), 159–175. Doi: [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)