

Derin öğrenme ile talep tahmini: Bir üçüncü parti lojistik firması için COVID-19 döneminde vaka analizi

Demand forecasting with deep learning: Case study in a third-party logistics company for the COVID-19 period

Ayşe ZEYBEL PEKÖZ¹ , Tülin İNKAYA^{1*} 

¹Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Bursa Uludağ Üniversitesi, Bursa, Türkiye.
azeybel@gmail.com, tinkaya@uludag.edu.tr

Geliş Tarihi/Received: 17.05.2022
Kabul Tarihi/Accepted: 29.09.2022

Düzeltilme Tarihi/Revision: 20.08.2022

doi: 10.5505/pajes.2022.73537
Araştırma Makalesi/Research Article

Öz

COVID-19 pandemi döneminde yaşanan kısıtlamalar ve kapanmalar küresel tedarik zincirlerini büyük ölçüde etkilemiştir. Lojistik sektörü, bu süreçten en çok etkilenen sektörler arasında yer almaktadır. Bu nedenle, lojistik talebinin doğru ve hızlı tahmin edilmesi, etkin kaynak planlaması için önem taşımaktadır. Bu çalışmada, bir üçüncü parti lojistik firmasında COVID-19 pandemi dönemindeki talebin doğru tahmin edilmesi hedeflenmiştir. Lojistik firmasının Haziran 2020 ve Aralık 2020 tarihleri arasındaki sevkiyat verisi incelenmiştir ve tahmin problemi tek değişkenli zaman serisi olarak ele alınmıştır. Çalışma kapsamında, derin öğrenme tabanlı talep tahmini modeli önerilmiştir. Önerilen modelde evrişimli sinir ağı (CNN) ile uzun kısa dönem hafıza (LSTM) ağı bütünleştirilmiştir. CNN özniteliklerin çıkarılmasını, LSTM ağı ise uzun dönemli bağımlılıkların yakalanmasını sağlamaktadır ve önerilen model hibrit CNN-LSTM olarak adlandırılmıştır. Hibrit CNN-LSTM'in tahmin performansı klasik tahmin yaklaşımlarının yanı sıra makine öğrenmesi ve derin öğrenme yaklaşımları ile karşılaştırılarak değerlendirilmiştir. Tüm tahmin yöntemlerinin parametre değerleri deneysel çalışmalar ile belirlenmiştir. Deneysel sonuçlara göre önerilen hibrit CNN-LSTM yöntemi diğer yöntemlerden daha yüksek tahmin performansı göstermiştir. Önerilen yaklaşım, lojistik talebinin doğru tahmin edilmesini sağlayarak işgücü ve kaynak planlaması faaliyetlerine girdi oluşturmaktadır.

Anahtar kelimeler: Talep tahmini, Üçüncü parti lojistik, Derin öğrenme, Evrişimli sinir ağları, Uzun kısa dönem hafıza.

Abstract

The restrictions and closures experienced during the COVID-19 pandemic period have affected the global supply chains greatly. The logistics sector is among the most affected sectors from this process. For this reason, accurate and fast estimation of logistics demand is important for effective resource planning. In this study, the aim is to predict the demand accurately in a third-party logistics company during the COVID-19 pandemic period. The shipment data of a logistics company between June 2020 and December 2020 were examined, and the prediction problem was considered as univariate time series. In the scope of the study, a deep learning-based demand forecasting model is proposed. In the proposed prediction model, convolutional neural network (CNN) and long short-term memory (LSTM) network are integrated. CNN provides feature extraction, LSTM captures long-term dependencies, and the proposed model is called hybrid CNN-LSTM. The prediction performance of the hybrid CNN-LSTM was evaluated by comparing it with the classical prediction approaches as well as machine learning and deep learning approaches. The parameter values of all forecasting methods were determined by experimental studies. According to the experimental results, the proposed hybrid CNN-LSTM method showed higher performance than the other methods. The proposed approach generates input to workforce and resource planning activities by providing accurate estimation of logistics demand.

Keywords: Demand forecasting, Third-party logistics, Deep learning, Convolutional neural networks, Long short-term memory.

1 Giriş

Globalleşme ve artan rekabet ile günümüzde firmalar kaliteli ürünleri, hızlı ve düşük maliyetle müşterilerine sunma yarışını içerisindedirler. Lojistik sektörü bu yarışta önemli bir rol üstlenmektedir. Özellikle pek çok üretici firma, lojistik faaliyetlerini üçüncü parti lojistik şirketlerine (Third-Party Logistics-3PL) devretmeye başlamışlardır.

Üçüncü parti lojistik kavramı bir firmanın lojistik faaliyetlerini başka firmaları kullanarak yerine getirmesi şeklinde tanımlanmaktadır [1]. Armstrong & Associates araştırma firmasının yayınladığı rapora göre dünyanın önde gelen ilk beş büyük 3PL firmasının 2019 yılı brüt lojistik gelirleri yaklaşık 107.7 milyar ABD dolarıdır [2]. Aynı araştırmaya göre Fortune 100'de yer alan firmaların 3PL kullanım oranı 2008 yılında %93 olup 2019 yılında %99'a yükselmiştir. Fortune 500 firmalarının geneline bakıldığında ise 2008-2019 yılları arasında 3PL kullanım oranı %77'den %92'ye artmıştır [2].

Üçüncü parti lojistik firmalarının araç, insan, depo gibi kaynakları etkin bir şekilde planlaması için talebi hızlı ve doğru olarak tahmin etmesi gerekmektedir. Diğer yandan 2020 yılında başlayan ve tüm dünyayı etkisi altına alan COVID-19 pandemisi lojistik sektörü dâhil olmak üzere tüm küresel tedarik zincirlerini büyük ölçüde etkilemiştir. Firmalar artan COVID-19 vakalarından dolayı işgücü kaybına uğramıştır. Üretimdeki bu dalgalanmalar ve duruşlar hammadde, ara ürün ve bitmiş ürün dağıtımını yapan lojistik firmaları için talepteki belirsizliğin artmasına neden olmuştur. Aynı zamanda COVID-19 sebebiyle yaşanan kapanmalar ve kısıtlamalar, ülkeler arası sevkiyat yapan araçların sınırlarda uzun bekleme sürelerine maruz kalmasına yol açmıştır ve lojistik faaliyetlerin akışında aksamalar yaşanmıştır.

Bu çalışmada, üçüncü parti lojistik sektöründe faaliyet gösteren bir firmada COVID-19 pandemi sürecindeki talep tahmini problemi ele alınmıştır. Problemin çözümü için büyük verinin işlenmesini ve karmaşık örüntülerin çıkarılmasını sağlayan

*Yazışılan yazar/Corresponding author

derin öğrenme yöntemleri kullanılmıştır. Önerilen tahmin modeli, derin öğrenme yaklaşımlarındaki öznitelik çıkarma özelliği ile zaman serisindeki uzun dönemli bağımlılıkları takip etme özelliğini bütünleştiren hibrit bir yaklaşımdır. Geliştirilen modelin performansı klasik tahmin yaklaşımlarının yanı sıra makine öğrenmesi ve derin öğrenme yaklaşımları ile karşılaştırılarak değerlendirilmiştir. Bu çalışma, COVID-19 pandemi sürecinde üçüncü parti lojistik firmasının talebini tahmin etmek için derin öğrenme tabanlı hibrit bir yöntem sunması itibarıyla literatüre katkı sağlamaktadır.

Makalenin diğer bölümleri şu şekilde organize edilmiştir: İkinci bölüm, konuyla ilgili literatür taramasını içermektedir. Üçüncü bölüm, materyal ve önerilen derin öğrenme tabanlı yöntemi tanıtmaktadır. Dördüncü bölümde deneysel koşullar ve karşılaştırmalı sonuçlar verilmiştir. Son bölümde ise sonuç ve gelecek çalışmalar belirtilmiştir.

2 Literatür taraması

Tedarik Zinciri Yönetimi Profesyonelleri Konseyinin (Council of Supply Chain Management Professional) tanımına göre lojistik yönetimi; müşterilerin ihtiyaçlarını karşılamak için mal, hizmet ve bilginin üretim noktasından tüketim noktasına kadar olan iki yönlü akışları ile depolama faaliyetlerinin etkin ve verimli bir şekilde yürütülmesi amacıyla gerçekleştirilen planlama, uygulama ve kontrol etme süreçlerini içeren tedarik zinciri yönetiminin bir bölümüdür [3].

Günümüzde dijitalleşme, bulut bilişim ve otomasyon teknolojileri ile lojistik yönetimde büyük miktarda veri toplanmaktadır. Toplanan büyük verinin işlenerek anlamlı hale getirilmesi ve karar verme süreçlerine katkı sağlaması bu alanda faaliyet gösteren firmalara rekabet avantajı yaratmaktadır.

Lojistik sektöründe büyük verinin işlenmesi için yapay zekâ tekniklerinin kullanımı yaygınlaşmaktadır [4]. Özellikle lojistik talebinin tahmininde yapay zekânın bir alt sınıfı olan derin öğrenme ile başarılı sonuçlar elde eden çalışmalar bulunmaktadır [5]-[10].

Yuan ve diğ. [5], Brezilya'daki bir lojistik firmasının talep tahmini için gri model ve yığılmış otomatik kodlayıcıyı (Stacked Auto-encoder-SAE) birleştirerek gri derin sinir ağı yaklaşımını önermiştir. Önerilen yaklaşımda, öncelikle birçok gri model orijinal veriyi işler, çıkan veri yığılmış otomatik kodlayıcı tahmin modeline girdi olur. Yığılmış otomatik kodlayıcının özelliği, bir otomatik kodlayıcının çıktısının diğer otomatik kodlayıcıya girdi olmasıdır. Yığılmış otomatik kodlayıcı etkili özniteliklerin çıkarımını yapar. Sonrasında aşırı öğrenme makinesi (Extreme Learning Machine-ELM) ile talep tahmini yapılır. Bu yöntem, gri sinir ağından daha iyi performans göstermiştir.

Gao ve diğ. [6], Çin kemer ve yol işletmesine ait limandaki konteynır hacimlerinin tahmini için tekrarlayan sinir ağı (Recurrent Neural Network-RNN) türü olan uzun kısa dönem hafıza (Long Short-Term Memory-LSTM) ağını kullanmıştır ve yüksek tahmin doğruluğu elde etmiştir.

Sınır ötesi e-ticaret ile ilgili yapılan bir çalışmada [7], üçüncü parti lojistik hizmet sağlayıcıların operasyonlarının hizmet kapasitesinin belirlenmesi için evrişimli sinir ağları (Convolutional Neural Network-CNN) ve LSTM yöntemleri birleştirilerek sıra bazlı CNN-LSTM modeli önerilmiştir. Bölgesel talep tahmini yapıldıktan sonra lojistik merkezlerinin nerede kurulması ve kaç adet olması gerektiği hesaplanmıştır.

Sonuç olarak, CNN-LSTM modelinin otoregresif bütünleşik hareketli ortalama (Autoregressive Integrated Moving Average-ARIMA), parçacık sürü optimizasyonu ve ELM yöntemlerinden daha iyi sonuç verdiği görülmüştür.

Yang ve Chang [8] ise bir limandaki ithalat ve ihracat için lojistik talebini CNN-LSTM modeli ile tahmin etmiştir. Bu kapsamda lojistik talebine etki eden faktörler incelenmiştir ve ekonomik büyüme faktörü talebe en yüksek etki eden faktör olarak bulunmuştur. Ayrıca önerilen model diğer makine öğrenmesi yöntemlerinden daha iyi performans göstermiştir.

E-ticaret firmalarının kullandığı üçüncü parti lojistik hizmet sağlayıcıları için talep tahmini problemini ele alan bir çalışmada [9], derin öğrenme ile etkili lojistik yönetimi yaklaşımı önerilmiştir. Önerilen yaklaşımda talep verisi çok değişkenli zaman serisi olarak ele alınmıştır ve CNN-LSTM modeli geliştirilmiştir. Üç farklı veri seti ile yapılan deneysel çalışmalarda tahmin doğrulukları %89-%95 aralığında bulunmuştur.

Fas'taki bir süpermarketin lojistik ihtiyaçlarının belirlenmesi için yapılan çalışmada [10]; ARIMA, çok katmanlı ileri beslemeli yapay sinir ağı (Multilayer Perceptron-MLP), LSTM ve CNN yöntemleri karşılaştırılmıştır. Deneysel sonuçlarda CNN yöntemi ile daha iyi performans elde edilmiştir.

Lojistik talebinin tahmini ile ilgili çalışmaların bir bölümünde yapay sinir ağları, destek vektör regresyon (Support Vector Regression-SVR), rassal ağaç gibi makine öğrenmesi yöntemleri de kullanılmıştır [11]-[13]. Örnek olarak; Xia ve diğ. [11], bölgesel ekonomik ve sosyal gelişme faktörlerini ele alan lojistik talep indeks sistemini geliştirmiştir ve topluluk tabanlı gri sinir ağı tahmin modeli önermiştir. Bu bütünleşik model, gri sistem teorisinin az veri gereksinimi ile geri beslemeli sinir ağlarının öğrenme, adaptasyon ve genelleme özelliklerini birleştirmiştir.

Moscozo Lopez ve diğ. [12], Ro-Ro ile İspanya'daki Algeciras Limanına gelen taze gıdaların bir haftalık nakliye miktarının tahmininde yapay sinir ağları ve SVR yöntemlerini kullanarak başarılı sonuçlar elde etmiştir.

Kentsel lojistik talebinin tahmininde SVR parametrelerini optimize etmek için karınca kolonisi algoritması kullanılmıştır [13]. Ekonomik büyüme faktörü, endüstriyel yapı, ticaret, gelir seviyesi, sabit değerler ve tüketici pazarı öznitelik olarak ele alınmıştır. Geliştirilen yöntem, SVR'nin performansını iyileştirmiştir.

Lojistik talebinin tahmini ile ilgili çalışmaların diğer bir bölümünde ise basit hareketli ortalama ve ARIMA gibi klasik zaman serisi tahmin yöntemleri kullanılmıştır. Yin ve Chen [14], karayolu taşımacılığındaki altyapı çalışmalarında kullanmak üzere karayolu taşıma hacmini tahmin etmiştir. Bu kapsamda, basit hareketli ortalama ile gri teori yöntemleri bütünleşik olarak ele alınmıştır ve ağır akut solunum sendromu (Severe Acute Respiratory Syndrome-SARS) salgını etkisinden dolayı veride olabilecek değişimler düzeltilmiştir. Önerilen model 2005 yılı toplam yolcu hacmini %2.57 hata ile tahmin etmiştir.

Antalya limanında aylık konteynır talep tahmini problemini ele alan bir başka çalışmada [15], gri teori ve ARIMA kullanılmıştır. Fattah ve diğ. [16] ise bir yiyecek firmasında tedarik zincirindeki lojistik aktivitelerin yönetimi için ARIMA ile talep tahmini yapmıştır.

Yukarıdaki çalışmalara ek olarak farklı sektörlerdeki talep ve satış tahmininde yapay zekâ tekniklerini kullanan çalışmalar da mevcuttur. E-ticaret sektöründe tüketici fiyat endeksi, tatil günü, işsizlik oranı gibi faktörler kullanılarak derin öğrenme, yapay sinir ağları, Gauss süreç regresyonu, regresyon ağacı, SVR ve topluluk öğrenme gibi yapay zekâ teknikleri ile satış tahmini yapılmıştır [17]. En yüksek performans derin öğrenme yöntemlerinden biri olan LSTM ile elde edilmiştir. Bir yem işletmesinin satış tahmininde yapay sinir ağları, SVR ve geleneksel zaman serisi yöntemleri karşılaştırılmıştır ve SVR'ın diğer tahmin yöntemlerinden daha iyi performans gösterdiği tespit edilmiştir [18]. Ayrıca otomobil satışlarının tahmininde derin sinirsel ağları [19]; perakende ofis malzemelerinin satış tahmininde ise doğrusal regresyon, K-en yakın komşuluk, rassal orman gibi makine öğrenmesi yaklaşımlarını [20] kullanan çalışmalar bulunmaktadır.

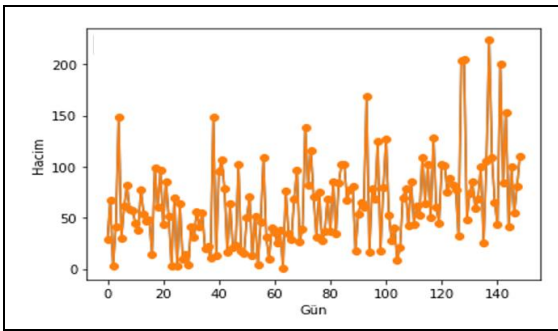
Bu çalışma, bir üçüncü parti lojistik firması için COVID-19 pandemi sürecindeki talebin tahmininde CNN ve LSTM'i bütünleştirerek derin öğrenme tabanlı bir çözüm yaklaşımı sunması ile literatüre katkı sağlamaktadır.

3 Materyal ve yöntem

3.1 Materyal

Bu çalışmada, Fransa'da faaliyet göstermekte olan bir 3PL firması ele alınmıştır. Firma tedarikçilerden aldığı hammadde ve yarı mamulleri toplayarak müşterisi olan üretici firmaya sevkiyatını yapmaktadır. Firmanın işgücü, kamyon, depolama alanı gibi kaynaklarını verimli ve etkin bir şekilde planlaması için sevkiyat hacmini öngörmesi gerekmektedir. Bu nedenle, bu çalışma kapsamında 3PL firmasının Covid-19 pandemi sürecinde gelecek dönemdeki sevkiyat hacimlerini doğru tahmin etmesini sağlayan bir yöntem geliştirilmesi amaçlanmıştır.

Bu çalışmada, COVID-19 salgınında üretimin başladığı Haziran 2020 ve Aralık 2020 tarih aralığındaki sevkiyat verisi ele alınmıştır. Çalışmada, üretici firmaya sevkiyat yapılan çalışma günleri kullanılmıştır. Şekil 1'de zamana göre talep verisi görülmektedir.



Şekil 1. Zamana göre talep verisi.

Figure 1. Demand data according to time.

3.2 Yöntem

Bu bölümde, çalışma kapsamında kullanılan derin öğrenme yöntemleri açıklanmıştır.

3.2.1 Uzun kısa dönem hafıza ağı

Uzun kısa dönem hafıza ağı, RNN'nin özel bir türüdür. RNN veride uzun dönemli zaman bağımlılığı olduğunda önceki girdilerin aktarımında zorlanır [21]. Bu nedenle, RNN uzun dönemli hafıza konusunda başarılı değildir.

RNN'de geriye yayılım esnasında kaybolan gradyan ya da patlayan gradyan problemi ortaya çıkabilir. Gradyan değerleri sinir ağındaki ağırlıkların güncellenmesinde kullanılır. Gradyan değeri hem mevcut hem de önceki katmanlara bağlı olduğu için geriye yayılım tekrarlandığında gradyan değeri küçülmektedir. Buna kaybolan gradyan denir. Benzer şekilde gradyan değerleri birden büyük olduğunda sonuç büyüyerek patlayan gradyan oluşabilir. Bu nedenlerle ağı uzun dönemli bağımlılıkları öğrenmesinde problemler gözlenir.

Hochreiter ve Schmidhuber RNN'nin sorunlarını çözmek amacıyla LSTM'i önermişlerdir [22]. LSTM modeline temel katkı ise Gers ve diğ. tarafından önerilen unutmaya kapılarıdır [23]. LSTM'deki kapı mekanizmaları bilgi akışını sağlar, kapılar saklanacak ve hatırlanacak verilere karar verir. Bu sayede zaman serisi içindeki önemli verilerin kaybolması önlenir.

Bir LSTM hücresinde x_t t zaman adımındaki girdi vektörünü, h_{t-1} ($t-1$) zaman adımındaki gizli durumu ve c_{t-1} ($t-1$) zaman adımındaki hafıza hücresinin durumunu gösterir. Bunlar hücrenin girdileridir. Ayrıca LSTM hücresinde girdi, unutmaya ve çıktı kapıları yer alır.

LSTM'in unutmaya, hücre durum, girdi ve çıktı kapılarına ilişkin hesaplamalar sırasıyla Denklem (1)-(5)'te yer almaktadır. Buna göre, Denklem (1)'de t zaman adımında i hücresi için unutmaya kapısı $f_i^{(t)}$, bir sigmoid aktivasyon fonksiyonu (σ) aracılığı ile hangi bilginin geçip geçmeyeceğini belirler. b^f , U^f ve W^f unutmaya kapıları için sırasıyla sapma, girdi ağırlığı ve tekrarlayan ağırlıkları gösterir. Denklem (2)'de $s_i^{(t)}$ hücre durumunu güncelleme adımı verilmiş olup b , U ve W sırasıyla LSTM hücresine giren sapma, girdi ağırlıkları ve tekrarlayan ağırlıkları gösterir. Denklem (3)'te $g_i^{(t)}$ hücre girdi kapısının hesaplanması yer almaktadır ve hesaplama unutmaya kapısına benzer şekilde yapılır. Denklem (4)'te $h_i^{(t)}$ gizli durumu, $q_i^{(t)}$ ise çıktı kapısını gösterir. Denklem (5)'te yer alan çıktı kapısının hesaplanmasında b^o , U^o ve W^o sırasıyla sapma, girdi ağırlığı ve tekrarlayan ağırlıklarını ifade eder.

$$f_i^{(t)} = \sigma \left(b_i^f + \sum_j U_{i,j}^f x_j^{(t)} + \sum_j W_{i,j}^f h_j^{(t-1)} \right) \quad (1)$$

$$s_i^{(t)} = f_i^{(t)} s_i^{(t-1)} + g_i^{(t)} \sigma \left(b_i + \sum_j U_{i,j} x_j^{(t)} + \sum_j W_{i,j} h_j^{(t-1)} \right) \quad (2)$$

$$g_i^{(t)} = \sigma \left(b_i^g + \sum_j U_{i,j}^g x_j^{(t)} + \sum_j W_{i,j}^g h_j^{(t-1)} \right) \quad (3)$$

$$h_i^{(t)} = \tanh(s_i^{(t)}) q_i^{(t)} \quad (4)$$

$$q_i^{(t)} = \sigma \left(b_i^o + \sum_j U_{i,j}^o x_j^{(t)} + \sum_j W_{i,j}^o h_j^{(t-1)} \right) \quad (5)$$

3.2.2 Evrişimli sinir ağları

Evrişimli sinir ağları (CNN), görüntü tanıma ve görüntü işlemede yaygın olarak kullanılan çok katmanlı bir yapay sinir ağı yöntemidir [24]. CNN'de katmanların en az birinde evrişim adı verilen matematiksel bir işlem kullanılır [21]. Evrişim, özel bir doğrusal işlem türüdür ve gelişmiş bir öznitelik temsili elde edilmesini sağlar.

Genel olarak CNN evrişim katmanı, havuzlama katmanı ve tam bağlantı katmanından oluşur. Evrişim işlemi Denklem (6)'da verilmiştir.

$$x_j^d = \phi \left(\sum_{i \in M_j} x_i^{d-1} * w_{ij}^d + b_i^d \right) \quad (6)$$

Burada, x_j^d , d . evrişim katmanının j . öznetelik haritasıdır. $\phi(\cdot)$, aktivasyon fonksiyonudur. M_j , $(d-1)$. katmanının girdi öznetelik kümesidir. w_{ij}^d d . evrişim katmanının j . özneteliği ile $(d-1)$. katmanının i . özneteliği arasındaki bağlantı ağırlığını gösterir. b_i^d ise ilgili katmandaki sapmadır.

Evrişim katmanından sonra havuzlama katmanı gelir. Havuzlama katmanının amacı, öznetelik haritasının boyutunun azaltılmasıdır. Bu işlem, önemli özneteliklerin belirlenmesini sağlar, veri karmaşıklığını azaltır ve ağır çevresel değişikliklere toleransını artırır. Havuzlama katmanı Denklem (7)'de verilmiştir.

$$x_j^d = \phi(\beta_j^d \text{down}(x_j^{d-1}) + b_j^d) \quad (7)$$

Burada, $\text{down}(\cdot)$ alt örnekleme fonksiyonunu ve β ağırlık matrisini gösterir. Evrişim katmanı ve havuzlama katmanı sonrasında ise tam bağlantı katmanı ile sınıflandırma gerçekleştirilir. Denklem (8) ise tam bağlantı katmanı için çıktı fonksiyonunu göstermektedir.

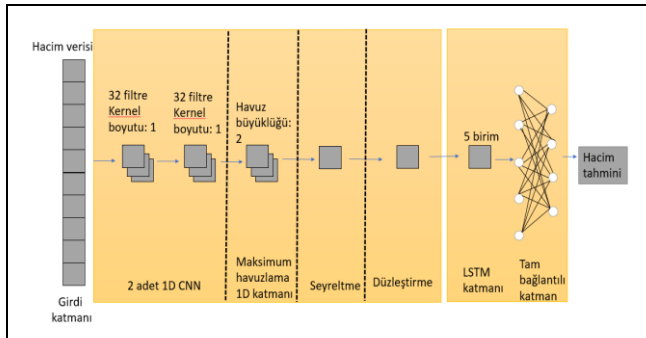
$$y^k = \phi(w^k x^{k-1} + b^k) \quad (8)$$

Burada, k katman indeksini, y^k tam bağlantı katmanının çıktısını, x^{k-1} tam bağlantı katmanının girdisini, w^k ağırlık katsayısını ve b^k sapmayı ifade eder.

3.2.3 Önerilen hibrit derin öğrenme yaklaşımı

Derin öğrenme yöntemlerinin bütünleşik kullanıldığı hibrit yaklaşımlar ile zaman serilerinde etkili sonuçlar alınmaktadır. Özellikle CNN'nin öznetelik çıkarma özelliği ve LSTM'in uzun dönemli bağımlılıkları takip etme özelliğini birleştiren hibrit CNN-LSTM modelleri ile zaman serilerinde başarılı sonuçlar elde edilmektedir [7]-[9],[17].

Bu makalede, tahmin problemlerindeki etkili performansı nedeniyle üçüncü parti lojistik firmasının COVID-19 salgınında talep tahmini için hibrit CNN-LSTM modeli önerilmiştir. Önerilen hibrit CNN-LSTM modelinin mimarisi Şekil 2'de verilmiştir.



Şekil 2. Hibrit CNN-LSTM modelinin mimarisi.

Figure 2. The architecture of hybrid CNN-LSTM model.

Modelde hacim verisi girdi olarak alınmıştır. Öznetelik çıkarımı için 32 filtre ve kernel boyutu bir olan iki adet bir boyutlu (1D) evrişim katmanı bulunmaktadır. Sonrasında havuz büyüklüğü iki olan maksimum havuzlama katmanı bulunmaktadır. Seyreltme (dropout) ve düzeltilmeden sonra LSTM katmanına bağlanmaktadır. Beş hücreden oluşan LSTM katmanı

sonrasında ise tam bağlantı katmanı ile hacim tahmini yapılmaktadır.

4 Deneysel çalışma

Bu bölümde, yapılan deneysel çalışmalar açıklanmıştır.

4.1 Deneysel koşullar ve karşılaştırma

Tahmin modellerinin performansını değerlendirmek için tahminler ile gerçek değerler arasındaki farkların hesaplanmasında performans metrikleri (hata ölçütleri), kullanılmaktadır [25]. Ortalama karesel hataların karekökü (Root mean squared error-RMSE), ortalama mutlak hata (Mean absolute error-MAE) ve ortalama mutlak yüzde hata (Mean absolute percentage error-MAPE) literatürde en sık kullanılan ölçütler arasındadır [26].

Farklı performans metriklerinin farklı ölçüm türleri mevcuttur ve performans metriği seçimi uygulama alanına göre yapılmalıdır. Örneğin, ölçeğe bağlı performans metrikleri hatanın büyüklüğüne göre cezalandırma yaparlar [26]. RMSE karesel hatalara, MAE ise mutlak hatalara dayalıdır ve gerçek değerler ile aynı birimdedir. RMSE, karesel hatayı ele aldığı için MAE'ye göre aykırı tahmin değerlerine karşı daha duyarlıdır. Bu nedenle, özellikle karar verme problemlerinde maliyet ve kazançların hesaplanmasında RMSE en çok tercih edilen ölçütlerden biridir [27]. Yüzdeye bağımlı performans metrikleri ise hatanın göreceli olarak değerlendirilmesini sağlarlar. Bu grupta yer alan MAPE zaman serisindeki değerlere duyarlı ve yanlı bir metriktir [26]. Gerçek değer çok küçük olduğunda MAPE çok yüksektir; gerçek değer sıfır ise MAPE tanımsız olur. Ayrıca, MAPE gerçek değerden büyük olan tahminlere daha büyük ceza verme eğilimindedir [26].

COVID-19 pandemi dönemindeki lojistik talep verisinde belirsizlikler ve dalgalanmalar yüksektir. Bu çalışmada ele alınan sevkiyat verisindeki yüksek değişkenlik Şekil 1'de görülmektedir. Şöyle ki, en küçük gerçek değer sıfıra yakın iken en büyük gerçek değer ise 220'den büyüktür. Ayrıca sevkiyat hacim tahminleri firmanın kaynak planlama kararlarına girdi teşkil etmektedir. Tahmin hatasının büyük olması firmada ek maliyetlere ve müşteri memnuniyetsizliğine yol açabilmektedir. Bu nedenlerle, bu çalışmada performans ölçütü olarak RMSE seçilmiştir.

RMSE'nin hesaplanmasına ilişkin formül Denklem (9)'da verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{n}} \quad (9)$$

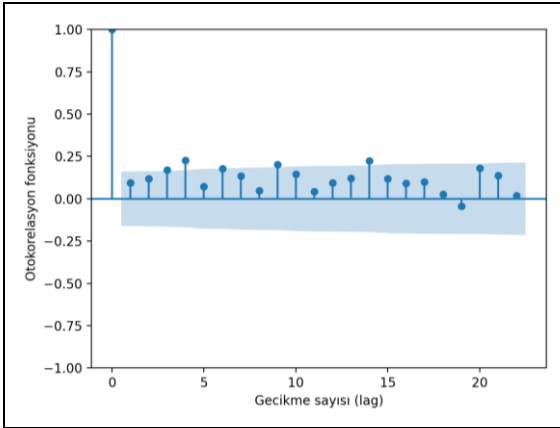
Burada, y_j gerçek değer, \hat{y}_j tahmin değeri, n ise veri sayısıdır. Tahmin modellerinde RMSE değerlerinin en küçüklenmesi amaçlanmaktadır.

Bu çalışmada, önerilen hibrit CNN-LSTM modelinin performansını karşılaştırmak için hem klasik tahmin yöntemleri hem de makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. Klasik tahmin yöntemleri kapsamında basit hareketli ortalama (Simple Moving Average-SMA), basit üstel düzeltme (Simple Exponential Smoothing-SES), doğrusal regresyon ve ARIMA yöntemleri ele alınmıştır. Makine öğrenmesi yöntemleri kapsamında ise K en yakın komşuluk (K Nearest Neighbor - KNN), regresyon ağacı, rassal orman ve SVR yöntemleri incelenmiştir. Ayrıca önerilen yaklaşımın performansı MLP, LSTM ve CNN gibi diğer derin öğrenme yöntemleri ile de kıyaslanmıştır.

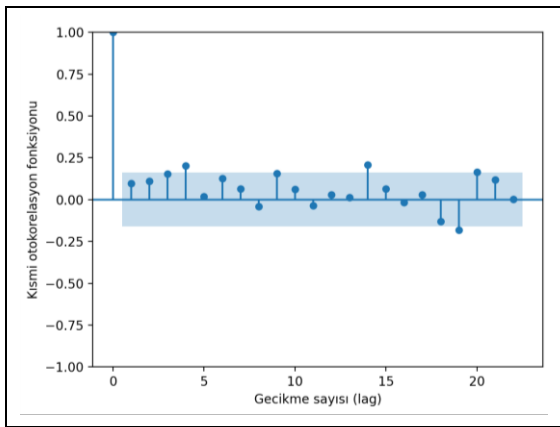
Doğrusal regresyon, KNN, regresyon ağacı, rassal orman ve SVR Python'da scikit-learn kütüphanesinde, ARIMA yöntemi ise Python'da pmdarima kütüphanesinde uygulanmıştır. MLP, CNN, LSTM ve CNN-LSTM yöntemleri için Python'da keras kütüphanesi kullanılmıştır. SMA ve SES yöntemleri ise Excel'de hesaplanmıştır.

Tahmin problemini gözetimli öğrenme yaklaşımları ile çözebilmek için özniteliklerin belirlenmesi gerekmektedir. Martínez ve diğ. [28], zaman serisi tahmin probleminde öznitelik seçimi için otokorelasyon ve kısmi otokorelasyon fonksiyonlarının kullanılabilirliğini belirtmiştir. Buna göre, ele alınan talep verisi için otokorelasyon ve kısmi otokorelasyon fonksiyonları %5 anlamlılık limitleri ile sırasıyla Şekil 3(a) ve 3(b)'de verilmiştir. Şekil 3'te yer alan otokorelasyon ve kısmi otokorelasyon fonksiyonlarına ilişkin değerler genel olarak sınırlar dahilindedir ve veride mevsimsel bir yapı gözlenmemiştir. Ayrıca, yapılan ön deneysel çalışmada bir gün önceki gözlem değeri ile beş gün önceki gözlem değeri öznitelik olarak seçilerek karşılaştırılmıştır ve bir gün önceki gözlem değeri ile daha doğru sonuçlar elde edilmiştir. Bu nedenlerle, bu çalışmada öznitelik olarak bir gün önceki gözlem değeri alınmıştır.

Deneysel çalışmalarda verinin ilk %80'ine karşılık gelen kısmi eğitim verisi, sonraki %10'luk kısmı doğrulama verisi ve geri kalan %10'luk kısmı ise test verisi olarak kullanılmıştır.



(a)



(b)

Şekil 3. Talep verisine ilişkin; (a): Otokorelasyon fonksiyonu ve (b): Kısmi otokorelasyon fonksiyonu.

Figure 3(a): Autocorrelation function and (b): Partial autocorrelation function for the demand data.

4.2 Parametre optimizasyonu

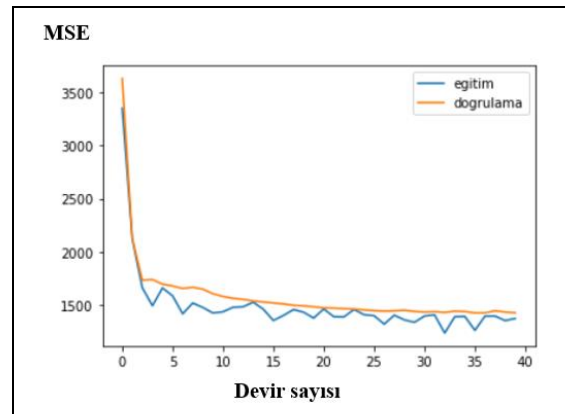
Tahmin yöntemlerindeki parametreler, tahmin performansını önemli ölçüde etkilemektedir. Bu nedenle, her tahmin yönteminde parametrelerin belirlenmesi için deneysel çalışmalar gerçekleştirilmiştir. Bu kapsamda, karşılaştırılan tahmin yöntemleri Tablo 1'de verildiği gibi üç grupta özetlenmiştir. Her tahmin yöntemi için ele alınan parametrelerin değer aralıkları ve seçilen değerleri Tablo 1'de yer almaktadır.

Klasik tahmin yöntemlerinden biri olan ARIMA'da parametre seçimi Akaike bilgi kriterine (Akaike Information Criteria-AIC) göre yapılmıştır. AIC kriteri, modelin performansı ve basitliğini birlikte ele alır. ARIMA'da tüm p , d , q kombinasyonları arasında en düşük AIC değerini veren sonuç seçilmiştir. Veride mevsimsellik bulunmaması nedeniyle mevsimsellik parametreleri (P, D, Q, m) sıfır değerini almıştır. Doğrusal regresyon yönteminde bağımsız değişken olarak bir önceki dönemdeki gözlem değeri kullanılmıştır. Doğrusal regresyon yönteminde parametre bulunmamaktadır.

Makine öğrenmesi ve derin öğrenme yöntemlerinde eğitim verisi ile modeller eğitilmiştir ve doğrulama verisindeki performansa göre en iyi parametre değerleri seçilmiştir. Regresyon ağacı, rassal orman ve SVR yöntemlerinde parametreler ızgara araması (grid search) ile belirlenmiştir.

Regresyon ağacı ve rassal orman yöntemlerinde ortalama karesel hata (Mean Squared Error-MSE) en küçüklenmiştir. Derin öğrenme yöntemlerinde incelenen mimariler Tablo 1'de verilmiştir. Tüm derin öğrenme modellerinde kayıp fonksiyonu MSE olarak alınmıştır ve modelleri eğitmek için ADAM algoritması kullanılmıştır [29]. Ayrıca modellerde gizli katmanda doğrultulmuş lineer birim (RELU) aktivasyon fonksiyonu seçilmiştir.

Önerilen hibrit CNN-LSTM seçilen parametre değerleri ile çalıştırıldığında devir sayısına göre kayıp fonksiyonu değerleri Şekil 4'te yer almaktadır. Buna göre, devir sayısına bağlı olarak eğitim ve doğrulama verilerindeki kayıp fonksiyonu değerleri azalarak yakınsamaktadır. Eğitim ve doğrulama hatalarındaki bu yakınsama modelin öğrenmesinin gerçekleştiğini göstermektedir.



Şekil 4. Hibrit CNN-LSTM'de devir sayısına göre kayıp fonksiyonunun değerleri.

Figure 4. The values of the loss function according to the epoch number in hybrid CNN-LSTM.

Tablo 1. Tahmin modellerinin parametreleri.

Table 1. Parameters of demand models.

Yöntem Grubu	Tahmin Yöntemi	Parametre	Aralık	Seçilen parametre değeri
Klasik Tahmin Yöntemleri	SMA	Dönem sayısı (m)	{3, 4, 5}	4
	SES	Düzeltilme faktörü (α)	[0.6, 0.9]	0.6
	ARIMA	Otoregresif model derecesi (p)	[0, 4]	0
		Fark alma derecesi (d)	1	1
		Hareketli ortalama model derecesi (q)	[0, 2]	1
Makine Öğrenmesi Yöntemleri	KNN	Komşu sayısı (k)	{3, 4, 5, 10}	4
	Regresyon ağacı	Bölme için minimum nesne sayısı	[2, 10]	2
		Yaprak düğümündeki minimum nesne sayısı	[2, 20]	2
		Maksimum derinlik	[2, 8]	2
		Maksimum yaprak düğümü sayısı	[5, 15]	5
		Bölme için minimum nesne sayısı	[2, 10]	3
	Rassal Orman	Ağaç sayısı	[100, 500]	100
		Yaprak düğümündeki minimum nesne sayısı	[2, 20]	20
		Maksimum derinlik	[2, 8]	2
		Maksimum yaprak düğümü sayısı	[5, 15]	10
		Düzenleştirme katsayısı (C)	[0.001, 10]	0.01
	SVR	Duyarsız Laplace kayıp fonksiyonu parametresi (ϵ)	[0.01, 10]	0.2
		Dağılım genişliği kontrol parametresi (γ)	{scale, auto}	scale
		Kernel fonksiyonu	{radyal tabanlı fonksiyon, gaussian, sigmoid, polinom}	polinom
		MLP (Bir girdi katmanı, bir gizli katman, bir çıktı katmanı)	Hücre sayısı	{5, 10, 15}
Devir sayısı			[5, 50]	40
Öğrenme oranı	[0.001, 0.1]		0.01	
Yığın boyutu	{1, 2}		1	
CNN 1D (İki evrişim katmanı ve aralarında seyreltme katmanı, bir havuzlama katmanı, bir düzleştirme katmanı, bir tam bağlantı katmanı)	Filtre sayısı	[8, 64]	32	
	Kernel sayısı	{1, 2}	2	
	Devir sayısı	[5, 100]	50	
	Yığın boyutu	{1, 2}	2	
	Öğrenme oranı	[0.001, 0.1]	0.001	
	Seyreltme	[0.1, 0.5]	0.1	
Derin Öğrenme Yöntemleri	LSTM (Bir girdi katmanı, iki gizli katman, bir tam bağlantı katmanı)	1. gizli katmandaki hücre sayısı	[5, 15]	10
		2. gizli katmandaki hücre sayısı	[5, 15]	5
	Hibrit CNN-LSTM (İki evrişim katmanı, bir havuzlama katmanı, bir seyreltme katmanı, bir düzleştirme katmanı, bir LSTM katmanı, bir tam bağlantı katmanı)	Fark alma sayısı	{1, 2, 4, 10}	1
		Devir sayısı	[5, 50]	20
		Yığın boyutu	{1, 5}	1
		Öğrenme oranı	[0.001, 0.1]	0.01
		Seyreltme	[0.1, 0.5]	0.5
		Zaman adımı	10	10
		Filtre	[8, 64]	8
		Kernel sayısı	{1, 2}	1
LSTM hücre sayısı	[5, 15]	15		
Devir sayısı	[5, 50]	40		
Yığın boyutu	{1, 2}	2		
Öğrenme oranı	[0.001, 0.1]	0.001		
Seyreltme	[0.1, 0.5]	0.1		

4.3 Sayısal sonuçlar ve tartışma

Tahmin yöntemlerinin seçilen parametre değerleri ile test verisindeki performansı karşılaştırılmıştır. Her tahmin yöntemi ile beş tekrar yapılmıştır ve elde edilen RMSE değerlerinin ortalaması ile standart sapması Tablo 2’de özetlenmiştir.

Tablo 2’ye göre, klasik tahmin yöntemlerinde en küçük ortalama RMSE değeri 62.32 olup ARIMA ile elde edilmiştir. Bu yöntemlerde rassallık bulunmadığı için standart sapma değerleri sıfırdır. En yüksek hata değeri ise doğrusal regresyonda gözlenmiştir.

Makine öğrenmesi yöntemleri arasında en küçük ortalama RMSE değeri 67.84’tür ve KNN yöntemine aittir. Bu grupta ortalama RMSE’ye göre KNN’den sonra sırasıyla SVR ve rassal orman yöntemleri gelmektedir. KNN, regresyon ağacı ve SVR yöntemlerinde standart sapma sıfır olarak bulunmuştur.

Derin öğrenme yöntemlerinde ise en küçük ortalama RMSE değeri önerilen hibrit CNN-LSTM ile 59.12 olarak bulunmuştur. Ortalama RMSE’ye göre ikinci en yüksek performans gösteren derin öğrenme yöntemi ise CNN’dır. Yöntemlerin

performanslarındaki değişkenlik incelendiğinde MLP en küçük standart sapma değerine sahip derin öğrenme yöntemidir.

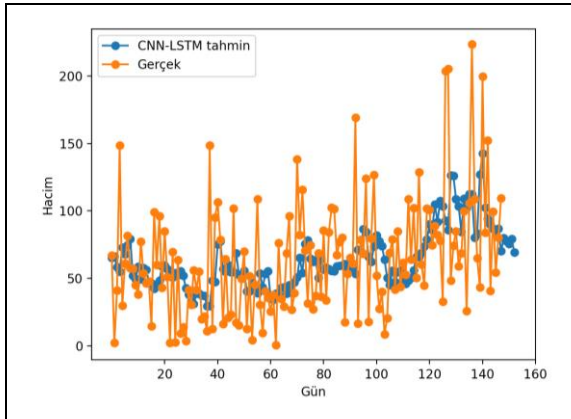
Tablo 2. Tahmin yöntemlerinin test verisindeki performanslarına göre karşılaştırılması.

Table 2. Comparison for the demand forecasting methods according to the performances on test data.

Yöntem Grubu	Yöntem	Ortalama (RMSE)	Standart Sapma (RMSE)
Klasik Tahmin Yöntemleri	SMA	63.83	0.00
	SES	62.42	0.00
	Doğrusal Regresyon	70.53	0.00
	ARIMA	62.32	0.00
Makine Öğrenmesi Yöntemleri	KNN	67.84	0.00
	Regresyon Ağacı	72.64	0.00
	Rassal Orman	69.55	0.22
	SVR	68.74	0.00
Derin Öğrenme Yöntemleri	MLP	75.73	0.39
	LSTM	66.88	2.91
	CNN	59.96	1.37
	CNN-LSTM	59.12	0.41

Diğer yandan, MLP en yüksek ortalama RMSE değerine sahiptir. Derin öğrenme yöntemleri arasında en küçük ikinci standart sapma değeri önerilen hibrit CNN-LSTM ile elde edilmiştir.

Sonuç olarak, tahmin yöntemleri arasında en yüksek performans önerilen hibrit CNN-LSTM ile elde edilmiştir. Ayrıca önerilen yöntemin performansındaki değişkenlik düşüktür. Hibrit CNN-LSTM ile yapılan tahminler ile gerçek talep verisinin karşılaştırması Şekil 5'te verilmiştir. Firmanın amacı gelecek talep hakkında öngörü sahibi olmaktadır. Bu nedenle, hibrit CNN-LSTM ile gelecek beş günlük talebe ilişkin tahminler yapılarak Şekil 5'te gösterilmiştir.



Şekil 5. Gerçek talep verisi ve hibrit CNN-LSTM ile yapılan tahminler.

Figure 5. Actual demand data and forecasts with hybrid CNN-LSTM.

Diğer tahmin yöntemlerinin performansları incelendiğinde ortalama RMSE'ye göre ikinci sırada CNN ve üçüncü sırada ARIMA yer almaktadır. Makine öğrenmesi ve LSTM gibi öznitelik çıkarma özelliği bulunmayan yöntemlerin performansı CNN tabanlı yöntemlerden geride kalmaktadır. Klasik tahmin yöntemleri zaman serisindeki doğrusal ilişkilerin

tespitinde etkili olurken derin öğrenme yöntemleri doğrusal olmayan ve karmaşık örüntülerin bulunmasını sağlamaktadır.

CNN'in öznitelik çıkarma özelliğinin tek değişkenli zaman serisinde etkili olduğu görülmüştür. Diğer yandan LSTM tek başına uygulandığında uzun zamanlı bağımlılıkların çıkarılmasında yeterli olmamıştır. Hibrit model iki derin öğrenme yönteminin güçlü özelliklerinin birleştirilmesini sağlamıştır.

Derin öğrenme ve makine öğrenmesi yöntemleri büyük miktarda veri ile eğitildiğinde daha iyi performans elde edilmektedir. Bu çalışmada COVID-19 pandemi dönemindeki talep verisi ele alındığı için veri sayısı azdır. Bu durum makine öğrenmesi ve derin öğrenme yöntemleri için bir dezavantaj teşkil etmektedir. Derin öğrenme ve makine öğrenmesi yöntemlerinin performansını arttırabilecek bir diğer unsur ise talep üzerinde etkili olabilecek diğer faktörlerin modele dâhil edilmesidir. Bu durumda, tahmin probleminin çok değişkenli zaman serisi olarak ele alınması mümkündür.

5 Sonuçlar

Dijitalleşme ve otomasyon sistemleri ile tedarik zincirinin önemli bir bileşeni olan lojistik faaliyetlerinin yönetiminde veriye dayalı sistemlerin kullanımı yaygınlaşmaktadır. Diğer yandan, COVID-19 salgını talepteki belirsizliklerin artmasına ve hammadde/bileşen krizlerinin yaşanmasına neden olmuştur. Bu nedenle maliyetlerin azaltılması, kaynakların verimli kullanılması ve müşterilere kaliteli hizmet verilebilmesi için lojistik talebinin doğru şekilde tahmin edilmesi gerekmektedir.

Bu çalışmada bir üçüncü parti lojistik firmasında COVID-19 pandemi dönemindeki talep tahmini problemi ele alınmıştır ve problemin çözümü için hibrit CNN-LSTM modeli önerilmiştir. Klasik tahmin, makine öğrenmesi ve derin öğrenme yöntemleri ile karşılaştırıldığında önerilen yaklaşımın tahmin performansının daha iyi olduğu görülmüştür.

COVID-19 pandemi döneminde talepteki değişkenlik ve belirsizliğe karşı CNN ve LSTM yöntemlerinin güçlü özelliklerinin birleştirilmesi başarılı sonuç vermiştir. CNN zaman serisindeki özniteliklerin çıkarılmasını, LSTM ise uzun zamanlı bağımlılıkların yakalanmasını sağlamıştır. Diğer yandan, derin öğrenme yöntemleri klasik tahmin yöntemlerine göre daha fazla veri ve eğitim süresine ihtiyaç duymaktadır. Ayrıca öznitelik çıkarma özellikleri bulunmayan makine öğrenmesi yöntemleri talep tahmininde düşük performans göstermiştir.

Bu çalışmanın özgün yönü COVID-19 pandemi döneminde üçüncü parti lojistik firmasında talep tahmini problemi için hibrit CNN-LSTM modeli geliştirilmesidir. Ayrıca elde edilen talep tahminleri depo kapasitesi, işgücü ve araç sayısı gibi kaynakların doğru planlanmasında firmanın karar verme süreçlerine girdi teşkil etmektedir.

Gelecek çalışmalarda, problem çok değişkenli zaman serisi tahmini olarak modellenebilir ve bu problem için derin öğrenme yöntemleri geliştirilebilir. Bu kapsamda, öznitelik olarak önceki dönemlerdeki talep değerlerinin yanı sıra talebi etkileyen diğer faktörler de incelenebilir. Ayrıca lojistik talep tahmininde doğruluğu arttırmak amacıyla topluluk yaklaşımlar kullanılabilir.

6 Conclusions

With the digitalization and automation systems, the use of data-based systems has become widespread in the

management of logistics activities, which is an important component of the supply chain. On the other hand, COVID-19 outbreak has caused uncertainties in demand and raw material/component crises. Hence, logistics demand should be accurately estimated in order to reduce costs, use resources efficiently and provide high quality service to customers.

In this study, the demand forecasting problem during the COVID-19 pandemic period is considered in a third-party logistics company, and a hybrid CNN-LSTM model is proposed to solve the problem. Compared to the classical prediction, machine learning and deep learning methods, the prediction performance of the proposed approach is better.

Combination of the powerful features for CNN and LSTM methods has yielded successful results against the volatility and uncertainty in demand during the COVID-19 pandemic period. CNN enables the extraction of features in the time series, and LSTM ensures long-term dependencies to be captured. On the other hand, deep learning methods require more data and time compared to the classical forecasting methods. In addition, since machine learning methods do not have feature extraction property, they show poor performance in demand forecasting.

The original aspect of this study is the development of a hybrid CNN-LSTM model for forecasting demand in a third-party logistics company during the COVID-19 pandemic period. In addition, the resulting demand forecasts constitute input to the company's decision making processes for the correct planning of resources such as warehouse capacity, workforce and number of vehicles.

In the future studies, the problem can be modeled as multivariate time series prediction, and deep learning methods can be developed for this problem. In this context, besides the demand values in previous periods, other factors affecting the demand can also be examined as attributes. In addition, ensemble approaches can be used to increase accuracy in estimating logistics demand.

7 Yazar katkı beyanı

Bu çalışmada Ayşe ZEYBEL PEKÖZ literatür taraması, veri toplama, yöntem geliştirilmesi, analizlerin gerçekleştirilmesi, elde edilen sonuçların incelenmesi ve makale yazılması başlıklarında; Tülin İNKAYA fikrin oluşturulması, sonuçların değerlendirilmesi, makalenin yazım denetiminin yapılması, eleştirel inceleme ve makalenin içerik açısından kontrol edilmesi başlıklarında katkı sunmuştur.

8 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması yoktur.

9 Kaynaklar

- [1] Waters D. *Logistics An Introduction to Supply Chain Management*. 1st ed. New York, USA, Palgrave Macmillan, 2003.
- [2] Burnson P. "Top 50 Third-party logistics: Today's marketplace not for the faint of heart". *Logistics Management*, 59(6), 56-64, 2020.
- [3] Council of Supply Chain Management Professionals. "CSCMP Supply Chain Management Definitions and Glossary". https://cscmp.org/CSCMP/Educate/SCM_Definitions_and_Glossary_of_Terms.aspx (15.12.2021).

- [4] Barua L, Zou B, Zhou Y. "Machine learning for international freight transportation management: A comprehensive review". *Research in Transportation Business & Management*, 34, 1-11, 2020.
- [5] Yuan W, Chen JH, Cao JJ, Jin ZY. "Forecast of logistics demand based on grey deep neural network model". *2018 International Conference on Machine Learning and Cybernetics*, Chengdu, China, 15-18 July 2018.
- [6] Gao Y, Chang D, Chen CH, Fang T. "Deep learning with long short-term memory recurrent neural network for daily container volumes of storage yard predictions in port". *2018 International Conference on Cyberworlds*, Singapore, 3-5 October 2018.
- [7] Ren S, Choi TM, Lee KM, Lin L. "Intelligent service capacity allocation for cross-border E-commerce related third-party-forwarding logistics operations: A deep learning approach". *Transportation Research Part E: Logistics and Transportation Review*, 134, 1-19, 2020.
- [8] Yang C, Chang P. "Forecasting the demand for container throughput using a mixed-precision neural architecture based on CNN-LSTM". *Mathematics*, 8, 1-17, 2020.
- [9] Abosuliman SS, Almagrabi AO. "Computer vision assisted human computer interaction for logistics management using deep learning". *Computers and Electrical Engineering*, 96, 1-12, 2021.
- [10] Bousqaoui H, Slimani I, Achchab S. "Comparative analysis of short-term demand predicting models using ARIMA and deep learning". *International Journal of Electrical and Computer Engineering*, 11(4), 3319-3328, 2021.
- [11] Xia G, Ma Lu, Wang D, Sun Z. "Prediction of logistics demand based on grey neural network ensemble". *2016 3rd International Conference on Systems and Informatics*, Shanghai, China, 19-21 November 2016.
- [12] Moscoso-Lopez JA, Turias IJ, Come MJ, Ruiz-Aguilar JJ, Cerban M. "Short-term forecasting of intermodal freight using ANNs and SVR: Case of the Port of Algeciras Bay". *Transportation Research Procedia*, 18, 108-114, 2016.
- [13] Yu N, Xu W, Yu KL. "Research on regional logistics demand forecast based on improved support vector machine: a case study of Qingdao City under the new free trade zone strategy". *IEEE Access*, 8, 9551-9564, 2020.
- [14] Yin Y, Chen S. "Research on the prediction model to the highway transportation demand based on moving average and grey theory". *International Conference on Grey Systems and Intelligent Services*, Nanjing, China, 18-20 December 2007.
- [15] Altın FG, Çelik Eroğlu Ş. "Gri tahmin ve Box-Jenkins yöntemleri ile Antalya Limanı için aylık konteyner talep tahmini". *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(3), 540-562, 2020.
- [16] Fattah J, Ezzine L, Aman Z, Moussami HE, Lachhab A. "Forecasting of demand using ARIMA model". *International Journal of Engineering Business Management*, 10, 1-9, 2018.
- [17] Acı M, Ayyıldız Doğanşoy G. "Demand forecasting for e-retail sector using machine learning and deep learning methods". *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37(3), 1325-1339, 2021.
- [18] Demir L, Akkaş S. "A comparison of sales forecasting methods for a feed company: A case study". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(4), 705-712, 2018.

- [19] Kayapınar Kaya S, Yıldırım Ö. "A prediction model for automobile sales in Turkey using deep neural networks". *Journal of Industrial Engineering*, 31(1), 57-74, 2020.
- [20] Nacar EN, Erdebili B. "Makine öğrenmesi algoritmaları ile satış tahmini". *Endüstri Mühendisliği Dergisi*, 32(2), 307-330, 2021.
- [21] Goodfellow I, Bengio Y, Courville A. *Deep Learning*. 1st ed. Cambridge, USA, MIT Press, 2016.
- [22] Hochreiter S, Schmidhuber J. "Long short-term memory". *Neural Computation*, 9(8), 1735-1780, 1997.
- [23] Gers F, Schmidhuber J, Cummins F. "Learning to forget: continual prediction with LSTM". *Neural Computation*, 12(10), 2451-2471, 2000.
- [24] Karahan T, Nabiye V. "Plant identification with convolutional neural networks and transfer learning". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 27(5), 638-645, 2021.
- [25] Botchkarev A. "A new typology design of performance metrics to measure errors in machine learning regression algorithms". *Interdisciplinary Journal of Information, Knowledge and Management*, 14, 45-79, 2019.
- [26] Jierula A, Wang S, Oh TM, Wang P. "Study on accuracy metrics for evaluating the predictions of damage locations in deep piles using artificial neural networks with acoustic emission data". *Applied Sciences*, 11(5), 1-20, 2021.
- [27] Armstrong JS, Collopy F. "Error measures for generalizing about forecasting methods: Empirical comparisons". *International Journal of Forecasting*, 8(1), 69-80, 1992.
- [28] Martínez F, Frías MP, Pérez MD, Rivera AJ. "A methodology for applying k-nearest neighbor to time series forecasting". *Artificial Intelligence Review*, 52(3), 2019-2037, 2019.
- [29] Yi D, Ahn J, Ji S. "An effective optimization method for machine learning based on ADAM". *Applied Sciences*, 10(3), 1-20, 2020.