

Uzun Kısa Vadeli Bellek Yöntemi ile Havayolu Yolcu Tahmini

Ömer Osman DURSUN^{1*} , Suat TORAMAN² 

¹ Fırat Üniversitesi, Sivil Havacılık Yüksekokulu, Uçak Elektrik Elektronik Bölümü, Elazığ, Türkiye

² Fırat Üniversitesi, Sivil Havacılık Yüksekokulu, Hava Trafik Kontrol Bölümü, Elazığ, Türkiye

Özet

Havayolu taşımacılığında uçuş operasyonlarının planlanması önemlidir. Uçuş operasyonları planlanırken en önemli unsur yolcu sayısıdır. Yolcu sayısını belirli bir zaman dilimi için tahmin etmek, havayolu firmasının planlamalarını daha uygun bir şekilde gerçekleştirmelerine yardımcı olabileceği gibi maliyetten de tasarruf etmelerini sağlayacaktır. Çalışmada, uzun kısa vadeli bellek (LSTM) yöntemi kullanılarak havayolu yolcu sayısı tahmin edilmiştir. Elazığ Havalimanına ait yolcu sayısı Vanilla LSTM yöntemi kullanılarak tahminleme gerçekleştirilmiştir. Önerilen yöntem ile Elazığ Havalimanına ait yolcu sayısı tahminlemede ortalama kare hata (MSE) sıfıra yakın ve karekök ortalama karesel hata (RMSE) 0.02 olarak bulunmuştur. Deneysel sonuçlar önerilen yaklaşımın havayolu yolcu tahminine katkı sağlayabileceğini göstermiştir.

Anahtar Kelimeler: Uzun kısa vadeli bellek, Havayolu yolcu tahmini, Tekrarlayan sinir ağları

Air Passenger Forecasting with Long Short Term Memory Method

Abstract

Flight operations planning is fundamental in air transport. The most important factor when flight operations planning is the number of passengers. Estimating the number of passengers for a specific period can help the airline plan more conveniently and save costs. In the study, the number of airline passengers is estimated using the long short-term memory (LSTM) method. The passenger number dataset of Elazığ Airport is predicted using the Vanilla LSTM method. In the proposed method, Mean Square Error (MSE) is close to zero and Root Mean Square Error (RMSE) is found 0.02 in estimating the number of passengers belonging to Elazığ Airport. Experimental results showed that the proposed approach could contribute to airline passenger estimation.

Keywords: Long short term memory, Air passenger prediction, Recurrent neural network

Corresponding Author/Sorumlu Yazar: Ömer Osman Dursun oodursun@firat.edu.tr

Citation/Alıntı: Dursun Ö. O., Toraman S. (2021). Uzun Kısa Vadeli Bellek Yöntemi ile Havayolu Yolcu Tahmini J. Aviat. 5 (2), 241-248.

ORCID: ¹ <https://orcid.org/0000-0001-5605-0419>; ² <https://orcid.org/0000-0002-7568-4131>

DOI: <https://doi.org/10.30518/jav.1009331>

Gelis/Received: 13 Ekim 2021 **Kabul/Accepted:** 29 Kasım 2021 **Yayınlanma/Published (Online):** 20 Aralık 2021

Copyright © 2021 Journal of Aviation <https://javsci.com> - <http://dergipark.gov.tr/jav>



This is an open access article distributed under the terms of the Creative Commons Attribution 4.0 International Licence

1. Giriş

Son zamanlarda Covid-19 pandemiden kaynaklı küresel salgının etkisiyle birçok sektör olumsuz olarak etkilenmiştir. Salgından en çok etkilenen sektörlerin başında havacılık sektörü gelmektedir. Salgından kaynaklı ulaşım alanındaki kısıtlamalar küresel ekonomide bozulmalara yol açmış bu durum havacılık sektörünü durma noktasına getirmiştir. Özellikle havayolu yolcu taşımacılığının durması mali sektörel sıkıntıları beraberinde getirmiştir.

Havayolu taşımacılığı, uçakları, havaalanlarını, uçuş rotalarını ve hava trafik yönetim sistemlerini içeren karmaşık bir sistemdir. Ulaştırma endüstrisindeki gelişim ve sosyo-ekonomik kalkınma havacılığın en önemli rollerinden biridir. Havayolu endüstrisinde, havayolu şirketlerinde yolcu talebinin tahmin edilmesi hayati önem taşımaktadır [1, 2]. Uçuş rotalarındaki sefer sayısının artırılması, havalimanlarının iyileştirilmesi, yeni hat açılması, bilet fiyatının değiştirilmesi gibi operasyon planlarının geliştirilmesi için uzun vadeli talep tahmini yapılması gerekmektedir. Ayrıca, kısa vadeli talep tahmini de havalimanı planlamasında, operasyonların düzenlenmesinde ve kısa vadeli bakım için önemli bir rol oynamaktadır [3]. Aynı zamanda havaalanı inşaatı için yüksek ekonomik maliyet ve zaman tüketimi hesaba katıldığında, tahminin ve öngörünün doğruluğunun ne derece önemli olduğu görülmektedir [4]. Yolcu talebini öngörmek, durağan olmama, yüksek oynaklık ve düzensizlik gibi sürecin çok yönlü özelliklerinden dolayı oldukça zordur [5].


Makine öğrenimi, karmaşık verilerden anlamlı sonuçlar çıkarmak için kullanılmaktadır. Gelişen

veri işleme sistemleri, bulut hizmetleri, çeşitli algoritmaların uygulanmasında kullanılan çok sayıda araç ve kütüphaneler sayesinde son birkaç yılda yeni tekniklerin uygulanması oldukça önem kazanmıştır. Bununla beraber, havacılık alanı, çoğunlukla yüksek kaliteli verilere erişimin zor olması veya hiç olmaması ayrıca yeni karmaşık modellere kıyasla basit tahmin modellerine bağlı kalınması sebebiyle diğer alanlara nazaran yeni teknik ve yöntemlerden yararlanamamıştır [6]. Yang vd. kentsel raylı sistemler için uzun-kısa vadeli bellek ağına dayanan tahminleme modeli geliştirmişlerdir [7]. Kanavos vd. havayolu yolcu taşımacılığı için zaman serilerine dayanan otoregresif hareketli ortalama (ARIMA) ve derin öğrenmeye dayalı model önermişlerdir [2]. Tang vd. kentsel taşıma sistemi için mekânsal-zamansal grafik evrimsel ağına dayalı olarak bölge düzeyinde çok topluluklu yolcu talebi tahmini gerçekleştirmişler [8]. Zhu ve Li derin öğrenme yaklaşımıyla yakıt doldurma kararları için uçuş süresi tahmini yapmışlardır [9].

Çalışmanın 2. bölümünde veriler, uygulanan Vanilla LSTM yöntemi detaylı olarak açıklanmıştır. Deneysel sonuçlar ve tartışma 3. bölümde sunulmuştur. En son bölümde ise sonuç kısmı verilmiştir.

2. Materyal ve Metot

Çalışmada, Elazığ iline ait havayolu yolcu verileri kullanılmıştır. Sonraki adımda elde edilen yolcu verilerine normalizasyon işlemi uygulanmıştır. Normalizasyon uygulanan veriler Vanilla LSTM ile modellenerek yolcu tahmini gerçekleştirilmiştir. Şekil 1'de, çalışmanın akış şeması verilmiştir.



Şekil 1. Çalışmanın akış şeması

2.1. Verilerin elde edilmesi

Elazığ Havalimanı'na ait 2007 Ocak – 2021 Ağustos sonu yolcu verileri Devlet Hava Meydanları İşletmesi Genel Müdürlüğü'nden elde edilmiştir. Yolcu verileri yıllara göre aylık olarak

alınmıştır. Elazığ Havalimanı için yıllara göre aylık olarak alınan iç hat ve dış hat yolcu sayılarının toplamı, toplam yolcu sayısı olarak değerlendirilmiştir [10]. Toplam 176 verinin %80'i

Vanilla LSTM modelinin eğitimi için geriye kalan %20'si ise test edilmesi için kullanılmıştır [11, 12].

2.2. Normalizasyon

Normalizasyon, veri dağılımının farklı olduğu verileri tek bir düzen içerisinde ele almayı ve karşılaştırılabilmesini sağlamaktadır. Çalışmada min-max normalizasyon yöntemi kullanılmıştır. Min-max normalizasyon yöntemi ile orijinal veri seti üzerinde doğrusal bir dönüşüm yapılmaktadır. Dönüşüm sonrasında veri seti [0-1] aralığına indirgenmiştir. Denklem 1'de min-max normalizasyon yönteminin matematiksel ifadesi görülmektedir.

$$x' = \frac{x_t - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Burada, x' normalize edilmiş veriyi, x_t t zamanındaki giriş değerini, x_{max} veri setindeki en büyük sayıyı, x_{min} veri setindeki en küçük sayıyı ifade etmektedir [11].

2.3. LSTM

Uzun Kısa Vadeli Bellek (LSTM) mimarileri genellikle zaman serisi tahmini ve öngörülerinde kullanılmaktadır. Konuşma tanıma ve metin tanıma gibi genellikle doğal dil işleme problemleri için sıklıkla kullanılan tekrarlayan sinir ağlarının (RNN) üzerine inşa edilmektedir. RNN'lerde her bir zaman adımındaki çıktı bir önceki hesaplamalara bağlı olarak işlenmektedir. Bu sayede RNN'ler geçmiş bilgileri taşıyıp ve onları hafızasında saklamaktadır. Ancak RNN'ler kısa vadede geleceği tahmin ve öngörmeyi başarırken, uzun vadeli bağımlı ve sıralı giriş verisinde anlamlı olabilecek bilgiyi ihmal edebilmektedir. Bir başka deyişle RNN'lerde dizi ne kadar uzunsa, önceki zaman adımlarından sonraki zaman adımlarına bilginin taşınması o oranda zorlaşacaktır. RNN'lerdeki diğer bir problemde sinir ağlarının ağırlıklarını güncellemek için kullanılan eğitim değerlerinin zaman içerisinde küçülmesidir. RNN geriye yayılım yaptığında eğitim değeri küçülmektedir. Eğitim değeri ne derecede küçülürse öğrenme oranı o oranda azalır. Küçük bir eğitim değeri ile güncellenen katmanda öğrenme oranı azalır ve bu durum uzun dizilerde RNN'nin kısa vadeli hafızaya sahip olmasına sebep olmaktadır. Bahsedilen problemlerin ortadan kaldırılması için LSTM mimarisi geliştirilmiştir [13].

LSTM, RNN'lerin performansını arttırmak, eğim ve uzun vadeli bağımlılık sorunlarını çözmek için tasarlanmıştır. LSTM'ler yeni tip hücre durumu yöntemiyle RNN'lerde ortaya çıkan sorunları gidermektedir. Bilgi her adımda hücre durumundan geçer ve geçişler sırasında değiştirilebilir. Böylece bilgi parçalarının unutulması veya hatırlanması sağlanır. LSTM'in matematiksel gösterimi Denklem 2-6'da gösterilmiştir. Burada, x_t giriş vektörünü, c_{t-1} önceki hücre hafızasını, h_{t-1} önceki hücre çıkışı, b eğim değerini, W her bir giriş değeri için ağırlık vektörünü, σ sigma aktivasyon fonksiyonunu, \tanh tanjant aktivasyon fonksiyonunu ifade etmektedir. Şekil 2'de LSTM modelinin blok diyagramı görülmektedir. LSTM mimarisi Şekil 2'de gösterilen durumlar ve kapılar aracılığıyla tanımlanmaktadır.

Unutma kapısı; hangi bilgilerin atılacağına veya hangi bilgilerin saklanacağına karar vermektedir. Kapı önceki hücrenin gizli durumu olan h_{t-1} değerini ve o zaman adımındaki x_t giriş değerini alır. Daha sonra h_{t-1} ve x_t kodlanarak ağırlıklarla çarpılır ve eğim değeri eklenir. Ardından bu değere sigmoid fonksiyonu uygulanarak 0 ve 1'lerden oluşan bir çıkış vektörü elde edilir. Elde edilen vektörün değerleri 0'a yaklaştıkça bilgileri unutması 1'e yaklaştıkça bilgileri tutması anlamına gelmektedir. Vektör değerleri hücre durumuna aktararak önceki hücre durumu olan c_{t-1} ile çarpılır. Unutma kapısının fonksiyonu Denklem 2'de gösterilmiştir.

Giriş kapısı; hücre durumunu güncellemek için kullanılmaktadır. İlk olarak önceki gizli durum h_{t-1} ve x_t mevcut giriş bir sigmoid aktivasyon fonksiyonundan geçirilir. Böylece 0 ile 1 arasında olan değerlere dönüştürülerek bir vektör oluşturulur. Bu vektör ile hangi değerlerin güncelleneceğine karar verilir. Daha sonra h_{t-1} ve x_t , \tanh aktivasyon fonksiyonundan geçirilerek -1 ile 1 arasında değerler veren bir vektör elde edilir. Sigmoid çıktısı \tanh çıktısındaki hangi bilgilerin saklanmasının önemli olduğuna karar verecektir. Son olarak her iki vektör çarpılarak hücre durumuna eklenir. Denklem 3'de giriş kapısının fonksiyonu görülmektedir.

Çıkış kapısı; bir \tanh aktivasyon fonksiyonu kullanılarak hücre durumunun değerleri -1 ile 1 arasında değişen bir vektöre dönüştürülür. Ardından unutma kapısına benzer bir şekilde hangi bilgilerin

çıkarılacağını veya taşınacağını seçmek için bir sigmoid aktivasyon fonksiyonu kullanılır. Daha sonra sigmoid ve tanh aktivasyon fonksiyonlarından elde edilen değerler çarpılarak bir sonraki zaman hücresinin gizli durumu h_t elde edilir. Çıkış kapısı fonksiyonu Denklem 4’te görülmektedir.

Hücre durumu; önceki hücre durumundan gelen bilgilerle unutma vektörü noktasal olarak çarpılır. Daha sonra giriş kapısından gelen ek bilgi ile hücre durumunu sinir ağının uygun bulunduğu yeni değerlere güncelleyen noktasal bir ekleme yapılır. Böylece gelecek yeni hücre durumu bilgisi elde edilirken h_t gelecek gizli duruma katkı sağlanmış

olur. Denklem 5’te yeni hücre durumu fonksiyonu, Denklem 6’da ise gelecek gizli durum fonksiyonu görülmektedir.

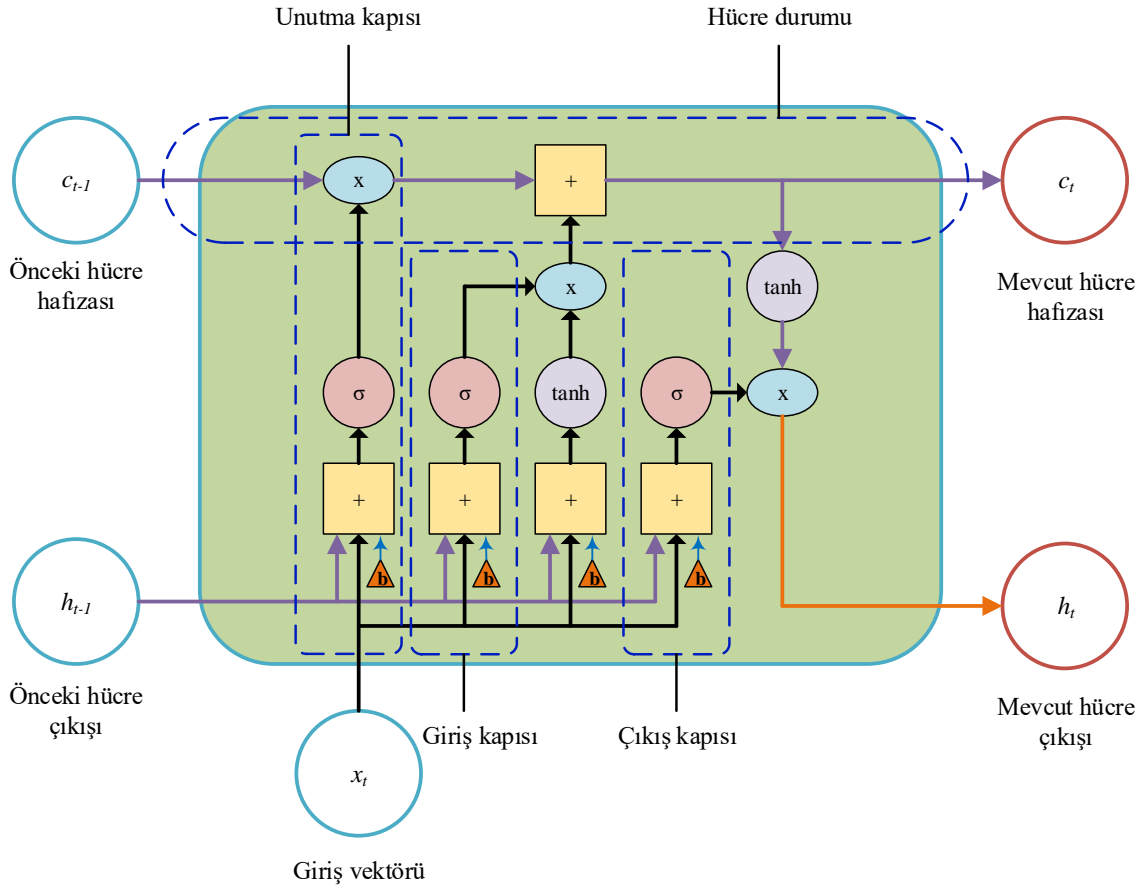
$$f_t = \sigma(W[x_t, h_{t-1}, c_{t-1}] + b_f) \quad (2)$$

$$i_t = \sigma(W[x_t, h_{t-1}, c_{t-1}] + b_i) \quad (3)$$

$$o_t = \sigma(W[x_t, h_{t-1}, c_t] + b_o) \quad (4)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tanh(W[x_t, h_{t-1}, c_{t-1}] + b_c) \quad (5)$$

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



Şekil 2. LSTM modelinin blok diyagramı

2.4. Oto regresif model

Oto regresif model (AR), geriye dönük değerlerin zaman serileri arasındaki korelasyonlarına bakarak basit lineer regresyon ile ileriye yönelik olasılıksal tahminleme yapılmasını sağlayan bir modeldir. Modelin matematiksel gösterimi Denklem 7’de gösterilmiştir.

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (7)$$

Burada c , φ sabit sayı, ε beyaz gürültü (rastgelelik) olarak ifade edilmektedir [14].

3. Deneysel Sonuçlar ve Tartışmalar

Bu bölümde, modele ait performans değerlendirme kriterleri, Vanilla LSTM modelinin parametre ayarları, tahmin sonuçları değerlendirilmiştir.

3.1. Performans değerlendirmesi

Önerilen çalışmada performans ölçümü ortalama karesel hata (MSE), karekök ortalama karesel hata (RMSE), R^2 , kayıp fonksiyonu (loss) olarak yapılmış ve değerlendirilmiştir. *MSE*, *RMSE* ve R^2 performans ölçütlerine ait denklemler Denklem 8-10'da görülmektedir. *MSE*, modelin hata oranını aynı zamanda başarımını ölçen fonksiyondur. *MSE*, modelin yapmış olduğu tahminin gerçek değerden ne kadar farklı olduğunu hesaplamaktadır. Gerçek değer ile tahmin değeri arasındaki fark ne kadar az ise o oranda iyi bir tahmin yapılmış olur. *MSE* değeri 0'a yaklaşırsa tahmin o oranda iyi gerçekleşmiş demektir [13-16].

$$MSE = \frac{1}{n} \sum_{t=1}^n (x_t - \bar{x}_t)^2 \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (x_t - \bar{x}_t)^2} \quad (9)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (x_t - \bar{x}_t)^2}{\sum_{t=1}^n x_t^2} \quad (10)$$

Burada, n örneklem sayısını, x_t , t zaman dilimindeki yolcu sayısını, \bar{x}_t , t zaman dilimindeki tahmin edilen yolcu sayısını ifade etmektedir.

3.2. Parametre ayarları

Yapılan çalışmada önerilen Vanilla LSTM modelinde optimizasyon algoritması olarak Adam, kayıp fonksiyonu olarak MSE kullanılmıştır. Döngü sayısı olarak 50, 100, 200, 500, 1000 değerleri denenmiş en iyi sonuç 200 değerinde elde edilmiştir. Modelde küme boyutu 3, 4, 8 gibi değerler denenmiş bunlar içerisinde en iyi sonuç 4 değerinde elde edilmiştir. LSTM modelinde gizli katman sayısı 1 olarak girilmiştir. Nöron sayısı olarak 8, 10, 16, 32, 50 değerleri modelde uygulanmış en iyi sonuç 16 değerinde elde edilmiştir. Modelde $[10^{-1}, \dots, 10^{-4}]$ aralığındaki değerler öğrenme oranı olarak kullanılmış en iyi sonuç $l_r = 10^{-2}$ değerinde bulunmuştur. Öğrenme

değeri 10^{-4} olarak alındığında modelin ezberlemeye başladığı görülmüştür. Önerilen LSTM modeline ait parametreler ve parametrelere ait en iyi değerler Tablo 1'de gösterilmiştir.

Tablo 1. Vanilla LSTM modelinde kullanılan parametreler ve en iyi değerleri

| Parametre | Değer |
|--------------------------|-------|
| Optimizasyon algoritması | Adam |
| Kayıp fonksiyonu | MSE |
| Döngü sayısı | 2000 |
| Küme boyutu | 4 |
| Gizli katman | 1 |
| Nöron sayısı | 32 |
| Öğrenme oranı | 0.001 |

3.3. Tahmin sonuçları ve tartışma

AR modelinin yolcu tahmininde *MSE* değeri 0.026, *RMSE* değeri 0.161 ve R^2 'si 0.615 olarak bulunmuştur. Bunun yanı sıra Vanilla LSTM modelinde *MSE* değeri 0'a çok yakın *RMSE* değeri 0.02 ve R^2 ise 0.98 olarak elde edilmiştir. Her iki model *MSE* değerleri açısından karşılaştırıldığında *MSE* değeri sıfıra yakın olan Vanilla LSTM modeli AR modeline göre daha iyi tahminleme yapmıştır. Ayrıca R^2 değerleri ele alındığında Vanilla LSTM modelinin R^2 değerinin AR modeline kıyasla daha büyük ve bire yakın olduğu görülmektedir. Bu sebeple Vanilla LSTM modeli AR modeline göre gerçeğe yakın bir tahminleme yapmıştır. Tablo 2'de her iki modelin tahminlemesine ait performans değerlendirmeleri görülmektedir.

Tablo 2. Modellerin performans değerlendirmesi

| AR | | | Vanilla LSTM | | |
|------------|-------------|-------|--------------|-------------|-------|
| <i>MSE</i> | <i>RMSE</i> | R^2 | <i>MSE</i> | <i>RMSE</i> | R^2 |
| 0.026 | 0.161 | 0.615 | 0.00 | 0.02 | 0.98 |


AR ve Vanilla LSTM modellerine 2007-2021 yılları arasındaki Elazığ iline ait yolcu verilerinin %80'i eğitim ve %20'si test verisi olarak verilmiştir. Eğitim sürecinden sonra modeller test verileri ile değerlendirilmiştir. Model tahminleri ve gerçek değerler Tablo 3'de görülmektedir. Tablo 3'ün ilk satırı dikkate alındığında 34839 olan Elazığ'a ait gerçek yolcu sayısı, AR modeli ile 318246.6,

Vanilla LSTM modeli ile 40761.1 olarak bulunmuştur.

Tablo 3. Gerçek ve tahmin sonuçları

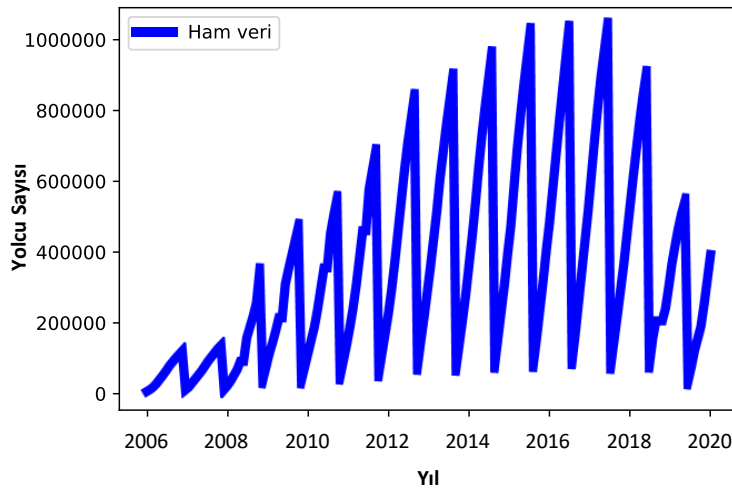
| Gerçek Değer | Tahmin Değeri | |
|--------------|---------------|--------------|
| | AR | Vanilla LSTM |
| 34839 | 318246.6 | 40761.1 |
| 73786 | 298141.4 | 73353.4 |
| 120072 | 282230.3 | 132883.3 |
| 155306 | 267544.9 | 170497.9 |
| 189327 | 268972.6 | 208610.9 |
| 252026 | 290549.8 | 286770.5 |
| 320601 | 327898.6 | 361530.7 |

Önerilen Vanilla LSTM modelinin kayıp fonksiyonunun döngü sayısına göre değişim grafiği Şekil 3'te gösterilmiştir. Şekil 3'teki grafik incelendiğinde hem eğitim hem de test verilerinin kayıp değerinin iterasyonla azaldığı görülmektedir. Kayıp fonksiyonu olarak MSE kullanılmıştır. MSE değerinin küçük çıkması önerilen modelin iyi bir tahminleme yaptığını göstermektedir. Eğitim ve test veri değerleri öğrenme sürecinde sifıra yaklaşmıştır. Şekil 3'deki kayıp grafiğinde görüldüğü gibi modelde ezberleme durumu gerçekleşmemiştir.



Şekil 3. Vanilla LSTM kayıp fonksiyonu grafiği

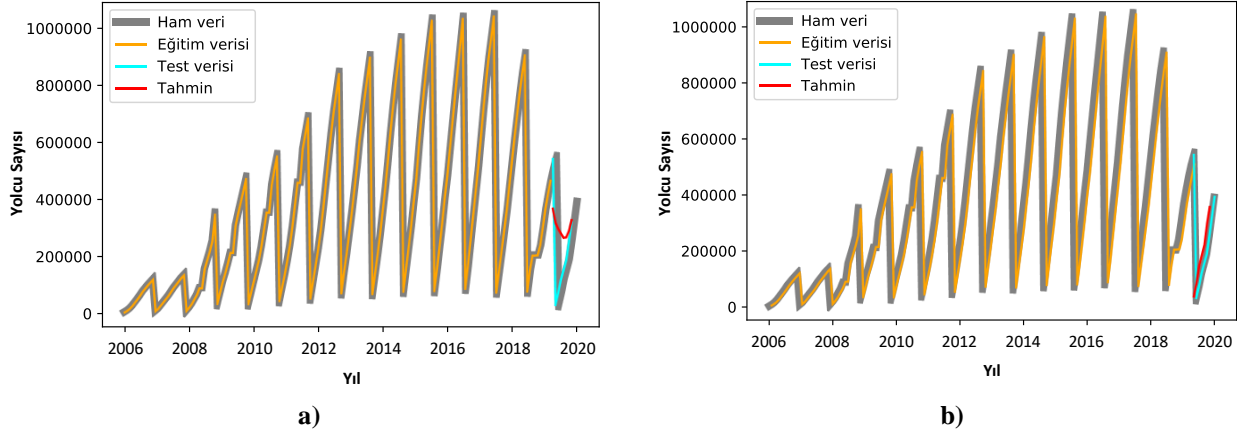
Elazığ iline ait havayolu iç hat ve dış hat toplam yolcu sayısının 2007 – 2021 yılları arasındaki değişimi Şekil 4'de gösterilmiştir.



Şekil 4. 2007-2021 tarihleri arasındaki Elazığ iline ait toplam yolcu sayısı

Ayrıca, hem AR hem de Vanilla LSTM modellerinin test verisinin tahminleri, orijinal veri ile karşılaştırıldığında AR modelinin tahmininin orijinal veriden uzak, Vanilla LSTM modelinin ise orijinal veriye çok yakın olduğu görülmüştür. Vanilla LSTM ile yapılan Elazığ iline ait yolcu

tahminlemesinin AR modeli tahminlemesinden daha iyi olduğu görülmüştür. Şekil 5 a ve b'de yolcu verilerinin ham hali, eğitim ve test veri kümesine ayrılmış hali verilmiştir. Şekil 5 a'da AR modelinin tahminlemesi, Şekil 5 b'de ise Vanilla LSTM modelinin tahminlemesi görülmektedir.



Şekil 5. a) AR ve b) Vanilla LSTM modellerinin tahmini

4. Sonuç

Bu çalışmada havayolu yolcu tahmini için geleneksel olarak kullanılan regresyon analizi, zaman serileri, yapay sinir ağları gibi makine öğrenme ve istatistiksel yöntemler yerine tekrarlayan sinir ağlarının gelişmiş bir yapısı olan Vanilla LSTM kullanılmıştır.

Özellikle tahminlemenin sıklıkla kullanıldığı havacılık alanında, önerilen Vanilla LSTM modelinin büyük bir eksikliği gidereceği öngörülmektedir. Önerilen model ile uçuş ağlarının operasyon verimliliğinin artırılması ve etkili hava trafik kontrol stratejilerinin geliştirilmesi hedeflenmektedir. Böylece havacılık otoritelerine ve havayolu firmalarına filo planlama, ekip çizelgeleme, rota planlama ve biletleme ücretleri konularında önemli katkı sağlayacağı düşünülmektedir.

Etik Kurul Onayı

Gerekli değil.

Kaynaklar

- [1] S. Kim and D. H. Shin, "Forecasting short-term air passenger demand using big data from search engine queries," *Autom. Constr.*, vol. 70, pp. 98–108, 2016.
- [2] A. Kanavos, F. Kounelis, L. Iliadis, and C. Makris, "Deep learning models for forecasting

aviation demand time series," *Neural Comput. Appl.*, vol. 0123456789, 2021.

- [3] W. H. K. Tsui, H. Ozer Balli, A. Gilbey, and H. Gow, "Forecasting of Hong Kong airport's passenger throughput," *Tour. Manag.*, vol. 42, no. 2014, pp. 62–76, 2014.
- [4] B. Flyvbjerg, M. K. Skamris Holm, and S. L. Buhl, "How (In)accurate are demand forecasts in public works projects?: The case of transportation," *J. Am. Plan. Assoc.*, vol. 71, no. 2, pp. 131–146, 2005.
- [5] Y. Xiao, J. J. Liu, Y. Hu, Y. Wang, K. K. Lai, and S. Wang, "A neuro-fuzzy combination model based on singular spectrum analysis for air transport demand forecasting," *J. Air Transp. Manag.*, vol. 39, no. January 2019, pp. 1–11, 2014.
- [6] A. Maheshwari, N. Davendralingam, and D. A. Delaurentis, "A comparative study of machine learning techniques for aviation applications," *2018 Aviat. Technol. Integr. Oper. Conf.*, no. July, 2018.
- [7] X. Yang *et al.*, "A novel prediction model for the inbound passenger flow of urban rail transit," *Inf. Sci. (Ny.)*, vol. 566, pp. 347–363, 2021.
- [8] J. Tang, J. Liang, F. Liu, J. Hao, and Y. Wang, "Multi-community passenger demand prediction at region level based on spatio-temporal graph convolutional network,"

- Transp. Res. Part C Emerg. Technol.*, vol. 124, no. January, p. 102951, 2021.
- [9] X. Zhu and L. Li, "Flight time prediction for fuel loading decisions with a deep learning approach," *Transp. Res. Part C Emerg. Technol.*, vol. 128, no. March, p. 103179, 2021.
- [10] DHMİ, "DHMİ," 2021. [Online]. Available: <https://www.dhmi.gov.tr/Sayfalar/Istatistikler.aspx>.
- [11] X. Song *et al.*, "Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model," *J. Pet. Sci. Eng.*, vol. 186, no. November 2019, p. 106682, 2020.
- [12] J. Guo, Z. Lao, M. Hou, C. Li, and S. Zhang, "Mechanical fault time series prediction by using EFMSAE-LSTM neural network," *Meas. J. Int. Meas. Confed.*, vol. 173, no. October 2020, p. 108566, 2021.
- [13] M. A. KIZRAK and B. BOLAT, "Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım," *Bilişim Teknol. Derg.*, pp. 103–109, 2019.
- [14] A. Shakeel, T. Tanaka, and K. Kitajo, "Time-series prediction of the oscillatory phase of eeg signals using the least mean square algorithm-based ar model," *Appl. Sci.*, vol. 10, no. 10, 2020.
- [15] Y. Tian, K. Zhang, J. Li, X. Lin, and B. Yang, "LSTM-based traffic flow prediction with missing data," *Neurocomputing*, vol. 318, pp. 297–305, 2018.
- [16] B. Yang, S. Sun, J. Li, X. Lin, and Y. Tian, "Traffic flow prediction using LSTM with feature enhancement," *Neurocomputing*, vol. 332, pp. 320–327, 2019.