



Çift üstel düzeltme, ARIMA ve yapay sinir ağları ile kısa mesaj miktarının tahmini

Forecasting the short message quantity with double exponential smoothing, ARIMA and artificial neural networks

Mehtap PARLAK¹, Gonca YILDIRIM^{2*}

¹Fen Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara, Türkiye.

mehtap.parlak@gazi.edu.tr

²Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Gazi Üniversitesi, Ankara, Türkiye.

goncayildirim@gazi.edu.tr

Geliş Tarihi/Received: 30.12.2024

Düzeltilme Tarihi/Revision: 06.04.2025

doi: 10.5505/pajes.2025.91586

Kabul Tarihi/Accepted: 12.05.2025

Araştırma Makalesi/Research Article

Öz

Günümüzde hala farklı sektörlerde ve bireyler arasında yaygın olarak kullanılan ve mobil iletişimde önemli bir yere sahip olan kısa mesaj servisi, çeşitli sektörlerdeki işletmelere operasyonel verimlilik, pazarlama ve müşteri hizmetlerine yönelik geliştirilen stratejiler gibi çok farklı alanlarda faydalar üretmektedir. Bu çalışmada, çift üstel düzeltme, ARIMA ve yapay sinir ağları kullanılarak kısa mesaj servisi için miktar tahmini ve ortalama mutlak yüzde hata ve ortalama kare hatası kullanılarak elde edilen tahminlerin karşılaştırılması yapılmıştır. Çalışmada, yapay sinir ağları en yüksek tahmin doğruluğunu vermiş, bunu çift üstel düzeltme yöntemi ve en son olarak ARIMA yöntemi izlemiştir. Tahmin hatalarının tek yönlü ANOVA karşılaştırmaları, yapay sinir ağları ile çift üstel düzeltme yöntemi arasında istatistiksel olarak anlamlı bir fark olduğuna dair yeterli kanıt sağlamamaktadır. Ancak, ARIMA yöntemi her iki yönetime kıyasla önemli ölçüde daha kötü performans göstermektedir. Deneyler sonucunda elde edilen bir diğer bulgu; katman, nöron ve epok (öğrenme döngüsü) sayılarının artmasının yapay sinir ağlarının tahmin performansını genel olarak iyileştirdiği yönündedir. Ayrıca çalışmada, yapay sinir ağının çıktı katmanında kullanılan sigmoid aktivasyon fonksiyonunu düzeltilmiş doğrusal birim, hiperbolik tanjant ve doğrusal fonksiyonlarıyla değiştirilerek yapılan deneyler sonucunda doğrusal fonksiyonunun daha iyi performans gösterdiği görülmüştür.

Anahtar kelimeler: Zaman serileri tahmini, çift üstel düzeltme, ARIMA, yapay sinir ağları, SMS

Abstract

The short message service, which is still widely used to this day in different sectors and among individuals and has an important place in mobile communication, provides benefits to businesses in various sectors in many different areas, such as operational efficiency, marketing, and customer service strategies. In this study, double exponential smoothing, ARIMA, and artificial neural networks are used to forecast the short message quantity, and mean absolute percentage error and mean squared error measures are used to compare the forecasts. In this study, the artificial neural networks yield the highest forecast accuracy, followed by double exponential smoothing and, lastly, the ARIMA method. One-way ANOVA comparisons of forecast errors do not provide sufficient evidence to declare a statistically significant difference between artificial neural networks and the double exponential smoothing method. However, ARIMA method performs significantly worse than both. Another finding obtained as a result of the experiments is that increasing the number of layers, neurons, and epochs (learning cycles) improves the forecasting performance of artificial neural networks in general. Additionally, the experiments done by replacing the sigmoid activation function used in the output layer of the neural network with rectified linear unit, hyperbolic tangent, and linear functions showed that the linear function performs better.

Keywords: Time series forecasting, double exponential smoothing, ARIMA, artificial neural networks, SMS

1 Giriş

Mobil haberleşmenin önemli yapı taşlarından birini oluşturan kısa mesaj servisi (SMS) günümüzde elektronik bankacılığa giriş yapılabilmesinde, işletmelerin kampanyalarıyla ilgili müşterileriyle iletişime geçmesinde, sağlıkla ilgili randevu hatırlatma ve reçete bilgilendirmesinin yapılmasında, bir etkinlik alımı sonucunda müşterilere onay bilgilerinin gönderilmesinde, vergi ve yasal bildirimler gibi kamusal hizmetlerle ilgili vatandaşların bilgilendirilmesinde, satın alınan ulaşım biletlerinin onaylarının iletilmesinde, e-ticaret kapsamında satın alma sürecinin ödeme doğrulama aşamasında ve daha birçok farklı alanda yaygın olarak kullanılmaktadır. SMS'yle sadece bireyler arasındaki değil, aynı zamanda işletmelerin müşterileriyle olan iletişimi de sağlanmaktadır.

Finans, pazarlama, ticaret, sağlık, eğitim, ve kamusal hizmetler gibi sektörler için kritik öneme sahip SMS miktarının tahmini ile telekomünikasyon sektöründe faaliyet gösteren işletmeler müşteri stratejilerini daha kolay belirleyebilmektedir. SMS miktarının doğru tahmini sayesinde kaynakları etkin kullanmak, müşteri memnuniyetini artırmak ve daha iyi yatırım planları yapmak mümkün olabilir. Ayrıca, tahmin bulguları müşteri ilişkileri yönetimi (CRM) ve dijital pazarlama gibi alanlarda da kullanılabilir. CRM kapsamında, doğru SMS talep tahmini işletmelerin müşteri iletişim stratejilerini optimize etmelerine yardımcı olarak promosyon veya işlem mesajlarının en etkili zamanlarda gönderilmesini sağlayabilir. Dijital pazarlama açısından ise zamanlaması iyi ayarlanmış kampanyalar oluşturulmasına katkıda bulunarak müşteri etkileşimini ve dönüşüm oranlarını artırabilir.

Türkiye'de gönderilen SMS sayısı düşüş eğilimindedir (bk. Şekil 1). Bu düşüş eğiliminin önemli sebeplerinden birisi internet

*Yazışılan yazar/Corresponding author

tabanlı mesajlaşma uygulamalarının artan popülaritesidir [1]. Ayrıca, internet kullanımının yaygınlaşması ile SMS ve MMS'yi birleştirerek farklı marka telefonlar/servis sağlayıcılar arasındaki mesajlaşmayı daha kaliteli ve ek özelliklerle sunabilecek yeni teknolojiler de gündemdedir. Bunlardan, Zengin İletişim Hizmetlerinin (RCS) gelecek yıllarda benimsenme oranlarının daha da artacağı öngörülmektedir [2]. Dolayısıyla, hem servis sağlayıcıların altyapı geliştirme ve modernizasyonu ile yeni teknolojilere yatırımlarını planlamalarında hem de diğer sektörlerin dijital pazarlama stratejilerini belirlemelerinde mesajlaşma eğilim ve trendlerini analiz etmelerinin önemi artarak sürmektedir.

Bu çalışmada, SMS sayısının tahmini için gerçek veriler kullanılarak verinin yapısına uygun klasik tahmin modellerinden çift üstel düzeltme ile ARIMA'nın yanı sıra özellikle son zamanlarda literatürde oldukça sık olarak karşılaşılan makine öğrenmesi modellerinden yapay sinir ağları kullanılmıştır. Bu modeller için en iyi parametre değerleri belirlenerek tahminler gerçekleştirilmiş ve modellerin performansları karşılaştırılmıştır.

Çalışmanın devamı şu şekilde organize edilmiştir: Bölüm 2'de bazı geçmiş tahmin çalışmalarına değinilerek literatüre katkılar anlatılmıştır. Bölüm 3'te, çalışmadaki girdiler, veriler, performans ölçütleri, aktivasyon fonksiyonları ve tahmin için kullanılan yöntemler ile uygulamaları verilmiştir. Bölümler 4 ve 5'te sonuçlar ele alınarak çalışma sonlandırılmıştır.

2 Geçmiş Çalışmalar

Literatürde tahminleme konusu üzerine çok farklı alanlarda yapılmış olan çalışmalar bulunmaktadır. [3]'te ürün talep, [4]'te trafik kazası ve yaralı sayıları, [5]'de şeker üretiminde kalite kontrol kriterlerinden biri olan çözelti rengi, [6]'da 112 Acil Çağrı Merkezine gelebilecek çağrı sayısı, [7]'de COVID-19 pandemi döneminde bir üçüncü parti lojistik firmasının talep tahminleri için çeşitli klasik istatistiksel ve makine öğrenmesi yöntemleri kullanılmıştır. Bu çalışmanın konusu olan SMS miktarı gibi telekomünikasyon sektörü için kritik öneme sahip değişkenlerin tahminine yönelik geçmiş çalışmalar incelenerek Tablo 1'de özetlenmiştir. Çalışmalarda kullanılan kısaltmalar Ek A, Tablo 15'te verilmiştir.

Tablo 1. Telekom sektöründeki bazı tahmin çalışmaları.
Table 1. Some forecasting studies in the telecommunication sector.

Çalışma	Hedef değişken	Yöntemler	Metrikler	Veri	En iyi yöntemler
[8], 2016	Şebeke hücresindeki aktif kullanıcı sayısı	MLP/MLPWD/SVM	MAPE/RMSE	25.01.2015-31.01.2015, 168 adet veri (Deney 1: 24 özellik, Deney 2: 1 özellik)	Deney 1: SVM Deney 2: MLPWD
[9], 2016	Mobil abone sayısı	ARIMA	AIC/MAD/MAPE/RMSE/SBC	2000-2014, yıllık 15 adet veri	ARIMA (1,2,1)
[10], 2017	Mobil internet trafiği	RNN/3D CNN/CNN-RNN/ARIMA (STL)/LM (STL)/RNN (MTL)/3D CNN (MTL)/CNN-RNN (STL)/CNN-RNN (MTL)	MAE/MAPE/RMSE	Kasım-Aralık 2013, 6 farklı zaman dilimi için onar dakikalık veriler*	CNN-RNN
[11], 2021	GSM kullanıcı sayısı	MLP	MSE/RE	Aralık 2008-Ağustos 2020 yıllık 140 adet veri	-
[12], 2022	Deney 1: İnternet trafik hacmi Deney 2: Ortalama giden ve gelen trafik ayrımında internet trafik hacmi	YSA/LSTM/ARIMA/SMA	MAE/MAPE/MSE/RMSE/R ²	Deney 1: 07.07.2005-28.07.2005, Deney 2: 15.06.2021-15.07.2021, beşer dakikalık veriler*	Deney 1: YSA Deney 2: LSTM
[13], 2024	Mobil şebeke trafiği	HA/SVR/FNN/STGCN/ASTGCN/Graph-WaveNet/HGCN/HSeq2Seq	MAE/RMSE	23.12.2019-5.1.2020 beşer dakikalık veriler*	HSeq2Seq
[14], 2024	5G hücresel şebekelerin verimliliği	LSTM/BiLSTM/YSA/RF	MSE/R ²	35 farklı veri kümesi*	BiLSTM, LSTM
[15], 2024	Uydu iletişimindeki trafik talebi	Seq2Seq-LSTM	MAE/MSE	14 günlük 5555 adet veri	-
[16], 2024	SMS, arama ve internet trafiği	Son değer/HA/STCnet/GASTN/STAGCN/DMFS-MF/Conv3D/ConvLSTM/ConvGRU/ConvLS TM-GNN/Stdense net	MAE/RMSE/R ²	01.11.2014-01.01.2023, onar dakikalık veriler*	ConvLSTM-GNN
Bu çalışma	SMS miktarı	DES/ARIMA/YSA	MAPE/MSE/Kruskal-Wallis	2009,3. üç aylık dönem-2023, 4. üç aylık dönem, 58 adet veri	YSA ve DES

* Net veri adeti belirtilmemiştir.

Tablo 1'de özetlenen telekomünikasyon sektörüne ait çalışmalardan [8]'de kullanılan özellikler mobil şebeke sistemlerindeki teknik bilgilerden oluşmaktadır. Öznitelik seçimi, korelasyon ve sıralama kullanılarak yapılmıştır. Çalışmada, değişik eğitim-test oranları incelenmemiştir. [9]'da ARIMA için parametre optimizasyonu yapılmış ancak farklı modeller incelenmemiştir. [10]'da YSA türevlerinden olan LSTM ve RNN gibi derin öğrenme modellerinde, hücre ve gizli katman sayıları için parametre değerleri belirlenmiştir. Ancak eğitim-test oranı tek bir değerde sabit bırakılmıştır. [11]'de, basit yapılı bir YSA üzerinde bir özellik ve bir eğitim-test oranı kullanılarak tahmin gerçekleştirilmiş, farklı yöntemlerle


karşılaştırma ve hata analizi yapılmamıştır. [12]'de YSA ve LSTM modellerinin benzer performans gösterdiği, ancak YSA'nın çalışma süresinin LSTM'ye göre çok daha düşük olduğu vurgulanmıştır. Çalışmamızla en ilgili olan [16]'da SMS, arama ve internet hizmetlerine ilişkin trafik tahminleri tarihsel ortalama, çeşitli makine ve derin öğrenme yöntemleri kullanılarak yapılmıştır. Çalışmada, ConvLSTM-GNN hibrit modeli en iyi performansı göstermiştir. Ancak, modellerde kullanılan parametrelerin optimizasyonu yapılmamış, bunlar baştan sabitlenerek tahminler üretilmiştir.

Yazarların bilgisi dahilinde bu çalışmaya benzer başka bir çalışmaya literatürde rastlanılmamış olup katkılarımız aşağıda özetlenmiştir:

- Veri yapısına uygun tahmin modelleri belirlenerek model performansları MAPE ve MSE metrikleriyle karşılaştırılmıştır. Ayrıca, modellerin tahminleri arasında istatistiksel olarak anlamlı bir fark olup olmadığı test edilerek çalışmanın bulguları daha objektif hale getirilmiştir.
- YSA modeliyle tahmin performansını iyileştirebilmek için alana özgü 15 girdi belirlenerek gerçek veriler toplanmıştır. Raporlanmış verinin bütününde zamansal harmoniyi oluşturabilmek için yıllık miktar olarak yayımlananları doğrusal interpolasyon yaklaşımıyla, orantısız olanları seçilen periyotta aynı olacak şekilde düzenlenmiştir.
- YSA modelinin kurulması aşamasında RFE özellik seçimi yapılarak sıralamalar belirlenmiş, her özellik sayısı için denemeler yapılmış ve girdilerden hedef değişkenle en ilgili olanları bu sayede belirlenmiştir. Özellik seçiminde ikili bir süreç yürütülerek özelliklerin hem ham değerleri hem de birinci dereceden farkları kullanılmıştır.
- Modeller için parametre optimizasyonu yapılmış, özellikle YSA modelinde parametre değerlerinin tahminlere etkileri duyarlılık analiziyle incelenmiştir.

3 Veri kümesi ve yöntem

Bu bölümde, çalışmada kullanılan girdiler, veriler ve tahmin yöntemleri açıklanmaktadır. Şekil 1'de görüldüğü üzere SMS miktarının zaman serisi azalan bir trende sahiptir. Çalışmada, bu durum dikkate alınarak trende sahip zaman serilerinin tahmini için uygun olan çift üstel düzeltme yöntemi, ARIMA metodu ve YSA kullanılmıştır.



Şekil 1. Çeyrek dönemlerde gönderilen SMS miktarının zaman serisi ve trendi (2009, 3. çeyrek-2023, 4. çeyrek).

Figure 1. Time series plot and trendline of the quarterly SMS quantity sent (2009, 3rd quarter-2023, 4th quarter).

SMS miktarını etkileyebilecek 15 özellik belirlenerek Tablo 2'de listelenmiştir.

Tablo 2. SMS miktarını etkileyebilecek özellikler.

Table 2. Features that may affect the SMS quantity.

No.	Özellik
1.	Mobil abone sayısı
2.	2G ve 3G abone sayısı
3.	Haberleşme tüketici fiyat endeksi (H-TÜFE)
4.	Okuma yazma bilmeyen kişi sayısı
5.	Okuma yazma bilen fakat bir okul bitirmeyen kişi sayısı
6.	Ortaokul veya dengi mezunu kişi sayısı
7.	İlköğretim mezunu kişi sayısı
8.	Lise veya dengi meslek okulu mezunu kişi sayısı
9.	Yüksekokul veya fakülte mezunu
10.	Yüksek lisans mezunu kişi sayısı
11.	Doktora mezunu kişi sayısı
12.	Eğitim durumu bilinmeyen kişi sayısı
13.	SMS ve çokluortam mesaj hizmeti (MMS) gelir oranı

14. Mobil genişbant abone sayısı
15. Zamansal sıra

İlgili özelliklerden;

- mobil abone sayısı, sadece mobil aboneliğe sahip bireylerin SMS hizmetinden yararlanabileceği;
- 2G ve 3G abone sayısı, 2G ve 3G teknolojisini kullanan bireylerin internet kullanımının 4.5G'yi kullanan bireylere göre daha az gerçekleşebileceği;
- H-TÜFE, haberleşme sektöründe gerçekleşen fiyatları, abonelikleri ve dolayısıyla işletmelerin sunduğu paket veya tarifelerin tercih edilmesini etkileyebileceği;
- ulusal eğitim istatistikleri, SMS kullanımının eğitim durumundan ve nüfustan etkilenebileceği;
- SMS ve MMS gelir oranı, işletmelerin gelir oranı gibi stratejilerini önceden belirleyebilecekleri ve kendileri için daha önemli olan gelir türüne yönelik yatırımlarını planlayabilecekleri;
- mobil genişbant abone sayısı, mobil internete sahip bireylerin sayısını göstermekte olup bu bireylerin mesajlaşma için SMS'yi daha az tercih edebilecekleri düşünceleriyle;
- zamansal sıra, SMS'nin zaman serisi olması sebebiyle

seçilmiştir.

3.1 Verilerin elde edilişi

Çalışmada tahminler her üç aylık periyot için yapılmıştır. İlgili veriler, Bilgi Teknolojileri ve İletişim Kurumunun üçer aylık periyotlarla yayımladığı Türkiye Elektronik Haberleşme Sektörü Üç Aylık Pazar Verileri Raporu ile Türkiye İstatistik Kurumu tarafından 2009 ile 2023 yılları arasında yayımladığı çalışmalardan elde edilen 58 periyotluk girdi ve çıktılardan oluşmaktadır ([17]-[19]). Ulusal eğitim istatistikleri yıllık olarak yayımlanmakta olup, çeyrek yıllık veriler bulunmamaktadır. Bu çalışmada, ulusal eğitim istatistiklerinin, yıl içindeki çeyrek yıllık periyotlarda büyük dalgalanmalar veya mevsimsel davranış göstermesi beklenmeyeceği varsayımı yapılmıştır. Dolayısıyla, yıllık verilerin üçer aylık dönemlere dönüştürülmesi işlemi doğrusal interpolasyonla yapılmıştır ([20],[21]). SMS ve MMS gelir oranı sadece o yıla ait olan ilgili gelirlerin tüm gelirlere oranını temsil ettiği için yıl boyunca sabit alınmıştır.

3.2 Özellik seçimi

YSA modelinde kullanılmak üzere girdi olarak belirlenen özelliklerin yüksek korelasyona sahip oldukları belirlenmiştir. Tahmin performansının olumsuz etkilenmesini önlemek ve en iyi performansı veren özellikleri belirlemek için RFE yöntemiyle özellik seçimi yapılmıştır. RFE, özellikleri önem değerine göre sıralamak yerine en önemsizleri eler ve bunu istenen sayıda özellik kalana kadar yineler. RFE yöntemi herhangi bir makine öğrenme algoritmasını işleyebilme özelliğine sahiptir [22]. Bu duruma istinaden, çalışmadaki özellik seçimi için RFE rastgele orman tekniğiyle kurulmuş ve Python programlama dilinde kodlanarak uygulanmıştır. Rutin 1, ilgili sürecin sözde kodunu vermektedir.

Rutin 1. RFE yöntemiyle özellik seçiminin sözde kodu.

Routine 1. Pseudocode for feature selection with RFE.

Hem ham hem de 1. dereceden fark alınmış veriler için:


Veri kümesini girdi ve çıktı değişkenleri için ayır.

n girdi sayısı için $(n-1)$ 'den 1'e kadar:

Rastgele orman tekniğini kullanan RFE yöntemini uygula.

Seçilen özellikleri raporla.

Özellik seçiminde iki veri kümesi kullanılmıştır. Bunlardan ilki tüm girdi parametrelerinin gerçek değerleri, diğeri ise SMS miktarının azalan bir trende sahip olmasına bağlı olarak tüm girdi değerlerinin birinci dereceden farklarının alınmasıyla oluşan değerlerdir. Özellik seçim süreci, önem düzeyi yüksek ilk 14 özelliğin belirlenmesiyle başlayıp tek bir özelliğin belirlenmesine kadar sürdürülmüştür. RFE yönteminin girdilere uygulamasını gösteren Şekil 2’de, dikey eksen özelliklerin sıralaması (ve sayısı), yatay eksen özelliklerin numaralarıdır. İstenen özellik sayısına denk gelen çubuk yüksekliğinin altındaki özellikler seçilirken üstündeki özellikler elenir. Örneğin, tek bir özellik seçmek istenirse bu özellik, ham veriler kullanıldığında 10., birinci dereceden fark alınmış veriler kullanıldığında 3. özellik olur. Tablo 3, özelliklerin önem düzeylerini sıralı olarak göstermektedir.



Şekil 2. RFE yönteminin uygulanması.
Figure 2. Application of the RFE method.

Tablo 3. Özelliklerin RFE yöntemine göre önem sıralaması.

Table 3. Ranking of the features based on RFE.

Sıralama (önem düzeyi)	Ham veri	Fark alınmış veri
1	10	3
2	8	15
3	11	5
4	5	14
5	9	10
6	6	2
7	15	4
8	3	13
9	12	1
10	1	7
11	14	6
12	4	9
13	13	11
14	7	8
15	2	12

3.3 Özellik Normalizasyonu

Normalizasyon, kullanılacak özelliklerin ölçekleri arasında belirgin farklılıklar olduğunda verileri [0,1] veya [-1,1] aralıklarındaki değerlere dönüştürerek verilerin birbirleriyle karşılaştırılabilmesini sağlar ([23],[24]). Çalışmadaki veriler, literatürde sıklıkla kullanılan min-max normalizasyonu [0,1] aralığına sınırlandırılmıştır [25]. İlgili notasyon Tablo 4’te, formülasyon Denklem (1)’de verilmiştir [26].

Tablo 4. Min-max normalizasyonunda kullanılan notasyon.

Table 4. The notation used in the min-max normalization.

Sembol	Açıklama
X	Veri kümesi
$\min X$ ve $\max X$	Veri kümesindeki en küçük ve en büyük değerler
x_i	Veri kümesindeki i . verinin gerçek değeri

x_i'

Veri kümesindeki i . verinin normalize edilmiş değeri

$$x_i' = \frac{x_i - \min X}{\max X - \min X} \quad (1)$$

3.4 Performans metrikleri

Literatürde, tahmin modellerinin performanslarının ölçülmesi ve karşılaştırılması için farklı hata metrikleri bulunmaktadır [27]. Bu çalışmada MAPE ve MSE tercih edilmiş ve ilgili metriklerin notasyonu Tablo 5’te verilmiştir.

Tablo 5. Tahmin performans ölçümünde kullanılan notasyon.

Table 5. Notation used in the forecast error measures.

Sembol	Açıklama
D_i	i periyodundaki gerçek değer
F_i	i periyodundaki tahmin değeri
n	Periyot (gözlem) sayısı

3.4.1 Ortalama mutlak yüzde hata

MAPE, gerçek ve tahmin değerleri arasındaki farkın gerçek değere oranına dayalı olduğundan diğer metriklere göre daha objektif bir gösterge olarak kabul edilir. Veri ölçeğine duyarlı olmayan MAPE değeri sıfıra ne kadar yakınsa tahmin o kadar başarılıdır [28]. MAPE, Denklem (2) kullanılarak hesaplanır.

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

MAPE, gerçek değer üstündeki tahminlere, altındakilerden daha yüksek bir ceza uyguladığından, yüksek hataların beklendiği modellerde kullanımı eleştiri konusudur [29]. Bu sebeple, çalışmada ikinci bir metrik olarak MSE kullanılmıştır.

3.4.2 Ortalama kare hata

YSA’da girdilerin normalizasyona tabi tutulduğu modelden elde edilen çıktılar da normalize değerler verir. Hata hesaplaması yapabilmek için tahmin değerlerini tekrar gerçek değerlere dönüştürmek gerekir [30]. Bu çalışmada, veri değerlerinin gerçek ölçekte ele almak ve MAPE metriğindeki olası dezavantajlardan korunmak için yaygın olarak kullanılan ve Denklem (3)’te formülü verilen MSE metriği tercih edilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (D_i - F_i)^2 \quad (3)$$

3.5 Aktivasyon fonksiyonları

Aktivasyon fonksiyonu, yapay sinir hücresinin giriş verilerini işleyerek bir çıktı değerinin üretilmesini sağlar. Fonksiyonun doğru şekilde seçilmesi modelin performansını doğrudan etkiler [31]. Bu seçim genelde veriye değil, deneylere bağlı olarak yapılır [32]. Sigmoid, ReLU, hiperbolik tanjant (tanh) ve doğrusal en sık kullanılan aktivasyon fonksiyonlarındandır.

3.5.1 Sigmoid

Sigmoid fonksiyonu, negatif değerleri sıfıra, büyük pozitif değerleri ise 1’e yaklaştırarak çıktıları [0,1] aralığındaki değerlere atar. Sigmoid, genelde sınıflandırma problemlerinin çıktısını modellemede kullanılmaktadır. Formülü Denklem (4)’te verilen sigmoid fonksiyonunun üstel işlem içermesinden dolayı hesaplama karmaşıklığı yüksektir ([33],[34]) ve çalışmamızda sadece çıktı katmanında kullanılmıştır.

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

3.5.2 ReLU

ReLU fonksiyonu, negatif girdi değerlerini sıfıra, pozitif girdi değerlerini kendisine döndürür [35]. Parçalı doğrusal bir fonksiyon olarak betimlenebilen ReLU’nun formülasyonu

Denklem (5)'te verilmiştir. ReLU, pratikte iyi sonuç verdiği için sıklıkla tercih edilir ([32],[36]) ve çalışmamızda YSA'nın girdi ile gizli katmanlarında kullanılmıştır.

$$\text{ReLU}(x) = \max \{0, x\} \quad (5)$$

3.5.3 Hiperbolik tanjant

Formülasyonu Denklem (6)'da verilen tanh aktivasyon fonksiyonu sigmoide benzer bir yapıya sahiptir, ancak çıktı değerleri $[-1,1]$ aralığındadır. Türevi sigmoide göre daha dik olduğundan daha geniş bir değer aralığı elde edilir [36].

$$\tanh(x) = \frac{2}{(1+e^{-2x})} - 1 \quad (6)$$

3.5.4 Doğrusal

Doğrusal aktivasyon fonksiyonu, yorumlanabilirlik gerektiren, girdi-çıkı ilişkisinin basit ve doğrusal olduğu durumlarda kullanılır. Denklem (7)'de verilen doğrusal aktivasyon fonksiyonundaki a çarpanının değerini kullanıcı belirler [37].

$$F(x) = ax \quad (7)$$

3.6 Yöntem

Bu çalışmada, ele alınan SMS miktarının azalan trend göstermesinden dolayı bu tür zaman serilerinin tahmini için uygun olan çift üstel düzeltme yöntemi, ARIMA metodu ve YSA kullanılmıştır. Tahmin modelleri Python programlama dilinde kodlanarak JupyterLab üzerinde çalıştırılmış, uygun parametre değerleri ile model yapıları belirlenmiştir. Modellerin karşılaştırılmaları MAPE ve MSE metrikleri, performansları arasında istatistiksel olarak anlamlı bir fark olup olmadığı da Kruskal-Wallis testi [38] kullanılarak yapılmıştır.

3.6.1 Çift üstel düzeltme yöntemi

Literatürde yaygın olarak kullanılan üstel düzeltme yönteminde, yakın tarihli gözlemlere eski gözlemlere göre daha fazla ağırlık verilir ([39],[40]). Bu yöntemin sıklıkla kullanılan üç türü basit üstel düzeltme, çift üstel düzeltme ve Holt-Winters'dır [41]. Çalışmamızdaki veri trende sahip olduğundan çift üstel düzeltme yöntemi kullanılmıştır. İlgili notasyon Tablo 6'da, formülasyonlar Denklemler (8)-(10)'da verilmiştir [42].

Tablo 6. Çift üstel düzeltme yönteminde kullanılan notasyon.
Table 6. Notation used in the double exponential smoothing method.

Sembol	Açıklama
S_t	t periyodundaki düzeltilmiş seviye değeri
D_t	t periyodundaki gerçek gözlemlenen değer
G_t	t periyodundaki trend değeri
α ve β	Üstel ve trend düzeltme parametreleri, $\alpha, \beta \in [0,1]$
$F_{t,t+\tau}$	t periyodunda τ adım sonraki tahmin değeri

$$S_t = \alpha D_t + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (8)$$

$$G_t = \beta(S_t - S_{t-1}) + (1 - \beta)(G_{t-1}) \quad (9)$$

$$F_{t,t+\tau} = S_t + \tau G_t \quad (10)$$

Çift üstel düzeltme yöntemiyle yapılan çalışmanın süreci Rutin 2'de verilmiştir.

Rutin 2. SMS sayısının çift üstel düzeltme yöntemiyle tahmini için sözde kod.

Routine 2. Pseudocode for forecasting the SMS quantity using the double exponential smoothing method.

Veri kümesini yükle.
 G_0 değerini ilk 4 döneme göre hesapla.
 S_0 değerini 4. gözlem değeri olarak al.
 $\beta = 0.1$ 'den 1'e kadar 0.1'lik artışla:

$\alpha = 0.1$ 'den 1'e kadar 0.1'lik artışla:
Her $t \in \{5, 6, \dots, n\}$ için:
 S_t değerini Denklem (8)'le hesapla.
 G_t değerini Denklem (9)'la hesapla.
 $F_{t,t+\tau}$ değerini Denklem (10)'la hesapla.
MSE ve MAPE değerlerini hesapla.

Üstel ve trend düzeltme parametrelerinin (sırasıyla α ve β) değerleri 0.1'den başlayarak 0.1'lik artışla denenmiştir. Tablo 7'de özetlendiği gibi, en iyi α ve β değerleri sırasıyla; MAPE metriğine göre 0.8 ve 0.2, MSE metriğine göre 0.9 ve 0.2'dir.

Tablo 7. Çift üstel düzeltme için test edilen parametre kümesindeki en iyi sonucu veren parametre değerleri.

Table 7. Best parameter values in the set of those tested for the double exponential smoothing model.

α	β	MAPE	MSE
0.8	0.2	0.073790	4,395,378
0.9	0.2	0.074764	4,281,504

3.6.2 ARIMA metodu

Box-Jenkins yöntemi olarak da adlandırılan ARIMA, zaman serilerinde kullanılan bir diğer tahmin metodudur. Durağan olmayan ve fark alma gibi dönüşümlerle durağanlaştırılan zaman serilerinde kullanılır ([6],[9]). Model parametrelerinin belirlenmesinde, otokorelasyon ve kısmi otokorelasyon fonksiyonlarından yararlanılır. ARIMA ile ilgili notasyon Tablo 8'de, formülasyon Denklem (11)'de verilmiştir [43].

Tablo 8. ARIMA yönteminde kullanılan notasyon.

Table 8. Notation used in the ARIMA method.

Sembol	Açıklama
Y_t	Bir ya da birden fazla kere farkı alınmış zaman serisi
Z	Sabit
θ_p	AR model parametresi
θ_j	MA model parametresi
ε_t	Hata miktarı

$$Y_t = Z + \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \dots + \theta_p Y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_j \varepsilon_{t-j} \quad (11)$$


ARIMA çalışmasına ait sözde kod Rutin 3'te verilmiştir.

Rutin 3. SMS sayısının ARIMA ile tahmini için sözde kod.

Routine 3. Pseudocode for forecasting the SMS quantity using ARIMA.

Veri kümesini yükle.
Otokorelasyon ve kısmi otokorelasyon grafiklerinin çiz.
Durağanlık testi için Dickey Fuller testini uygula.
 $p < 0.05$ oluncaya kadar x değeri 1'den başlamak üzere x kere:
 x . dereceden fark alma işlemini yap.
Dickey Fuller testini yap.
Otokorelasyon ve kısmi otokorelasyon grafiklerini çiz.
Veriyi 0.75:0.25, 0.5:0.5, 0.25:0.75 oranlarında eğitim-test için ayır.
Oluşturulan üç veri kümesi için modeli çalıştır.
MSE ve MAPE değerlerini hesapla.


ARIMA modeliyle tahmin çalışmasında öncelikle otokorelasyon ve kısmi otokorelasyon grafikleri çizilmiştir. Şekil 3, ham veri için ilgili grafikleri göstermektedir.



Şekil 3. Ham veride otokorelasyon ve kısmi otokorelasyon.
Figure 3. Autocorrelation and partial autocorrelation in the raw data.

Grafik çizimlerinin ardından, durağanlık testi birim kök testlerinden birisi olan Dickey Fuller ile yapılmış ve

gözlemlenen hata değeri olan p değeri 0.91 çıkmıştır. Birinci dereceden fark alma işlemi gerçekleştirildikten sonra ise p değeri 0.006'ya inmiştir. Bu değer, çalışmada kabul edilebilir hata yüzdesi olarak kullanılan 0.05'in altında olduğundan fark alımıyla serinin durağan hale geldiği gözlemlenmiştir. Farkı alınan veriler için Şekil 4 incelendiğinde, otokorelasyon grafiğinde anlamlı bir korelasyonun olmadığı, kısmi otokorelasyon grafiğinde bir adet anlamlı korelasyonun olduğu görülmüştür. Bu sebeple model parametreleri (1,1,0) alınmıştır.



Şekil 4. Fark verisinde otokorelasyon ve kısmi otokorelasyon.
Figure 4. Autocorrelation and partial autocorrelation in the differenced data.

Tablo 9'da görülebileceği gibi 0.75:0.25 eğitim-test oranı en düşük MAPE ve MSE değerlerini vermiştir.


Tablo 9. ARIMA tahminlerinin farklı eğitim-test oranlarındaki performansı.

Table 9. ARIMA forecast performance under different training-to-test ratios.

Eğitim-test oranı	MAPE	MSE
0.75:0.25	0.576412	19,753,650
0.50:0.50	1.422308	195,232,491
0.25:0.75	2.399017	848,639,698

3.6.3 Yapay sinir ağları

YSA'nın temellerinin 1943'te McCullogh ve Pitts tarafından hücre modeli oluşturulmasıyla atıldığı kabul edilmektedir [44]. Beyin yapısından esinlenerek ortaya çıkan YSA, kendisine gelen bilgileri toplar, aktivasyon fonksiyonundan geçirerek ürettiği çıktıları diğer hücrelere iletir [45]. YSA, geçmiş tecrübelerden öğrenebilme özelliği sayesinde yeni bilgileri tahmin edebilme yeteneğine sahiptir [46]. Çeşitli katmanlar ile nöronlar ve aralarındaki bağlantılardan oluşan bir ağa (ör. bk. Şekil 5), önce bir girdi kümesi tanıtılır ve ardından ağı eğitilmesi sağlanır.



Şekil 5. Örnek bir YSA.
Figure 5. An example artificial neural network.

Eğitme işleminin ardından, tüm nöronların girdileri bir aktivasyon fonksiyonundan geçerek çıktıya dönüşür [47]. Aktivasyon fonksiyonuyla ilgili notasyon Tablo 10'da, formülasyonlar tek ve birden fazla girdili durumlar için sırasıyla Denklemler (12) ve (13)'te verilmiştir [48].

Tablo 10. Aktivasyon fonksiyonu için kullanılan notasyon.
Table 10. The notation used for the activation function.

Sembol	Açıklama
y_i	i . düğümün çıktısı,
x_j ve x_k	Düğümün j . ve k . girdileri, $j = 1, 2, \dots, n$
w_{ij}	i ve j düğümleri arasındaki ilişkinin ağırlığı (tek girdili durum)
w_{ijk}	i , j ve k düğümleri arasındaki ilişkinin ağırlığı (çok girdili durum)
θ	i . düğümün eşiği veya sapması

f_i i . düğüm için aktivasyon fonksiyonu

$$y_i = f_i\left(\sum_{j=1}^n w_{ij}x_j - \theta_i\right) \quad (12)$$

$$y_i = f_i\left(\sum_{j=1}^n \sum_{k=1}^n w_{ijk}x_jx_k - \theta_i\right) \quad (13)$$

YSA ile tahmin sürecini etkin bir şekilde yürütebilmek için çalışma üç aşamada gerçekleştirilmiştir:

- İlk aşama, RFE yöntemiyle sıralanan özelliklerden en iyi performans gösterenlerini ve en iyi eğitim-test oranını,
- İkinci aşama, katman, nöron ve epok sayılarının tahmin performansına etkisinin gözlemlenerek en uygun ağ yapısını,
- Üçüncü aşama, çeşitli aktivasyon fonksiyonlarının zaman serisine etkisini

belirlemek amaçlarını gütmektedir. Rutin 4, YSA'yla tahmin çalışmasının sözde kodunu vermektedir.

Rutin 4. SMS sayısının YSA'yla tahmin çalışmasının sözde kodu.

Routine 4. Pseudocode for forecasting the SMS quantity using artificial neural networks.

Birinci aşama:
Ham ve birinci dereceden fark alınmış veriler için, RFE yöntemiyle özellik önem sıralaması yap.
YSA'yla denemeler yaparak en iyi özellik sayısı ve eğitim-test oranını belirle.
İkinci aşama:
Birinci aşamada belirlenen en iyi özellik sayısı ile eğitim-test oranı için:
Gizli katman sayısı $m \in [1, 5]$ için:
Epok sayısını 200 ve 300 olarak:
YSA'yla denemeler yap.
En iyi sonucu veren katman ve epok sayılarını belirle.
Üçüncü aşama:
ReLU, tanh ve doğrusal fonksiyonları kullanarak ikinci aşamada belirlenen katman ve epok sayıları için:
YSA'yla denemeler yap.
YSA denemelerindeki en iyi sonucu belirle.

Birinci aşamada, Bölüm 3.2'de bahsedilen üç değişik eğitim-test oranı için, RFE yöntemiyle sıralanmış özelliklerden hem ham hem de birinci dereceden fark alınmış veriler kullanılarak (bk. Tablo 2) özellik seçimi yapılmıştır. Özellik seçiminde, olası tüm girdi sayıları için RFE'yle elenen özellik kolonları veri kümelerinden silinmiştir. Ardından, 1 girdi, 1 gizli ve 1 çıktı katmanlı bir YSA modeli oluşturularak 5-40 arasındaki nöron sayıları ve 200 epok kullanılarak tahminler yapılmıştır. YSA'nın ağırlıklarını güncellemede, literatürde sıklıkla karşılaşılan ve genellikle iyi sonuçlar üreten Adam algoritması kullanılmıştır [49]. Süre kısıtı da gözönüne alınarak, her nöron sayısı için 10 deneme yapılmış ve bunların ortalama MSE ve MAPE değerleriyle hata metrikleri elde edilmiştir. İlk aşamanın sonuçları Tablo 11'de listelenmiş olup en iyi sonuçlar kalın olarak belirtilmiştir.

Tablo 11. Özellik ve eğitim-test oranı seçimiyle ilgili en iyi ilk aşama sonuçları.


Table 11. Best first-phase results for the feature and training-to-test ratio selection.

Veri tipi	Eğitim-test oranı	Özellik sayısı	Nöron sayısı	MAPE	MSE
Ham	0.25:0.75	15	24	0.148543	10,621,600
	0.25:0.75	15	36	0.135298	11,254,240
	0.50:0.50	15	38	0.098026	7,588,416
	0.75:0.25	15	37	0.092622	7,197,161
Fark alınmış	0.25:0.75	11	37	0.137982	8,861,345
	0.25:0.75	12	34	0.127532	9,234,935
	0.50:0.50	14	31	0.103357	7,398,551
	0.50:0.50	14	39	0.099509	8,339,657

0.75:0.25 12 33 0.092115 8,011,594
0.75:0.25 14 38 0.099607 7,776,198

Ham veri için 0.75:0.25 eğitim-test oranındaki veri kümesinde 15; fark alınmış veri için 0.75:0.25 eğitim-test oranındaki veri kümesinde MAPE metriğine göre 12 (bk. Tablo 3'teki 8., 11. ve 12. özellikler elenmiştir), 0.50:0.50 eğitim-test oranındaki veri kümesinde MSE metriğine göre 14 (bk. Tablo 3'teki 12. özellik elenmiştir) özellik girdili modeller en iyi sonucu vermiştir. Bu veri tipleri, eğitim-test oranları ve özellik sayılarıyla ikinci aşamaya geçilmiştir.

Hedef değişkenle ilgili özelliklerin seçimi, eğitim-test oranının ve ilgili verilerin belirlenmesi, YSA'nın tahmin performansını etkiler ([50],[51]). Bu çalışmada, eğitim verisi oranının %50 ve üstü olduğunda, özellik sayısı arttıkça hata metriklerinin değerlerinin genel olarak düştüğü gözlemlenmiştir. Örneğin, eğitim-test oranı ile nöron sayıları Tablo 11'deki en düşük hata metrik değerlerine karşılık gelen değerlerde sabit tutulup, özellik sayısı artırıldığında MAPE ve MSE değerlerinin azalma eğiliminde olduğu Şekil 6'da görülebilir.



Şekil 6. RFE yöntemiyle seçilen özellik sayısına göre hata metriklerinin değişimleri.

Figure 6. Changes in error metrics versus number of features selected with the RFE method.

İkinci aşamada, ağ yapısı (katman, nöron ve epok sayıları) kafes arama (grid search) kullanılarak belirlenmiştir. Literatürde, kullanılacak gizli katman, nöron ve epok sayılarına ilişkin çeşitli deneysel çalışmalar bulunmaktadır. ([52]-[54]). Denemelerin uzun sürmesi sebebiyle gizli katman sayısı 1 ile 5, nöron sayısı 5 ile 40 arasında; epok sayısı ise 200 ve 300 olarak sınırlandırılmıştır [55]. Her YSA yapısı 10 kez çalıştırıldığından, birinci aşamadaki en iyi sonucu veren özellikler ve ilgili veri kümelerinin her biri için 3600 deneme yapılmıştır.


Her iki performans metriğine göre de en iyi sonuçlar fark alınmış verilerle RFE yönteminin sonucunda elde edilen 14 özellik girdili modellerle elde edilmiştir. Sonuçlar Tablo 12'de verilmiş olup en iyi sonuçlar kalın olarak gösterilmiştir. MAPE metriğine göre 3 gizli katmanlı, 38 nöronlu ve 300 epoklu; MSE metriğine göre 5 gizli katmanlı, 40 nöronlu ve 300 epoklu ağlar en iyi performansları göstermiştir.

Tablo 12. Ağ yapısıyla ilgili en iyi ikinci aşama sonuçları.

Table 12. Best second-phase results for the network structure.

Veri tipi, eğitim-test oranı, özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAPE	MSE
Ham, 0.75:0.25, 15	1	20	300	0.098135	8,255,654
	1	30	300	0.099747	7,139,096
	2	34	200	0.092215	6,876,626
	2	40	200	0.092735	6,680,840
	2	26	300	0.091175	6,072,133
	3	24	200	0.091578	6,231,353
	3	37	300	0.096836	6,466,148
	4	31	200	0.094882	6,513,967
	4	20	300	0.098618	6,773,953
	4	32	300	0.100089	6,306,123
	5	35	200	0.093087	6,110,056
	5	10	300	0.101317	6,886,820
	5	20	300	0.102933	6,780,095
	1	33	300	0.092442	7,158,851
	1	40	300	0.096423	7,006,669
Fark alınmış, 0.75:0.25, 12	2	39	200	0.090776	6,428,311
	2	34	300	0.093745	6,437,627
	2	27	300	0.094462	6,425,916
	3	19	200	0.092321	6,817,775
	3	35	200	0.093674	6,025,971
	3	13	300	0.095408	6,723,493
	3	22	300	0.096771	6,491,928
	4	14	200	0.095380	7,036,219
	4	27	200	0.096205	6,294,917
	4	13	300	0.096092	6,611,422
	4	21	300	0.096793	6,207,855
	5	18	200	0.092925	6,722,284
	5	35	200	0.098586	6,265,286
	5	33	300	0.096703	6,483,223
Fark alınmış, 0.50:0.50, 14	1	38	300	0.079273	5,995,044
	2	40	200	0.075973	5,749,600
	2	36	200	0.081801	5,668,842
	2	38	300	0.074658	5,104,798
	3	34	200	0.076830	5,372,284
	3	38	300	0.073757	5,143,250
	4	33	200	0.075086	5,630,001
	4	40	200	0.077054	5,131,178
	4	36	300	0.074951	4,786,122
	5	29	200	0.075691	5,510,914
	5	38	200	0.075866	5,092,965
	5	24	300	0.075326	5,137,498
	5	40	300	0.077363	4,638,883

Deneyler sonucunda, tüm modeller için geçerli olmasa da katman, nöron ve epok sayılarındaki artışın performansı genel olarak artırdığı görülmüştür (ör. bk. Şekil 7). Ek B, Tablo 16'da örnek olarak 3 ve 5 gizli katmanlı YSA'da ele alınan tüm nöron ve epok sayılarına ait MAPE değerleri verilmiştir.



Şekil 7. Gizli katman ve epok sayılarının tahmin performansına etkileri (14 özellik, fark verisi, 0.50-0.50 eğitim-test oranı).

Figure 7. Effects of hidden layer and epoch quantity on the forecasting performance (14 features, differenced data, 0.50-0.50 training-to-test ratio).


Üçüncü aşamada, çıktı katmanındaki aktivasyon fonksiyonunun model performansına etkisi sigmoid yerine ReLU, tanh ve doğrusal kullanılarak incelenmiştir. Denemelerde, ikinci aşamanın her iki metrik için en iyi sonuçları veren modelleri kullanılmıştır (bk. Tablo 12). Tablo 13'te bu aşamanın sonuçları özetlenerek en iyileri kalın olarak gösterilmiştir.

Tablo 13. Aktivasyon fonksiyonlarının tahmin performansına etkileri.

Table 13. Effects of activation functions on the forecasting performance.

Aktivasyon fonksiyonu	Gizli katman sayısı	Nöron sayısı	MAPE	MSE
ReLU	3	20	0.081685	4,971,176
ReLU	5	15	0.135647	63,774,733
Tanh	3	12	0.077469	6,858,741
Tanh	3	38	0.081454	5,714,426
Tanh	5	33	0.077708	5,885,620
Tanh	5	39	0.080609	5,298,009
Doğrusal	3	27	0.072853	4,888,124
Doğrusal	3	40	0.074697	4,196,943
Doğrusal	5	27	0.076807	5,006,053
Doğrusal	5	39	0.080796	4,490,899

Hata metriklerinin en düşük değerleri doğrusal aktivasyon fonksiyonuyla elde edilmiştir. Ancak, sigmoid fonksiyonunun performansı da bu değerlere oldukça yakındır. Verinin genelinde azalan bir trend olsa da, bazı periyotlarda artan değerlerin bulunması sebebiyle (bk. Şekil 1) ReLU aktivasyon fonksiyonunun nöronları aktive etmekte başarılı olamaması beklenen bir durumdur [56]. Şekil 8'de MAPE ve Şekil 9'da MSE metriklerinin nöron sayısına ve kullanılan aktivasyon fonksiyonuna göre değişimleri görülebilir. Nöron sayısı arttıkça azalan bir performans artışı (örneğin Şekil 8'de yaklaşık 12 nörondan sonra) beklenen bir durumdur. Pratikte, modelin karmaşıklığını ve çalışma süresini düşürmek için metriklerde iyileşmenin azalmaya başladığı nöron sayısı kullanılabilir.




Şekil 8. Nöron sayısı ve aktivasyon fonksiyonlarının tahmin performansına etkileri (14 özellik, fark verisi, 0.50-0.50 eğitim-test oranı, 3 gizli katman).

Figure 8. Effects of neuron quantity and activation function on the forecasting performance (14 features, differenced data, 0.50-0.50 training-to-test ratio, 3 hidden layers).

4 Tahmin modellerinin karşılaştırılması

Bu bölümde, çift üstel düzeltme, ARIMA ve YSA modellerinin en iyi performans gösterdiği parametreler ve yapılar kullanılarak tahmin performansları karşılaştırılmıştır. İlgili MAPE ve MSE metriklerinin değerleri en yüksekten en düşüğe sıralanmış olarak Şekil 9'daki sütun grafiğinde verilmiştir. Buna göre, eğitim-test oranı 0.50:0.50, 14 özellikli girdili ve 3 gizli katmanlı YSA modeli diğer modellere göre en düşük MAPE ve MSE değerlerini vermiştir. Spesifik olarak, çıktı katmanında doğrusal aktivasyon fonksiyonu kullanıldığında, MAPE metriği için 27 nöronlu ve 300 epoklu; MSE metriği için 40 nöronlu ve 300 epoklu modeller en iyi performansları göstermiştir.

Şekil 9'da ARIMA ile diğer modeller arasındaki fark görsel olarak belirgin olsa da, çift üstel düzeltmeyle YSA modelleri arasındaki fark oldukça küçüktür. Farkların istatistiksel olarak anlamlı olup olmadığını belirlemek için ek analizler yapılabilir. Bu çalışmada, parametrik olmayan, ikiden fazla popülasyonu karşılaştırmaya olanak sağlayan ve farklı örneklem büyüklükleri için kullanılabilen Kruskal-Wallis testi kullanılmıştır.



Şekil 9. Tahmin modellerinin hata metriklerinin karşılaştırması.


Figure 9. Comparison of the performance measures of the forecasting models.

Üçlü karşılaştırmayla Kruskal-Wallis testine başlanmış ve p değeri 0.05'ten küçük olduğundan en az iki yöntemin hata değerleri arasında anlamlı fark olduğu saptanmıştır. Bu nedenle, ikili karşılaştırmalara geçilmiştir (bk. Tablo 14). İkili karşılaştırmalarda ARIMA modeli diğer modellerden belirgin olarak farklı çıkmıştır. Çift üstel düzeltmeyle YSA arasında istatistiksel olarak anlamlı bir fark olduğuna dair yeterli kanıt bulunamamıştır. Dolayısıyla, eldeki verilerle SMS miktarının tahmininde ARIMA'nın tercih edilmemesi için yeterli kanıt varken, çift üstel düzeltme modeli ve YSA kullanımında esneklik bulunduğunu söyleyebiliriz. Örneğin, çift üstel düzeltme, YSA'ya göre daha basit ve yorumlanabilir bir model olduğundan tercih edilebilir.


Tablo 14. Kruskal-Wallis testinin sonuçları.
Table 14. Kruskal-Wallis test results.

Performans metriği	Karşılaştırılan modeller	Test istatistiği	p değeri
MAPE	ARIMA-DES-YSA	19.7654	0.0001
	ARIMA-DES	18.1691	0.0000
	ARIMA-YSA	14.2567	0.0002
	DES-YSA	0.5693	0.4505
MSE	ARIMA-DES-YSA	20.0378	0.0000
	ARIMA-DES	17.7989	0.0000
	ARIMA-YSA	15.4006	0.0001
	DES-YSA	0.6591	0.4169

Şekiller 10 ve 11, gerçek verilerle en iyi performans gösteren çift üstel düzeltme ve YSA modellerinin tahmin değerlerini göstermektedir. Verideki değişimin daha düzenli olduğu periyotlarda değerlerin birbirine oldukça yakın olduğu, ancak dalgalanmaların arttığı periyotlarda birbirlerinden farklılaştığı görülebilir. Bu sonuçlar beklenen bulgulardır. Eldeki veri miktarının yeterli olmaması özellikle YSA'nın eğitimini ve dolayısıyla model parametrelerinin optimizasyonunu etkilediğinden tahmin hatalarına sebep olabilmektedir. Çift üstel düzeltme yönteminin ise veride dalgalanmaların olduğu periyotlardaki tahminlerde gecikmelere yol açması beklenen bir sonuçtur.



Şekil 10. MAPE metriğinde en iyi performans gösteren modellerin tahmin değerleri ve gerçek SMS miktarları.
Figure 10. Forecasts of the models with the best performance in MAPE versus actual SMS quantities.



Şekil 11. MSE metriğinde en iyi performans gösteren modellerin tahmin değerleri ve gerçek SMS miktarları.
Figure 11. Forecasts of the models with the best performance in MSE versus actual SMS quantities.

5 Sonuçlar

Bu çalışmada, Türkiye'de gönderilen SMS miktarının tahmini için çift üstel düzeltme, ARIMA ve YSA modelleri oluşturularak modellerin tahmin performansları MSE ve MAPE metrikleriyle karşılaştırılmıştır. Bu metriklerle göre modellerin en iyi parametre değerleri kafes arama yöntemiyle belirlenmiş, ardından tahmin performansları karşılaştırılarak en yüksek performansa sahip model (YSA) seçilmiştir. YSA ve çift üstel düzeltme modellerinin tahmin ve hata metrik değerlerinin birbirine yakın olduğu gözlemlendiğinden, modellerin performansları arasında anlamlı bir istatistiksel fark olup olmadığı Kruskal-Wallis testi kullanılarak belirlenmiştir. Buna göre ARIMA modeli diğerlerinden belirgin olarak farklıdır. Çift üstel düzeltme ve YSA modellerinin performansları arasında ise anlamlı bir fark olduğuna dair yeterli bulgu elde edilememiştir. Bu sonuçlar, pratikte SMS miktarının tahmininde çift üstel düzeltme ve YSA modelleri arasında seçim esnekliği sağlayabilir. Çift üstel düzeltme, kısa vadeli tahminler için pratik, hızlı ve kolay yorumlanabilirken; YSA, hedef ve bağımsız değişkenler arasında karmaşık ve doğrusal olmayan ilişkileri modellemede başarılı olmasına rağmen daha fazla veri ve hesaplama gücü gerektirir.

YSA özelinde bir diğer çalışma bulgusu; katman, nöron ve epok sayıları arttıkça tahmin performansının genel olarak iyileştiği yönündedir. Ayrıca, YSA modelinin çıktı katmanında ReLU, tanh ve sigmoid aktivasyon fonksiyonları yerine doğrusal fonksiyonu kullanıldığında daha iyi tahmin değerleri ürettiği gözlemlenmiştir.

Yapılan bu çalışmanın sınırlılıkları olarak; girdilere ait veri sayılarının az olması, bazı girdilerin çeyrek dönem yerine yıllık olarak yayımlanması ve deneylerin çok zaman alması gösterilebilir. Veri eksikliği ve yayımlanan verilerin büyük ölçüde yıllık olmasından kaynaklanan zorlukları aşmak için, anlık SMS kullanım verilerini analiz ederek tahminleri dinamik olarak güncelleyebilen ve hızlı karar mekanizmaları oluşturabilen yöntemler gelecekteki çalışmalar kapsamında ele alınabilir. Bu tür yöntemler örneğin RCS gibi gelişen diğer mesajlaşma teknolojilerinin kullanıcı sayısı ve mesaj sayısının tahmini için daha uygun olabilir. Ayrıca, zaman serilerinin tahminine uygun olabilecek LSTM gibi derin öğrenme tekniklerinin veya klasik istatistiksel yöntemlerle derin öğrenme algoritmalarının güçlü yönlerini birleştirerek tahmin doğruluğunu arttıracak hibrit yöntemler uygulanabilir.

Kullanılan yöntemlerin, Türkiye'deki mobil ve genişbant abone sayıları, mobil veri trafiği gibi değişkenler için tahmin performansları incelenebilir. Telekom sektörü dışında farklı sektörlerdeki işletmeler mobil hizmet talep tahminlerini kullanarak, satış, kampanya, etkinlik gibi faaliyetlerini planlayabilir ve servis sağlayıcılarla yapacakları anlaşmalarda stratejik kararlar alabilir.

Son olarak, tahmin yöntemlerinin telekom sektöründeki iş zekası sistemlerine entegrasyonu kapsamında, bulut destekli sistemlerin incelenmesi ve uygulanması (bk. [57]) ile karar destek sistemlerinin geliştirilmesinin (bk. [58]) de değerli katkılar sunacağı düşünülmektedir.

6 Conclusions

In this study, double exponential smoothing, ARIMA, and artificial neural network (ANN) models are developed for forecasting the SMS quantity sent in Türkiye, and the forecasting performances of these models are compared using MAPE and MSE measures. These measures are used as the criteria for the grid search conducted to determine the best model parameter values, and then, to compare and select the best performing model (ANN). Since the forecasts and error metrics of the ANN and double exponential smoothing models are observed to be close to each other, Kruskal-Wallis test is used to check for any statistically significant difference between the model performances. Accordingly, the ARIMA model differs significantly from the others. However, no sufficient evidence was found to indicate a significant difference between the performances of the double exponential smoothing and ANN models. In practice, these results provide flexibility in choosing between the double exponential smoothing and ANN models in forecasting the SMS quantity. While double exponential smoothing is practical, fast, and easy to interpret for short-term forecasts, ANN, despite its ability to model complex and nonlinear relationships between target and independent variables, requires more data and computational power.

In the context of ANN, another finding is that the forecasting performance generally improves as the quantities of layers, neurons, and epochs increase. Additionally, it was observed that the ANN with the linear activation function in the output layer produces better forecasts than those with ReLU, tanh, and sigmoid activation functions.

Limitations of this study include the small number of data points for the inputs, the fact that some inputs are published annually rather than quarterly, and the time-consuming nature of the experiments. To overcome the challenges posed by the scarcity of and missing data, future studies may explore methods that enable real-time analysis of SMS usage data, allowing for dynamic updates to forecasts and the development of rapid decision-making mechanisms. These methods can better suit for forecasting user counts and message quantities in the case of other developing messaging technologies such as RCS. Additionally, deep learning techniques such as LSTM, which may be suitable for time series forecasting, or hybrid methods that combine the strengths of classical statistical methods and deep learning algorithms to enhance forecasting accuracy, can be implemented.

Forecasting performances of the methods can be analyzed for response variables such as number of mobile and broadband subscribers and mobile data traffic in Türkiye. Businesses in sectors other than telecommunications can use mobile service

demand forecasts to plan their activities such as sales, campaigns, events, and to make strategic decisions in their agreements with service providers.

Finally, we believe it is worthwhile to examine and implement cloud-supported systems (see, e.g., [57]) and to develop decision support systems (see, e.g., [58]) for integrating forecasting methods into business intelligence systems.

7 Yazar katkı beyanı

Yazar 1 fikrin oluşması, literatür taraması, deneylerin yapılması, sonuçların değerlendirilmesi; Yazar 2 fikrin şekillenmesi, kullanılacak yöntemlerle ve deneylerle ilgili yol gösterilmesi, çalışmanın sürekli 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 bulunmamaktadır.

9 Kaynaklar

- [1] Yapraklı TŞ, Altay Ş. "Mobil Anlık Mesajlaşma Servislerinin Kullanımı Üzerinde Etkili Faktörlerin İncelenmesi: Ardahan Üniversitesi Öğrencileri Üzerinde Bir Saha Araştırması". *Öneri Dergisi*, 12(48), 199-216, 2017.
- [2] GSMA. (t.y.). "Rich communication services (RCS)". <https://www.gsma.com/solutions-and-impact/technologies/networks/rcs/> (01.04.2025).
- [3] 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.
- [4] Özden C, Açı Ç. "Makine öğrenmesi yöntemleri ile yaralanmalı trafik kazalarının analizi: Adana örneği". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 266-275, 2018.
- [5] Erdem F. "Parameter estimation in crystal sugar production with MLR, ANN and ANFIS". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 28(7), 987-992, 2022.
- [6] Aydemir E, Karaatlı M, Yılmaz G, Aksoy S. "112 Acil çağrı merkezine gelen çağrı sayılarını belirleyebilmek için bir yapay sinir ağları tahminleme modeli geliştirilmesi". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 20(5), 145-149, 2014.
- [7] Zeybel Peköz A, İnkaya T. "Derin öğrenme ile talep tahmini: Bir üçüncü parti lojistik firması için COVID-19 döneminde vaka analizi". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(4), 331-339, 2023.
- [8] Nikravesh AY, Ajila SA, Lung CH, Ding W. "Mobile network traffic prediction using MLP, MLPWD, and SVM". *2016 IEEE International Congress on Big Data*, SF, ABD, 27 Haziran-02 Temmuz 2016.
- [9] Siluye I, Jere S. "Using Box-Jenkins models to forecast mobile cellular subscription". *Open Journal of Statistics*, 6(2), 81-90, 2016.
- [10] Huang CW, Chiang CT, Li Q. "A study of deep learning networks on mobile traffic forecasting". *2017 IEEE 28th Annual International Symposium on Personal, Indoor, and*

- Mobile Radio Communications, Montreal, Kanada, 8-13 Ekim 2017.
- [11] Alvarado JG, Alvarado AD, Lema, EV. "Time series analysis of telecommunications data using neural networks". *Turkish Journal of Computer and Mathematics Education*, 12(14), 2835- 284, 2021.
- [12] Prajam S, Wechtaisong C, Khan AA. "Applying machine learning approaches for network traffic forecasting". *Indian Journal of Computer Science and Engineering*, 13(2), 324-335, 2022.
- [13] Xie R, Guan X, Cao J, Wang X, Wu H. "HSeq2Seq: Hierarchical graph neural network for accurate mobile traffic forecasting". *Information Sciences*, 679, 1-18, 2024.
- [14] Batool I, Fouda MM, Fadlullah ZM. "Deep learning-based throughput prediction in 5G cellular networks". *2024 International Conference on Smart Applications, Communications and Networking*, Harrisonburg, ABD, 28-30 Mayıs 2024.
- [15] Zeng L, Zhang C, Qin P, Zhou Y, Cai Y. "One Method for Predicting Satellite Communication Terminal Service Demands Based on Artificial Intelligence Algorithms". *Applied Sciences*, 14, 6019, 2024.
- [16] Jiang W, Zhang Y, Han H, Huang Z, Li Q, Mu J. "Mobile traffic prediction in consumer applications: A multimodal deep learning approach". *IEEE Transactions on Consumer Electronics*, 70(1), 3425-3435, 2024.
- [17] Türkiye İstatistik Kurumu. "Tüketici Fiyat Endeksi, Aralık 2023". <https://data.tuik.gov.tr/Bulten/Index?p=Tuketici-Fiyat-Endeksi-Aralik-2023-49657> (20.09.2024).
- [18] Bilgi Teknolojileri ve İletişim Kurumu. "Pazar Verileri". <https://www.btk.gov.tr/pazar-verileri> (29.08.2024).
- [19] Türkiye İstatistik Kurumu. "Ulusal Eğitim İstatistikleri, 2023". <https://data.tuik.gov.tr/Bulten/Index?p=Ulusal-Egitim-Istatistikleri-2023-53444> (20.09.2024).
- [20] Can U. "Eksik veri probleminin çözümü". *YBS Ansiklopedi*, 12(1), 24-60, 2024.
- [21] Huang G. "Missing data filling method based on linear interpolation and LightGBM". *Journal of Physics: Conference Series*, 1754(1), 1-6, 2021.
- [22] Iranzad R, Liu X. "A review of random forest-based feature selection methods for data science education and applications". *International Journal of Data Science and Analytics*, 2024.
- [23] Aksu G, Güzeller CO, Eser MT. "The effect of the normalization method used in different sample sizes on the success of artificial neural network model". *International Journal of Assessment Tools in Education*, 6(2), 170-192, 2019.
- [24] Singh D, Singh B. "Feature wise normalization: An effective way of normalizing data". *Pattern Recognition*, 122, 108307, 2022.
- [25] Shalabi L, Shaaban Z. "Normalization as a preprocessing engine for data mining and the approach of preference matrix". *2006 International Conference on Dependability of Computer Systems*, Szklarska Poreba, Polonya, 25-27 Mayıs 2006.
- [26] Eesa AS, Arabo W. "A normalization method for backpropagation: A comparative study". *Science Journal of University of Zakho*, 5(4), 319, 2017.
- [27] Hyndman RJ, Koehler AB. "Another look at measures of forecast accuracy". *International Journal of Forecasting*, 22(4), 679-688, 2006.
- [28] Saigal S, Mehrotra D. "Performance Comparison of Time Series Data Using Predictive Data Mining Techniques". *Advances in Information Mining*, 4(1), 57-66, 2012.
- [29] Armstrong JS, Collopy F. "Error measures for generalizing about forecasting methods: Empirical comparisons". *International Journal of Forecasting*, 8(1), 69-80, 1992.
- [30] Zhang G, Patuwo BE, Hu MY. "Forecasting with artificial neural networks: The state of the art". *International Journal of Forecasting*, 14(1), 35-62, 1998.
- [31] Öztürk K, Şahin ME. "Yapay sinir ağları ve yapay zekâ'ya genel bir bakış". *Takvim-i Vekayi*, 6(2), 25-36, 2018.
- [32] Banerjee C, Mukherjee T, Pasiliao EJ. "An empirical study on generalizations of the ReLU activation function". *Proceedings of the ACM Southeast Conference*, Kennesaw, GA, ABD, 18-20 Nisan 2019.
- [33] TensorFlow. "tf.keras.activations.sigmoid". https://www.tensorflow.org/api_docs/python/tf/keras/activations/sigmoid (19.12.2024).
- [34] Chen Y, Li L, Li W, Guo Q, Du Z, Xu Z. *Fundamentals of neural networks*. Editör: Merken S. AI computing systems: An application-driven perspective, 17-51, Cambridge, ABD, Morgan Kaufmann, 2022.
- [35] Bhujade RK, Asthana S. "An extensive review of ReLU and sigmoid function in multiple hidden layer back propagation neural network model". *International Journal of Applied Engineering and Technology*, 5(2), 67-70, 2023.
- [36] Rasamoelina AD, Adjailia F, Sinčák P. "A review of activation function for artificial neural network". *IEEE 18th World Symposium on Applied Machine Intelligence and Informatics*, Herlany, Slovakya, 23-25 Ocak 2020.
- [37] Sharma S, Sharma S, Athaiya A. "Activation functions in neural networks". *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310-316, 2020.
- [38] Kruskal WH, Wallis WA. "Use of Ranks in One-Criterion Variance Analysis". *Journal of the American Statistical Association*, 47(260), 583-621, 1952.
- [39] Goodwin P. "The Holt-Winters approach to exponential smoothing: 50 years old and going strong". *Foresight: The International Journal of Applied Forecasting*, 19, 30-33, 2010.
- [40] Bergmeir C, Hyndman RJ, Beníte JM. "Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation". *International Journal of Forecasting*, 32(2), 303-312, 2016.
- [41] Billah B, King ML, Snyder RD, Koehler AB. "Exponential smoothing model selection for forecasting". *International Journal of Forecasting*, 22(2), 239-247, 2006.
- [42] Nahmias S, Olsen TL. *Production and Operations Analysis*, 52-126, Long Grove, Illinois, ABD, Waveland Press, 2015.
- [43] Peter D, Silvia P. "ARIMA Vs. ARIMAX – Which Approach is Better to Analyze and Forecast Macroeconomic Time

- Series". *Proceedings of 30th International Conference Mathematical Methods in Economics*, 136-140, 2012.
- [44] McCulloch WS, Pitts WH. "A logical calculus of the ideas immanent in nervous activity". *Bulletin of Mathematical Biophysics*, 5, 115-133, 1943.
- [45] Öztemel E. *Yapay Sinir Ağları*, 45-58, İstanbul, Türkiye, Papatya Yayıncılık Eğitim, 2012.
- [46] Uğur A, Kınacı AC. "Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması". *"Türkiye'de İnternet" Konferansı*, Ankara, Türkiye, 21-23 Aralık 2006.
- [47] Arslan B, Ertuğrul İ. "Çoklu regresyon, ARIMA ve yapay sinir ağı yöntemleri ile Türkiye elektrik piyasasında fiyat tahmin ve analizi". *Yönetim ve Ekonomi Araştırmaları Dergisi*, 20(1), 331-353, 2022.
- [48] Yao X. "Evolving artificial neural networks". *Proceedings of the IEEE*, 87(9), 1423-1447, 1999.
- [49] Kingma DP, Ba J. "Adam: A Method for Stochastic Optimization". *arXiv preprint arXiv:1412.6980*, <https://arxiv.org/abs/1412.6980>, 2014.
- [50] Pabuccu H, Barbu A. "Feature selection with annealing for forecasting financial time series". *Financial Innovation*, 10, 87, 2024.
- [51] Joseph VR. "Optimal ratio for data splitting". *Statistical Analysis & Data Mining*, 15, 531-538, 2022.
- [52] Ünal T, Çiftçi Ü, Urgan NN. "Bir Gizli Katmanlı Yapay Sinir Ağlarında Optimal Nöron Sayısının İncelenmesi." *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, 17(2), 303-325, 2022.
- [53] Yılmazel Ö, Afşar A, Yılmazel S. "Konut Fiyat Tahmininde Yapay Sinir Ağları Yönteminin Kullanılması". *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 20, 285-300, 2018.
- [54] Kurt R, Karayılmazlar S, İmren E, Çabuk Y. "Yapay sinir ağları ile öngörü modellemesi: Türkiye kağıt-karton sanayi örneği". *Bartın Orman Fakültesi Dergisi*, 19(2), 99-106, 2017.
- [55] Çılgın C, Ünal C, Alıcı S, Akkol E, Gökşen Y. "Metin sınıflandırmada yapay sinir ağları ile Bitcoin fiyatları ve sosyal medyadaki beklentilerin analizi". *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 4(1), 106-126, 2020.
- [56] Dubey SR, Singh SK, Chaudhuri BB. "Activation functions in deep learning: A comprehensive survey and benchmark". *Neurocomputing*, 503, 92-108, 2022.
- [57] Torkul O, Kor E, Şişçi M. "Tedarik Zincirinde Hibrit Talep Tahmin Modeli Önerisi: Çelik Sektörü Uygulaması". *Journal of Intelligent Systems: Theory and Applications*, 7(2), 66-80, 2024.
- [58] Algorabi Ö, Namlı E. "Banka Telepazarlama Başarısının Tahmini İçin Bir Birleşik Makine Öğrenme Tabanlı Karar Destek Modeli". *Verimlilik Dergisi* (1), 94-109, 2022.

Ek A

Kullanılan Kısaltmalar

Tablo 15. Kısaltmalar.
Table 15. Abbreviations.

Yöntemler

3D CNN	Üç boyutlu evrişimli sinir ağı
ARIMA	Birleştirilmiş otoregresif hareketli ortalama
ASTGCN	Dikkat tabanlı uzamsal-zamansal grafik evrişim ağı
BiLSTM	Çift yönlü uzun kısa vadeli bellek
CNN	Evrişimli sinir ağı
Conv3D	3D konvolüsyonel sinir ağı
ConvGRU	Konvolüsyonel kapı yinelemeli birimler
ConvLSTM	Çok modlu evrişimsel uzun-kısa süreli bellek
DES	Çift üstel düzeltme
DMFS-MF	Çift modüler özellik paylaşım katmanı-çoklu görev öğrenme katmanı
FNN	İleri beslemeli yapay sinir ağı
GASTN	Uzamsal-zamansal grafik dikkat ağı
GNN	Grafik sinir ağı
Graph WaveNet	Grafik WaveNet
HA	Tarihsel ortalama
HGCN	Hiyerarşik grafik sinir ağı
HSeq2Seq	Hiyerarşik sıradan sıraya
LM	Levenberg-Marquardt algoritması
LSTM	Uzun kısa süreli bellek
MLP	Çok katmanlı algılayıcı
MLPWD	Ağırlık azalmalı çok katmanlı algılayıcı
MTL	Çoklu görev öğrenme
RF	Rastgele orman
RNN	Yinelemeli sinir ağı
Seq2Seq	Sıradan sıraya
SMA	Basit hareketli ortalama
STAGCN	Uzamsal-zamansal toplama grafiği evrişimsel ağı
STCNet	Uzamsal-zamansal çapraz alanlı sinir ağı
STDenseNet	Standartlaştırılmış yoğun bağlantılı evrişimli ağı
STGCN	Uzamsal-zamansal grafik evrişimsel ağı
STL	Tekli görev öğrenme
SVM	Destek vektör makinesi
SVR	Destek vektör regresyonu
YSA	Yapay sinir ağı
Hata Metrikleri	
AIC	Akaike bilgi kriteri
MAD	Ortalama mutlak hata sapması
MAE	Ortalama mutlak hata
MAPE	Ortalama mutlak yüzde hata
MSE	Ortalama kare hata
RE	Göreceli hata
RMSE	Ortalama kare hatanın karekökü
SBC	Schwarz Bayes kriteri

Ek B

3 ve 5 gizli katmanlı YSA denemelerinin performansları

Tablo 16. 3 ve 5 gizli katmanlı YSA modellerinde MAPE değerleri.

Table 16. MAPE values for the ANN models with 3 and 5 hidden layers.

Nöron sayısı	(Gizli katman, Epok sayısı)			
	(3, 200)	(3, 300)	(5, 200)	(5, 300)
5	0.263592	0.156849	0.349084	0.182967
6	0.171565	0.165420	0.329471	0.145199
7	0.197723	0.163454	0.146056	0.091244
8	0.173863	0.144594	0.161699	0.110275
9	0.144244	0.133692	0.104790	0.094905
10	0.125975	0.129991	0.154662	0.080133
11	0.103580	0.080895	0.124133	0.083189
12	0.102059	0.080544	0.093280	0.082327
13	0.093224	0.080477	0.086876	0.077853
14	0.096466	0.083017	0.085102	0.078667
15	0.088318	0.079218	0.079982	0.078786
16	0.081816	0.077835	0.081081	0.080619
17	0.092447	0.077681	0.086517	0.079373
18	0.105664	0.078342	0.083331	0.078246
19	0.090914	0.079660	0.079656	0.080624
20	0.090690	0.080247	0.081218	0.078579
21	0.085996	0.075474	0.079440	0.079766
22	0.082993	0.082356	0.078073	0.080751
23	0.080467	0.077193	0.076510	0.077277
24	0.081624	0.078617	0.081956	0.075326
25	0.084416	0.075175	0.077859	0.079612
26	0.081956	0.077908	0.079692	0.076717

27	0.080636	0.078797	0.076795	0.080180
28	0.079196	0.078683	0.078719	0.078941
29	0.080491	0.074880	0.075691	0.076843
30	0.080773	0.078396	0.078034	0.084266
31	0.078937	0.077013	0.078210	0.079427
32	0.080122	0.078061	0.078976	0.077236
33	0.080049	0.079066	0.080408	0.077987
34	0.076830	0.077898	0.076622	0.076429
35	0.078420	0.078706	0.077750	0.078280
36	0.079085	0.077173	0.076673	0.082186
37	0.078968	0.075311	0.077898	0.078001
38	0.078092	0.073757	0.075866	0.082320
39	0.077733	0.076437	0.080902	0.081121
40	0.080287	0.078531	0.076799	0.077363

Düzenlenmemis Sürüm - Uncorrected Version