



Bir Çimento Firmasında İstatistiksel Zaman Serileri Yöntemleri ve Derin Öğrenme ile Talep Tahminleme

Fatma Demircan Keskin^{1*}, Haluk Soyuer²

^{1*} Ege Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, İstanbul, Türkiye, (ORCID: 0000-0000-0000-0000), xxxx@xxx.xx.xx

² Ege Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, İstanbul, Türkiye (ORCID: 0000-0000-0000-0000), xxxx@xxx.xx.xx

(1st International Conference on Engineering and Applied Natural Sciences ICEANS 2022, May 10-13, 2022)

(DOI: 10.31590/ejosat.1096898)

ATIF/REFERENCE: Demircan Keskin, F. & Soyuer, H. (2022). Bir Çimento Firmasında İstatistiksel Zaman Serileri Yöntemleri ve Derin Öğrenme ile Talep Tahminleme. *Avrupa Bilim ve Teknoloji Dergisi*, (36), 15-20.

Öz

Talep tahminleri, üretim planlama, finansal planlama, bütçeleme, satın alma, satış gibi birçok iş sürecinin yönetilebilmesi için kritik öneme sahiptir. Talep tahminlerinin yüksek doğrulukla elde edilmesi, tüm tedarik zinciri yönetimi süreçlerinin başarısı için kilit bir faktördür. Bu çalışmada talep tahminleme problemi, bir çimento firmasının en yüksek satış payına sahip bir ürün grubunun geçmiş satış verileri kullanılarak ele alınmıştır. Ele alınan veri seti tek değişkenli bir zaman serisidir. Veri setinin ilk üç yılı eğitim, son yılı ise test seti olarak kullanılmıştır. Tahminleme için öncelikle geleneksel istatistiksel zaman serileri analiz yöntemleri uygulanmıştır. Eğitim setinde, uygulanan yöntemler içinde en başarılı olan istatistiksel zaman serileri yöntemi Basit Mevsimsel Yöntem (Simple Seasonal Method - SSM) olmuştur. SSM modelinin performansı, derin öğrenme yöntemlerinden Uzun-Kısa Süreli Bellek (Long-Short Term Memory-LSTM) temelli olarak geliştirilen modelin performansıyla karşılaştırılmıştır. LSTM modeli geliştirilirken ızgara (grid) arama yapılmış ve hiper-parametrelerin değerleri için en başarılı kombinasyon belirlenmiştir. Bu konfigürasyonla eğitilen LSTM modeli test setinde uygulanmıştır. Modellerin test setindeki tahmin performansları karşılaştırıldığında, LSTM modelinin SSM modeline göre MAPE ölçütünde %34,57, RMSE ölçütünde ise %33,74 iyileştirme sağladığı görülmüştür.

Anahtar Kelimeler: Talep tahminleme, Tek değişkenli zaman serileri, İstatistiksel zaman serileri yöntemleri, Derin öğrenme, LSTM.

Demand Forecasting with Statistical Time Series Analysis Methods and Deep Learning in a Cement Firm

Abstract

Demand forecasts are critical for managing various business processes, including production planning, financial planning, budgeting, purchasing, and sales. Therefore, obtaining demand forecasts with high accuracy is a critical factor in successfully managing all supply chain management processes. This study addresses the demand forecasting problem by using actual past sales data of a cement firm's one product group, which has the largest sales share among all product groups. The handled data set is a univariate time series. The first three years of the data set are used as the training set; the remaining one-year data is used as the test set. Firstly, classical statistical time series analysis methods are applied to the training data. Among the methods, the Simple Seasonal Method (SSM) has the best performance. The performance of the SSM model is compared to the model developed based on Long-Short Term Memory (LSTM), a deep learning method well-known for its success for time series data. A grid search approach is performed to determine the best combination of the values of hyper-parameters for LSTM models. Finally, the selected LSTM model configuration is applied to the test set. The prediction performances of the models in the test set indicate that the LSTM model provides 34.57% improvement in the MAPE criterion and 33.74% in the RMSE criterion compared to the SSM model.

Keywords: Demand forecasting, Univariate time series, Statistical time series analysis methods, Deep learning, LSTM.

* Sorumlu Yazar: fatma.demircan.keskin@ege.edu.tr

Bu çalışma, sorumlu yazarın doktora tezine dayalı olarak üretilmiştir.

1. Giriş

Çimento üretim süreci süreç endüstrilerinin altında yer almakta ve bu endüstrinin birçok tipik özelliğini taşımaktadır. Süreç endüstrileri [1] tarafından “Karıştırma, ayırma, şekil verme veya kimyasal tepkimeler gerçekleştirerek malzemelere değer katan işletmeler” olarak tanımlanmaktadır.

Çimento üretim süreci hammaddenin hazırlanmasından başlanarak çimento öğütme ve paketleme aşamasına kadar bir dizi aşama içeren, kullanılan ekipman ve makinelerin oldukça yüksek maliyetli olduğu bir süreçtir. Süreçteki en büyük maliyet kalemlerinden biri olan elektrik enerjisi maliyeti, gün içinde üç farklı zaman diliminde farklı düzeylerde olmaktadır. Bu nedenle üretimin hangi zaman diliminde yapıldığı maliyetler açısından son derece önemlidir. Süreçte kapasite kullanımının yüksek seviyelerde tutulmasına odaklanılması, hem enerji maliyetinde hem de talebin düşük olduğu zaman dilimlerinde gereksiz yere ürün stoğu tutmaktan kaynaklı yüksek stoklama maliyetlerine sebep olabilmektedir.

Bu maliyetlerin önüne geçmek için, üretim planlama ve çizelgelemenin en önemli girdilerinden olan talep tahminlerinin başarılı bir şekilde elde edilmesi kritik öneme sahiptir.

İş süreçleri yönetiminin temel parçalarından biri olan talep tahmini, tahminlerin ilişkili olduğu değişkenlerin ve sürecin yapısına, talebin desenine ve ne kadarlık bir zaman dönemi için yapılacağına başta olmak üzere birçok faktöre bağlı olarak değişkenlik göstermektedir. Talep tahminleme sürecinin karmaşıklığı değişse de amaçlanan her zaman, geçmiş veriler ışığında bir ürün için gelecekteki talebin yüksek doğrulukla tahminini elde etmektir [2].

Tahminleme yöntemleri en genel olarak sayısal ve sayısal olmayan yöntemler şeklinde sınıflandırılabilir. Sayısal tahmin yöntemlerinde tarihsel ya da nedensel değişkenler kullanılarak çeşitli matematiksel modeller ile tahminler elde edilmektedir. Sayısal olmayan yöntemlerde ise tahminleme süreci sezgiler, kişisel düşünceler ve insan faktörünü içermekte, kesin sayısal ifadeler kullanılmamaktadır [3].

Sayısal tahminleme yöntemlerinden biri olan nedensel yöntemlerde, tahmin edilecek değişken ile onunla nedensellik ilişkisi olduğu düşünülen bir dizi tahminleyici değişken kullanılabilir ve aralarında istatistiksel bir ilişki kurulmaya çalışılmaktadır [4]. Diğer sayısal tahmin yöntemi olan zaman serileri analizinde, bir dönem içinde ardışık olarak alınan gözlemler dizisini ifade eden zaman serilerinde, gözlemler arasındaki bağımlılık çeşitli tekniklerle analiz edilmektedir [5]. Zaman serileri analizinde tahmin modelleri oluşturmak için genellikle sadece zaman serisi verileri kullanılmakta, zaman serilerinin bileşenleri olan trend, mevsimsellik ve döngüsel dalgalanmaların etkilerini ölçmeye odaklanılmaktadır [4].

Zaman serileri kullanılarak yapılan analizlerde geleneksel istatistiksel yöntemlerin yanında, özellikle son yıllarda giderek artan bir şekilde makine öğrenmesi ve derin öğrenme yöntemleri uygulanmaktadır ([6], [7], [8], [9]).

Bu çalışmada, tek değişkenli bir gerçek bir veri seti üzerinde, istatistiksel zaman serileri analiz ve derin öğrenme yöntemlerinin tahminleme performansı karşılaştırılmak istenmektedir. Bunun için çimento sektöründe faaliyet gösteren bir firmayı bir ürün grubuna ilişkin geçmiş satış verileri kullanılmıştır. Öncelikle tek değişkenli istatistiksel zaman

serileri yöntemleri, oluşturulan eğitim veri setine uygulanmış ve modellerin uyum istatistikleri incelenerek en iyi model seçilmiştir. En iyi modelin test veri seti üzerindeki performansı elde edilmiştir. Bunu takiben, aynı eğitim ve test veri seti kullanılarak literatürde zaman serilerinde başarılı uygulamaları olan derin öğrenme yöntemlerinden LSTM uygulanmış ve performansları karşılaştırılmıştır.

Çalışmanın bir sonraki bölümünde talep tahminlemede tek değişkenli zaman serileri yöntemleri ve tek değişkenli LSTM uygulamaları yapan önceki çalışmalardan bahsedilmiştir. Bunun ardından veri seti açıklanmış, uygulanan yöntemler ve veri hazırlık aşamaları detayları ile sunulmuştur. Ardından bulgular sunulmuş ve değerlendirmeler yapılmıştır.

2. Önceki Çalışmalar

Literatürde istatistiksel tek değişkenli zaman serileri analizi yöntemlerini ve tek değişkenli LSTM ağ yapılarını uygulayarak talep tahminleme yapan çok sayıda çalışma bulunmaktadır. Burada yakın zamanlı çalışmalara odaklanılarak bir inceleme yapılmıştır.

[10], bir perakendeci firmanın perakende satışlarına ilişkin bir örnek olayı ele almış ve Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average – ARIMA) ve Üstel Düzeltme tabanlı modeller uygulayarak tahmin performanslarını karşılaştırmıştır. [11], Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average - SARIMA) Modelleri ve Holt-Winters Üstel Düzeltme yöntemlerini uygulayarak satış tahminleme yapmışlardır. Performans kriterlerine göre en başarılı tahmin modeli SARIMA model $(1,1,0) (0,1,0)^{12}$ olmuştur.

[12], e-ticaret platformlarında, talepleri birbirileri ilişkilendirilebilecek ürünler için, ürünler arasındaki doğrusal olmayan talep ilişkilerini temel alan bütünleşik bir LSTM tabanlı bir talep tahminleme yaklaşım önermişlerdir.

[13] çok katmanlı LSTM ağları tabanlı bir talep tahminleme yaklaşımı önermiştir. Çalışmalarında farklı hiper-parametre kombinasyonlarını izgara arama yöntemi ile denemiş ve en iyi tahminleme modelini seçmişlerdir. LSTM tabanlı modelin performansını ARIMA ve Üstel Düzeltme gibi istatistiksel zaman serileri analiz yöntemleri ve çeşitli yapay zeka tabanlı yöntemlerin performanslarıyla karşılaştırmışlardır. Önerdikleri yaklaşım, denenen tüm modeller arasında en yüksek performansı göstermiştir.

[14], tedarik zinciri yönetiminde nihai tüketici talep tahminlemesi problemini LSTM ile ele almış, gerçek veri setleri üzerinde geliştirdikleri LSTM modellerinin performansını değerlendirmişlerdir.

[15], bir perakende mağazasının satış verilerini kullanarak satış tahmini yapmıştır. Çalışmalarında SARIMA ve Üstel Düzeltme Yöntemi olmak üzere istatistiksel zaman serileri analiz yöntemlerini ve LSTM, Evrimsel Sinir Ağları (Convolutional Neural Network - CNN) ve Prophet yöntemlerini uygulamışlardır. Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error – MAPE) ve Kök Ortalama Kare Hata (Root Mean Square Error – RMSE) kriterlerine göre yaptıkları tahminleme performans değerlendirmesinde en başarılı sonuçlara LSTM ile ulaşmışlardır.

3. Materyal ve Metot

2.1. Veri Seti

Bu çalışmanın veri setini çimento sektöründe faaliyet gösteren bir firmanın, toplam satışları içinde en yüksek paya sahip olan ürün grubunun 4 yıl boyunca gerçekleştirilen satış miktarları oluşturmaktadır. Bu satış miktarları bayiler aracılığıyla ve doğrudan müşteriye yapılan satışların toplamını içermektedir.

Analiz öncesi satış verileri gün sayısı bakımından (1) no'lu denklem kullanılarak düzeltilmiştir:

$$GSD_t = \frac{30}{\text{Düzeltilme yapılacak aydaki gün sayısı}} * Y_t \quad (1)$$

GSD_t : t ayına ilişkin gün sayısı bakımından düzeltilmiş satış miktarı


Y_t : t ayında yapılan satış miktarı

Gün sayısı bakımından düzeltilmiş satış verilerinin bir kısmı Tablo 1'de özet olarak verilmektedir.

Tablo 1. Özet Satış Verileri

Yıl	Ay	Satış Miktarı (ton)
Y1	1	36.026,12
Y1	2	32.717,38
Y1	3	35.368,96
---	---	---
Y4	10	51.462,58
Y4	11	68.819,30
Y4	12	51.955,72

Çalışmada uygulanan modelleri eğitmek için ilk 3 yıldaki veriler, modellerin performanslarını test etmek için ise son 1 yıldaki veriler kullanılmıştır. Eğitim ve test verisi Şekil 1'de grafik olarak sunulmaktadır.



Şekil 1. Analiz periyodu boyunca gerçekleşen aylık satış miktarları

2.2. İstatistiksel Zaman Serileri Yöntemleri ile Talep Tahminleme

Bu çalışmada istatistiksel zaman serileri analizleri SPSS 15 programında zaman serileri modelleyicisi kullanılarak, Tek Üstel Düzeltme Yöntemi, Holt'un Doğrusal Yöntemi, SSM, Toplamsal Holt-Winters Yöntemi, Çarpımsal Holt-Winters

Yöntemi ve ARIMA modelleri uygulanarak yapılmıştır. Yöntemler arasında, MAPE ve RMSE performans kriterlerine göre, eğitim verisinde en iyi tahminleri veren model seçilmiştir. MAPE ve RMSE'nin formülleri sırasıyla (2) ve (3) no'lu denklemlerde ifade edilmiştir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2} \quad (3)$$

Denklem (2)- (3)'te:

Y_t : t periyodundaki gerçekleşen talep değeri
 F_t : t periyodundaki tahminlenen talep değeri

Uygulanan tüm istatistiksel zaman serileri analizi yöntemlerinin matematiksel ifadeleri aşağıda sunulmaktadır:

Tek Üstel Düzeltme Yöntemi

Matematiksel ifadesi ([16]):

$$F_{t+1} = \alpha Y_t + (1 - \alpha) F_t \quad (4)$$

Holt'un Doğrusal Yöntemi

Matematiksel ifadesi ([17]):

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

$$F_{t+m} = L_t + b_t m \quad (7)$$

SSM

Matematiksel ifadesi ([18]):

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)L_{t-1} \quad (8)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (9)$$

$$F_{t+m} = L_t + S_{t+m-s} \quad (10)$$

Toplamsal Holt-Winters Yöntemi

Matematiksel ifadesi ([17]):

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (11)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (12)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (13)$$

$$F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (14)$$

Çarpımsal Holt-Winters Yöntemi

Matematiksel ifadesi ([19]):

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (15)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (16)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (17)$$

$$F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (18)$$

Denklem (4)- (18)'da:

F_{t+1} : t+1 periyodundaki tahminlenen talep değeri

F_t : t periyodundaki tahminlenen talep değeri

Y_t : t periyodundaki gerçekleşen talep değeri

L_t : t zamanında serinin genel seviyesi

b_t : Trend bileşeni

F_{t+m} : m periyot ilerisinin tahmin değeri

S_t : Mevsimsel bileşen

s: Mevsimsel uzunluk

α, β ve γ : Değerleri 0 ile 1 arasında olabilen düzeltme parametreleri

ARIMA

Matematiksel ifadesi ([20]):

$$y_t = \theta_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (19)$$

y_t, \dots, y_{t-p} : Gerçek değer
 ϕ_1, \dots, ϕ_p : d dereceden farkı alınmış gözlem değerleri için katsayılar

$\varepsilon_t, \dots, \varepsilon_{t-q}$: Rassal hata terimleri

$\theta_0, \dots, \theta_q$: Hata terimleri ile ilgili katsayılar

p: AR modelinin derecesi

q: MA modelinin derecesi

2.3. LSTM ile Talep Tahminleme

Bir Tekrarlayan Sinir Ağları (Recurrent Neural Networks – RNN) mimarisi olan LSTM, RNN'nin bilgiyi kısa zamanlı tutabilmesi ve RNN'de geri yayılımda kaybolan gradyan sorunu ile karşılaşılabilecek problemlerinin üstesinden gelmek amacıyla oluşturulmuş ağ yapısıdır [21]. LSTM mimarisinde hangi bilginin ne kadar süre kalacağını, ne zaman unutulacağını belirlemek de dahil olmak üzere bilgi akışları, giriş, unutma ve çıkış kapıları aracılığıyla düzenlenmektedir [22].

LSTM blok diyagramı aşağıda matematiksel ifadeleri sunulan üç kapı ve iki aktivasyon fonksiyonunu içermektedir [23].

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (20)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (21)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (22)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (23)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (24)$$

$$h_t = o_t \odot \tanh(c_t) \quad (25)$$

Matris çarpımı $W_f[h_{t-1}, x_t] = W_h h_{t-1} + W_x x_t$ şeklinde olmak üzere, (20)-(25) no'lu denklemlerde f_t unutma kapısının sonucu, i_t giriş kapısının sonucu, o_t çıktı kapısının sonucu, \tilde{c}_t yeni hücre durumu, c_t son hücre durumu ve h_t hücre çıktısını ifade etmektedir. W_f, W_i ve W_o sırasıyla unutma, girdi ve çıktı kapılarının ağırlıklarını; b_f, b_i, b_o ise sırasıyla unutma, girdi ve çıktı katmanlarının sapmalarını göstermektedir. \odot Hadamard çarpımını, σ lojistik sigmoid fonksiyonunu, \tanh ise hiperbolik tanjant fonksiyonunu ifade etmektedir [23].

LSTM modeli uygulanmadan önce, gün sayısına göre düzeltilmiş aylık satış verileri Min-Max normalizasyonu ile normalize edilmiştir. LSTM modelinin hiper-parametreleri GridSearchCV() metoduyla ızgara arama yapılarak ve veri setinin küçük boyutlu olması sebebiyle 3 katlı çapraz doğrulama yapılarak belirlenmiştir. LSTM modellerine ilişkin uygulamalarda Python programlama dilinin 3.9.9 versiyonu kullanılmıştır. Modeller 1,2,3,4 olmak üzere farklı zaman adımları (time step) için çalıştırılmıştır.

ızgara aramada farklı parti boyutları (batch size), döngü sayıları (epoch), nöron sayıları, seyreltme değerleri ve optimizasyon yöntemleri denenmiş ve MAPE ve RMSE kriterlerine göre en uygun model bulunmaya çalışılmıştır. Tüm modeller 10 kez çalıştırılmıştır. Deneysel çalışmalarda kullanılan hiper-parametre değerleri Tablo 2'de sunulmaktadır:

Tablo 2. Deneysel çalışmalarda kullanılan hiper-parametre değerleri

Hiper-parametre	Değer
Parti boyutu	2,4,8,16,32
Döngü sayısı	10, 50, 100

Nöron sayısı	2, 10, 50
Seyreltme değeri	0 - 0,2 - 0,5
Optimizasyon yöntemleri	SGD, Adam

4. Bulgular

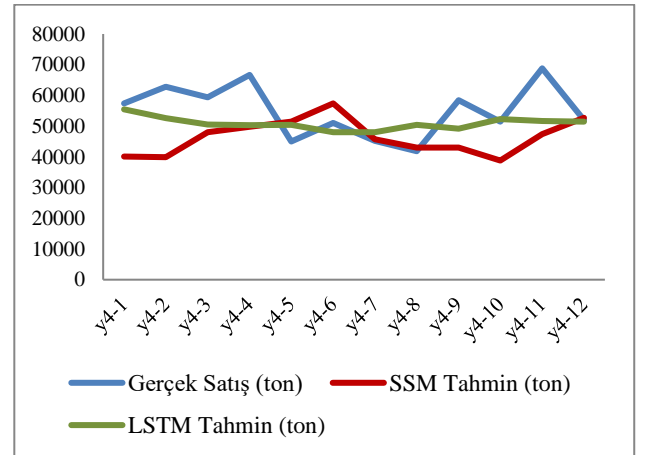
Çalışmada kullanılan eğitim veri setine SPSS 15 programında zaman serileri modelleyicisi kullanılarak tek değişkenli istatistiksel zaman serileri yöntemleri uygulanmıştır. MAPE ve RMSE performans kriterlerine göre en başarılı model SSM ile elde edilmiştir. SSM modelinin tahmin edilen parametreleri $\alpha=0,4$ ve $\gamma=6,88E-007$ olmuştur. Eğitim setinde SSM modelinin uyum istatistiklerine bakıldığında MAPE değeri %12,058 ve RMSE değeri 6680,887 ton olarak görülmüştür.

LSTM uygulamasında ise, yapılan ızgara aramasında MAPE ve RMSE performans kriterlerine göre en başarılı sonucu veren hiper-parametre kombinasyonu seçilmiştir. Bu kombinasyonda zaman adımı 3, parti boyutu 2, döngü sayısı 50, nöron sayısı 50, optimizasyon yöntemi Adam olmuştur. En iyi LSTM modelinin eğitim setindeki MAPE değeri %12,748 ve RMSE değeri 7873,605 ton olarak elde edilmiştir.

Bu konfigürasyon ile modelin 10 kez çalıştırılması sonucu elde edilen ortalama tahminler kaydedilmiştir. Eğitilen modeller ile test setinde aylık tahminler elde edilmiş ve tahminler gün sayısına göre düzeltilmiştir. Modellerin test setindeki performansları Tablo 3'te sunulmaktadır. Şekil 2'de ise test setinde gerçek satış değerleri ve model tahminleri grafik olarak sunulmuştur.

Tablo 3. Test setinde model performansları

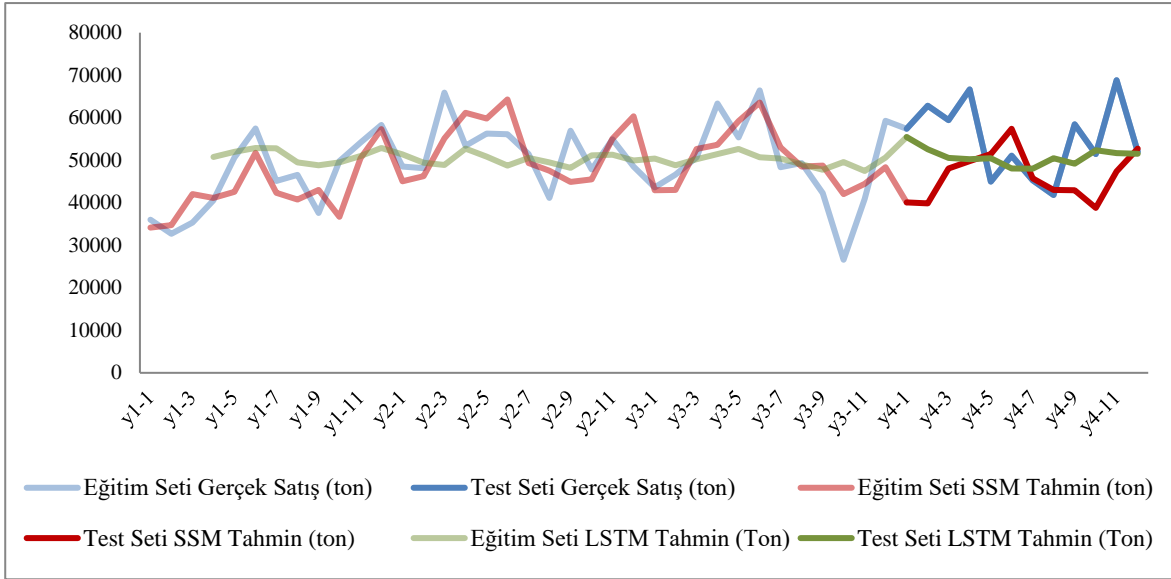
Performans Kriterleri	SSM Modeli	LSTM Modeli
MAPE	%18,784	%,12, 278
RMSE	13489,163 ton	8938,473 ton



Şekil 2. Test setinde gerçek satış ve model tahminleri

Tablo 3'te görüldüğü gibi, test setinde LSTM modeli, hem MAPE hem de RMSE ölçütünde SSM modelinden oldukça başarılı sonuçlar vermiştir. Test setinde LSTM modelinin tahmin performansı SSM modeline göre MAPE ölçütünde %34,57, RMSE ölçütünde ise %33,74 daha iyidir.

Eğitim ve test setini kapsayacak şekilde tüm veri seti için model tahminleri ve gerçek satış değerleri Şekil 3'te sunulmaktadır.



Şekil 3: Tüm veri seti için gerçek satış ve model tahminleri

5. Sonuç

Talep tahminleri işletmelerin üretim planlama ve kontrol sistemleri için temel girdiyi oluşturmaktadır. Talebin yüksek doğrulukla tahminlenmesi işletmelerin tedarik zinciri süreçlerini etkin bir şekilde yönetebilmeleri için kritik öneme sahiptir.

Bu çalışmada tek değişkenli zaman serilerinde talep tahminleme problemi ele alınmıştır. Zaman serilerinde tahminleme problemlerinde özellikle son yıllarda derin öğrenme tabanlı modellere sıklıkla başvurulmakta ve başarılı sonuçlar elde edilmektedir. Bu noktadan hareketle, bu çalışmada, zaman serilerindeki başarılı uygulamaları ile ön plana çıkan derin öğrenme yaklaşımlarından LSTM uygulanmıştır. LSTM'nin performansı, geleneksel istatistiksel zaman serisi analiz yöntemleri ile karşılaştırılarak değerlendirilmiştir.

Çalışmanın veri setini, bir çimento firmasının bir ürün grubuna ilişkin dört yıl boyunca gerçekleştirilmiş olan aylık satış verileri oluşturmaktadır. Veri setinin ilk üç yılı eğitim, son bir yılı test seti olarak kullanılmıştır. Geliştirilen modellerin tahmin performansı MAPE ve RMSE performans ölçütleri ile değerlendirilmiştir.

Eğitim seti için uygulanan istatistiksel tek değişkenli zaman serileri yöntemlerinden en başarılı sonucu veren model SSM olmuştur.

LSTM modelleri geliştirilirken eğitim setinde hiperparametreler için çok sayıda değer ızgara arama ile denenmiş ve en başarılı kombinasyon belirlenmiştir. Eğitilen SSM ve LSTM modellerinin test setinde uygulanmıştır.

Bulgular, test setinde LSTM modelinin hem MAPE hem de RMSE ölçütlerine göre daha başarılı olduğuna işaret etmektedir. LSTM modeli ile elde edilen tahminlerin MAPE'si % 12,278, RMSE değeri ise 8938,473 ton olarak elde edilmiştir.

LSTM modeli, test setinde talep tahminlemede, SSM modeline göre MAPE ölçütünde %34,57, RMSE ölçütünde ise %33,74 iyileştirme sağlamıştır. Çalışmada ele alınan çimento firmasının en yüksek satış payına sahip bu ürün grubu için talep tahminlerinin doğruluğunda gerçekleştirilen bu iyileştirmenin, üretim planlarına ve kısa dönemli üretim çizelgelerine

yansıtacağı düşünülmektedir. LSTM modeli ile elde edilen tahminler göz önünde bulundurularak üretimin planlanması ve çizelgelenmesi, üretimin düşük elektrik enerjisi maliyetinin olduğu zaman dilimlerinde yoğunlaştırılmasına ve ürün stoklama maliyetlerinin düşürülmesine imkan sağlayacaktır.

LSTM modelinin tahminleme performansında sağladığı bu iyileştirme, küçük boyutlu zaman serilerinde dahi derin öğrenme algoritmalarının başarılı performans gösterdiklerine dair bir örnek sunmaktadır.

6. Teşekkür

Yazarlar, SAN-TEZ Programı kapsamında 0426.STZ.2013-2 proje numarası ile bu teze destek veren TC Sanayi ve Teknoloji Bakanlığı Bilim ve Teknoloji Genel Müdürlüğü'ne ve proje boyunca desteklerini esirgemeyen firma yetkililerine teşekkür eder. Yazarlar ayrıca, 2211 Yurtiçi Doktora Burs Programı ile bu çalışmanın sorumlu yazarına doktora eğitimi boyunca destek verdiği için TÜBİTAK'a teşekkür eder.

Kaynakça

- [1] APICS Dictionary (1987), American Production and Inventory Control Society, Inc., Falls Church, VA.
- [2] Merkuryeva, G., Valberga, A., & Smirnov, A. (2019). Demand forecasting in pharmaceutical supply chains: A case study. *Procedia Computer Science*, 149, 3-10.
- [3] Stevenson, W. J. (2012). *Operations Management*. 11th Edition. McGraw-Hill Global Education.
- [4] Lawrence, K. D., & Klimberg, R.K. (Eds.). (2018). *Advances in business and management forecasting*. Volume 12. Emerald Group Publishing.
- [5] Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- [6] Bontempi, G., Ben Taieb, S., & Borgne, Y. A. L. (2012, July). Machine learning strategies for time series forecasting. In *European business intelligence summer school* (pp. 62-77). Springer, Berlin, Heidelberg.
- [7] Loureiro, A. L., Miguéis, V. L., & da Silva, L. F. (2018). Exploring the use of deep neural networks for sales

- forecasting in fashion retail. *Decision Support Systems*, 114, 81-93.
- [8] Wanchoo, K. (2019, March). Retail demand forecasting: a comparison between deep neural network and gradient boosting method for univariate time series. In *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)* (pp. 1-5). IEEE.
- [9] Mahmoud, A., & Mohammed, A. (2021). A survey on deep learning for time-series forecasting. In *Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges* (pp. 365-392). Springer, Cham.
- [10] Ramos, P., Santos, N., & Rebelo, R. (2015). Performance of state space and ARIMA models for consumer retail sales forecasting. *Robotics and computer-integrated manufacturing*, 34, 151-163.
- [11] Pongdatu, G. A. N., & Putra, Y. H. (2018, August). Seasonal time series forecasting using SARIMA and Holt Winter's exponential smoothing. In *IOP Conference Series: Materials Science and Engineering* (Vol. 407, No. 1, p. 012153). IOP Publishing.
- [12] Bandara, K., Shi, P., Bergmeir, C., Hewamalage, H., Tran, Q., & Seaman, B. (2019, December). Sales demand forecast in e-commerce using a long short-term memory neural network methodology. In *International conference on neural information processing* (pp. 462-474). Springer, Cham.
- [13] Abbasimehr, H., Shabani, M., & Yousefi, M. (2020). An optimized model using LSTM network for demand forecasting. *Computers & industrial engineering*, 143, 106435.
- [14] Pacella, M., & Papadia, G. (2021). Evaluation of deep learning with long short-term memory networks for time series forecasting in supply chain management. *Procedia CIRP*, 99, 604-609.
- [15] Ensafi, Y., Amin, S. H., Zhang, G., & Shah, B. (2022). Time-series forecasting of seasonal items sales using machine learning—A comparative analysis. *International Journal of Information Management Data Insights*, 2(1), 100058.
- [16] Goh, C., & Law, R. (2002). Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. *Tourism management*, 23(5), 499-510.
- [17] Chase, C. W. (2013). *Demand-driven forecasting: a structured approach to forecasting*. John Wiley & Sons.
- [18] Dankwa, P., Cudjoe, E., Amuah, E. E. Y., Kazapoe, R. W., & Agyemang, E. P. (2021). Analyzing and forecasting rainfall patterns in the Manga-Bawku area, northeastern Ghana: Possible implication of climate change. *Environmental Challenges*, 5, 100354.
- [19] Chatfield, C., & Yar, M. (1988). Holt-Winters forecasting: some practical issues. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 37(2), 129-140.
- [20] Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- [21] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [22] Bandara, K., Bergmeir, C., & Smyl, S. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert systems with applications*, 140, 112896.
- [23] Khalil, K., Eldash, O., Kumar, A., & Bayoumi, M. (2019). Economic LSTM approach for recurrent neural networks. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 66(11), 1885-1889.