



**YAPAY SİNİR AĞLARI KULLANILARAK MOBİL VE GENİŞBANT
ABONE SAYISI, MOBİL TRAFİK HACMİ, SMS VE MMS MİKTARI
TAHMİNİ**

Mehtap PARLAK

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2025

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Mehtap PARLAK

15/12/2025

YAPAY SİNİR AĞLARI KULLANILARAK MOBİL VE GENİŞBANT ABONE SAYISI, MOBİL TRAFİK HACMİ, SMS VE MMS MİKTARI TAHMİNİ

(Yüksek Lisans Tezi)

Mehtap PARLAK

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2025

ÖZET

Günümüzde, teknolojinin hızlı gelişimi ve cep telefonu ile bilgisayar gibi teknolojik ürünlerin yaygın kullanımı, elektronik haberleşme sektörünü günlük yaşamın vazgeçilmez bir unsuru hâline getirmiştir. Sektörün sürekli değişen dinamikleri ve artan kullanıcı taleplerine bağlı olarak her geçen gün üretilen veri miktarında da artış yaşanmaktadır. Sektörün kesintisiz hizmet sunma gerekliliği de göz önüne alındığında kaynakların etkin planlanarak yönetilmesi ve kullanıcı ihtiyaçlarının doğru analizi sektör için kritik öneme sahiptir. Bu kapsamda, ağ performansı, talep yoğunluğu, veri trafiği gibi bazı göstergelerin doğru biçimde tahmin edilmesi söz konusu stratejik süreçler için önemli katkılar sağlayacaktır. Bu bağlamda bu çalışmada, mobil ve genişbant internet abone sayıları, kısa mesaj servisi (SMS) ve çoklu ortam mesaj hizmeti (MMS) miktarları ile mobil ses trafik hacminin tahmini gerçekleştirilmiştir. Çalışmanın temel amacı, bu göstergelerinin tahmininde yapay sinir ağı (YSA) kullanımının etkisini analiz etmek ve en yüksek doğruluğu sağlayan metodu belirlemektir. Bu kapsamda, mobil ses trafik hacmi için mevsimsel birleştirilmiş otoregresif hareketli ortalama (SARIMA), Holt-Winters ve YSA; diğer göstergeler için ise birleştirilmiş otoregresif hareketli ortalama (ARIMA), çift üstel düzeltme ve YSA yöntemleri kullanılmıştır. Her modelde en uygun parametreler belirlenmiş, YSA için farklı epok, gizli katman sayıları ile aktivasyon fonksiyonları test edilmiştir. Yöntem karşılaştırmalarında hata metrikleri olarak ortalama mutlak hata, ortalama mutlak yüzde hata ve ortalama kare hata kullanılmış; en iyi SARIMA modeli seçiminde ise Akaike bilgi kriteri ve Bayes bilgi kriteri dikkate alınmıştır. Çalışma sonunda ayrıca, yöntemlerin en iyi modelleri Kruskal-Wallis testi ile istatistiksel olarak karşılaştırılmıştır. Bulgular, trend içeren serilerde YSA ve çift üstel düzeltmenin ARIMA'ya göre, mevsimsellik içeren serilerde ise Holt-Winters'in SARIMA ve YSA'ya göre daha başarılı olduğunu göstermektedir. Çalışmanın diğer bir bulgusu, YSA özelinde, katman, nöron ve epok sayılarındaki artışın genellikle modelin performansında iyileşme sağladığı yönündedir. Bununla birlikte, çıktı katmanında doğrusal, sigmoid ve hiperbolik tanjant aktivasyon fonksiyonlarının kullanılmasının, düzeltilmiş doğrusal birime göre daha tutarlı ve benzer sonuçlar ürettiği gözlemlenmiştir.

Bilim Kodu : 90632

Anahtar Kelimeler : Zaman serisi tahmini, elektronik haberleşme sektörü göstergeleri, yapay sinir ağları, geleneksel yöntemler

Sayfa Adedi : 152

Danışman : Dr. Öğr. Üyesi Gonca YILDIRIM

FORECASTING THE NUMBER OF MOBILE AND BROADBAND SUBSCRIBERS,
MOBILE TRAFFIC VOLUME, SMS AND MMS AMOUNTS USING ARTIFICIAL
NEURAL NETWORKS

(M. Sc. Thesis)

Mehtap PARLAK

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2025

ABSTRACT

Today, the rapid development of technology and the widespread use of technological devices such as mobile phones and computers have made the electronic communications sector an indispensable part of daily life. The continuously changing dynamics of the sector and the increasing user demands lead to a steady growth in the amount of data produced. Considering the necessity of uninterrupted service provision, effective planning and management of resources, as well as accurate analysis of user needs, are of critical importance for the sector. In this context, accurate forecasting of certain indicators such as network performance, demand intensity, and data traffic can make significant contributions to strategic decision-making processes. Accordingly, this study focuses on forecasting mobile and broadband internet subscriber numbers, short message service and multimedia messaging service volumes, and mobile voice traffic volume. The main objective is to examine the effect of Artificial Neural Networks (ANN) on the forecasting performance of these indicators and to determine the method that yields the highest accuracy. For this purpose, Seasonal Autoregressive Integrated Moving Average (SARIMA), Holt-Winters, and ANN models were applied for mobile voice traffic volume, while Autoregressive Integrated Moving Average (ARIMA), Double Exponential Smoothing, and ANN were used for the remaining indicators. Optimal parameters were determined for each model, and different epoch numbers, hidden layer sizes, and activation functions were tested for the ANN models. Mean Absolute Error, Mean Absolute Percentage Error, and Mean Squared Error were used as evaluation metrics, and Akaike Information Criterion and Bayesian Information Criterion were considered for selecting the best SARIMA model. Additionally, the best-performing models were statistically compared using the Kruskal-Wallis test. The findings indicate that ANN and Double Exponential Smoothing outperform ARIMA in series containing trend, while Holt-Winters performs better than SARIMA and ANN in series containing seasonality. Another key finding regarding ANN is that increasing the number of layers, neurons, and epochs generally improves model performance. Moreover, using linear, sigmoid, and hyperbolic tangent activation functions in the output layer were observed to produce more consistent and similar results compared to the rectified linear unit.

Science Code : 90632

Key Words : Time series forecasting, electronic communications sector indicators,
artificial neural networks, traditional methods

Page Number : 152

Supervisor : Asst. Prof. Dr. Gonca YILDIRIM

TEŞEKKÜR

Bu çalışmanın hazırlanması sürecinde, kıymetli bilgi ve tecrübelerini benimle paylaşarak her aşamada yol gösteren, sabrı ve özverisi ile karşılaştığım güçlükleri aşmamda bana daima destek olan ve akademik bakış açımın şekillenmesine büyük katkı sağlayan değerli danışman hocam Sayın Dr. Öğretim Üyesi Gonca YILDIRIM'a en içten teşekkürlerimi sunarım. Ayrıca, hayatımın her döneminde olduğu gibi bu süreçte de yanımda olarak desteklerini esirgemeyen canım anneme, babama ve kardeşime de gönülden teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ	xiv
SİMGELER VE KISALTMALAR.....	xvii
1. GİRİŞ	1
2. GEÇMİŞ ÇALIŞMALAR	5
3. TAHMİN YÖNTEMLERİ	13
3.1. Nitel Tahmin Yöntemleri	15
3.1.1. Yönetici görüşleri.....	15
3.1.2. Senaryo analizi	15
3.1.3. Delphi tekniği.....	15
3.1.4. Anketler.....	16
3.1.5. Uzman panelleri	16
3.2. Nicel Tahmin Yöntemleri	16
3.2.1. Zaman serileri analizi	16
3.2.2. Nedensel yöntemler.....	21
3.2.3. Yapay zekâ temelli yöntemler.....	23
4. UYGULAMA	31
4.1. Uygulamanın Genel Yapısı	31
4.1.1. Veri kümesi	31

	Sayfa
4.1.2. Hata metrikleri	33
4.1.3. Yöntem.....	34
4.2. Geniřbant İnternet Abone Sayısı.....	41
4.2.1. Veri kümesi	41
4.2.2. Özellik seçimi	42
4.2.3. Yöntem.....	44
4.3. Mobil Abone Sayısı.....	57
4.3.1. Veri kümesi	58
4.3.2. Özellik seçimi	59
4.3.3. Yöntem.....	61
4.4. MMS Miktarı	74
4.4.1. Veri kümesi	74
4.4.2. Özellik seçimi	75
4.4.3. Yöntem.....	77
4.5. SMS Miktarı.....	91
4.5.1. Özellik seçimi	91
4.5.2. Yöntem.....	92
4.6. Mobil ses trafik hacmi.....	103
4.6.1. Veri kümesi	103
4.6.2. Özellik seçimi	104
4.6.3. Yöntem.....	107
5. SONUÇ VE ÖNERİLER.....	125
KAYNAKLAR	129
EKLER.....	137

Sayfa

EK-1. Geniřbant internet abone sayısı tahmininde epok ve nöron sayılarının MAE'ye etkileri.....	138
EK-2. Geniřbant internet abone sayısı tahmininde epok ve nöron sayılarının MAPE'ye etkileri	139
EK-3. Geniřbant internet abone sayısı tahmininde epok ve nöron sayılarının MSE'ye etkileri.....	140
EK-4. Mobil abone sayısı tahmininde epok ve nöron sayılarının MAE'ye etkileri	141
EK-5. Mobil abone sayısı tahmininde epok ve nöron sayılarının MAPE'ye etkileri	142
EK-6. Mobil abone sayısı tahmininde epok ve nöron sayılarının MSE'ye etkileri	143
EK-7. MMS miktarı tahmininde epok ve nöron sayılarının MAE'ye etkileri.....	145
EK-8. MMS miktarı tahmininde epok ve nöron sayılarının MAPE'ye etkileri.....	146
EK-9. MMS miktarı tahmininde epok ve nöron sayılarının MSE'ye etkileri.....	147
EK-10. SMS miktarı tahmininde epok ve nöron sayılarının MAE'ye etkileri	148
EK-11. Mobil ses trafik hacmi tahmininde epok ve nöron sayılarının MAE'ye etkileri.....	149
EK-12. Mobil ses trafik hacmi tahmininde epok ve nöron sayılarının MAPE'ye etkileri.....	150
EK-13. Mobil ses trafik hacmi tahmininde epok ve nöron sayılarının MSE'ye etkileri.....	151
ÖZGEÇMİř	152

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. İnternet trafik hacminin tahminine yönelik yapılan çalışmalar	5
Çizelge 2.2. Ses trafiği ve SMS miktarı tahminine ilişkin yapılan çalışmalar	9
Çizelge 2.3. Elektronik haberleşme sektöründeki kullanıcı sayısı ve kullanım tercihlerine yönelik yapılan çalışmalar	10
Çizelge 3.1. Üstel düzeltme yöntemlerine ait notasyon	18
Çizelge 3.2. ARIMA yöntemine ait notasyon.....	20
Çizelge 3.3. SARIMA yöntemine ait mevsimsellik içeren notasyon	20
Çizelge 3.4. Çoklu regresyon metoduna ait notasyon.....	22
Çizelge 3.5. Nöronun bilgi işleme biçimi formülüne ait notasyon	27
Çizelge 4.1. RFE yöntemi aşamaları.....	33
Çizelge 4.2. Hata metriklerinde kullanılan notasyon.....	34
Çizelge 4.3. ARIMA yöntemine ait sözde kod	35
Çizelge 4.4. Çift üstel düzeltme yöntemi sözde kodu.....	36
Çizelge 4.5. Min-Max normalizasyon yöntemine ait notasyon.....	37
Çizelge 4.6. Üç aşama için oluşturulan YSA modellerinin yapısı.....	39
Çizelge 4.7. YSA yöntemi aşamalarına ait sözde kod	39
Çizelge 4.8. Genişbant internet abone sayısı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları	43
Çizelge 4.9. Genişbant internet abone sayısının tahmininde ARIMA (2,2,3) modelinin farklı eğitim-test oranındaki deneme sonuçları.....	46
Çizelge 4.10. Genişbant abone sayısı tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi sonuçları.....	47
Çizelge 4.11. Genişbant internet abone sayısı tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları	48
Çizelge 4.12. Genişbant internet abone sayısı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları	50

Çizelge	Sayfa
Çizelge 4.13. Genişbant internet abone sayısı tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları	53
Çizelge 4.14. Genişbant internet abone sayısı tahmini için yapılan Kruskal-Wallis testine ait sonuçlar	56
Çizelge 4.15. Mobil abone sayısı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları.....	60
Çizelge 4.16. Mobil abone sayısının tahmininde ARIMA (3,1,2) modelinin farklı eğitim-test oranındaki deneme sonuçları	63
Çizelge 4.17. Mobil abone sayısı tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi sonuçları	63
Çizelge 4.18. Mobil abone sayısı tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları	64
Çizelge 4.19. Mobil abone sayısı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları	66
Çizelge 4.20. Mobil abone sayısı tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları.....	69
Çizelge 4.21. Mobil abone sayısı tahmini için yapılan Kruskal-Wallis testine ait sonuçlar	72
Çizelge 4.22. MMS miktarı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları.....	76
Çizelge 4.23. MMS miktarının tahmininde ARIMA (2,1,1) modelinin farklı eğitim-test oranlarındaki deneme sonuçları	79
Çizelge 4.24. MMS miktarının tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi sonuçları	80
Çizelge 4.25. MMS miktarı tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları.....	81
Çizelge 4.26. MMS miktarı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları.....	83
Çizelge 4.27. MMS miktarı tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları.....	86
Çizelge 4.28. MMS miktarı tahmini için yapılan Kruskal-Wallis testine ait sonuçlar ...	89

Çizelge	Sayfa
Çizelge 4.29. SMS miktarı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları	92
Çizelge 4.30. SMS miktarının tahmininde ARIMA (1,1,0) modelinin farklı eğitim-test oranındaki deneme sonuçları	93
Çizelge 4.31. SMS miktarı tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi MAE hata metriği sonuçları	93
Çizelge 4.32. SMS miktarının tahmininde YSA yöntemine ait birinci aşamanın en iyi MAE metriği sonuçları.....	94
Çizelge 4.33. SMS miktarının tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları.....	96
Çizelge 4.34. SMS miktarının tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları.....	100
Çizelge 4.35. SMS miktarının tahmini için yapılan Kruskal-Wallis testine ait sonuçlar	102
Çizelge 4.36. Mobil ses trafik hacmi tahmini için YSA ve regresyon modellerinde kullanılan özellikler ile numaralandırmaları.....	106
Çizelge 4.37. Holt-Winters yöntemi sözde kodu.....	108
Çizelge 4.38. Mobil ses trafik hacmi tahmini için α , β ve γ değerlerine göre en iyi Holt-Winters yöntemi sonuçları	108
Çizelge 4.39. SARIMA yöntemine ait sözde kod	110
Çizelge 4.40. Mobil ses trafik hacminin tahmini için yapılan farklı SARIMA model denemelerine ait sonuçlar	112
Çizelge 4.41. SARIMA (2,1,0) $\times$ (2,1,0) ₄ ve SARIMA (1,1,0) $\times$ (2,1,0) ₄ modellerinin farklı eğitim-test oranındaki deneme sonuçları	114
Çizelge 4.42. Mobil ses trafik hacmi tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları.....	115
Çizelge 4.43. Mobil ses trafik hacmi tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları.....	117
Çizelge 4.44. Mobil ses trafik hacmi tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları	120
Çizelge 4.45. Mobil ses trafik hacmi tahmini için yapılan Kruskal-Wallis testine ait sonuçlar	123

Çizelge**Sayfa**

Çizelge 5.1. Tahmin edilen göstergelerin en iyi model yapıları	125
--	-----



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Tahmin yöntemleri.....	14
Şekil 3.2. Bir adet gizli katmanlı yapay sinir ağı modeli yapısı örneği	28
Şekil 4.1. Türkiye ile Avrupa Ülkelerinin MoU Değerlerinin Karşılaştırılması	31
Şekil 4.2. Genişbant internet abone sayısının zaman serisi grafiği.....	41
Şekil 4.3. Ham veri ve fark verisi ile uygulanan RFE yöntem sonucuna göre genişbant internet abone sayısı tahminindeki özelliklerin elenme sırası.....	44
Şekil 4.4. Genişbant internet abone sayısı tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri	45
Şekil 4.5. Genişbant internet abone sayısı tahmininde ikinci dereceden fark alınmış verinin otokorelasyon ve kısmi otokorelasyon grafikleri	46
Şekil 4.6. Genişbant internet abone sayısı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim	49
Şekil 4.7. Farklı gizli katman ve epok sayısı denemelerine göre genişbant internet abone sayısının tahmin performansındaki değişimi	52
Şekil 4.8. Aktivasyon fonksiyonlarının genişbant internet abone sayısının tahmin performansına etkisi.....	54
Şekil 4.9. Genişbant internet abone sayısı tahmin modellerinin karşılaştırılması	55
Şekil 4.10. En iyi MAE ve MAPE hata metrik sonuçlarının elde edildiği hiper parametrelerle üretilen genişbant abone sayısı tahminlerinin karşılaştırılması.....	57
Şekil 4.11. En iyi MSE metriği sonucunun elde edildiği hiper parametrelerle üretilen genişbant abone sayısı tahminlerinin karşılaştırılması	57
Şekil 4.12. Mobil abone sayısının zaman serisi grafiği	58
Şekil 4.13. Ham veri ve fark verisi ile uygulanan RFE yöntem sonucuna göre mobil abone sayısı tahminindeki özelliklerin elenme sırası	61
Şekil 4.14. Mobil abone sayısı tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri.....	62
Şekil 4.15. Mobil abone sayısı tahmininde birinci dereceden fark alınmış verinin otokorelasyon ve kısmi otokorelasyon grafikleri	62

Şekil	Sayfa
Şekil 4.16. Mobil abone sayısı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim	65
Şekil 4.17. Farklı gizli katman ve epok sayısı denemelerine göre mobil abone sayısının tahmin performansındaki değişimi	68
Şekil 4.18. Aktivasyon fonksiyonlarının mobil abone sayısının tahmin performansına etkisi	70
Şekil 4.19. Mobil abone sayısı tahmin modellerinin karşılaştırılması	71
Şekil 4.20. En iyi MAE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen mobil abone sayısı tahminlerinin karşılaştırılması	73
Şekil 4.21. En iyi MAPE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen mobil abone sayısı tahminlerinin karşılaştırılması	73
Şekil 4.22. En iyi MSE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen mobil abone sayısı tahminlerinin karşılaştırılması	73
Şekil 4.23. MMS miktarının zaman serisi grafiği	74
Şekil 4.24. Ham veri ve fark verisi ile uygulanan RFE yöntem sonucuna göre MMS miktarı tahminindeki özelliklerin elenme sırası	77
Şekil 4.25. MMS miktarının tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri	78
Şekil 4.26. MMS miktarının tahmininde birinci dereceden fark alınmış verinin otokorelasyon ve kısmi otokorelasyon grafikleri	78
Şekil 4.27. MMS miktarı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim	82
Şekil 4.28. Farklı gizli katman ve epok sayısı denemelerine göre MMS miktarı tahmininin performans değişimi	85
Şekil 4.29. Aktivasyon fonksiyonlarının MMS miktarı tahmin performansına etkisi....	87
Şekil 4.30. MMS miktarı tahmin modellerinin karşılaştırılması	88
Şekil 4.31. En iyi MAE metriği sonucunun elde edildiği hiper parametrelerle üretilen MMS miktarı tahminlerinin karşılaştırılması	90
Şekil 4.32. En iyi MAPE metriği sonucunun elde edildiği hiper parametrelerle üretilen MMS miktarı tahminlerinin karşılaştırılması	90

Şekil	Sayfa
Şekil 4.33. En iyi MSE metriği sonucunun elde edildiği hiper parametrelerle üretilen MMS miktarı tahminlerinin karşılaştırılması	90
Şekil 4.34. SMS miktarı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim	95
Şekil 4.35. Farklı gizli katman ve epok sayısı denemelerine göre SMS miktarı tahmininin performans değişimi	99
Şekil 4.36. Aktivasyon fonksiyonlarının SMS miktarı tahmin performansına MAE hata metriği özelindeki etkisi	101
Şekil 4.37. MAE hata metriği açısından SMS miktarı tahmin modellerinin karşılaştırılması	101
Şekil 4.38. En iyi MAE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen SMS miktarı tahminlerinin karşılaştırılması	103
Şekil 4.39. Mobil ses trafik hacminin zaman serisi grafiği	104
Şekil 4.40. Ham veri ile uygulanan RFE yöntem sonucuna göre mobil ses trafik hacmi tahminindeki özelliklerin elenme sırası	107
Şekil 4.41. Mobil ses trafik hacmi zaman serisinin mevsimsel trend ayrıştırması	111
Şekil 4.42. Mobil ses trafik hacminin tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri	111
Şekil 4.43. Mobil ses trafik hacminin tahmini için alınan birleşik farkın sonucunda oluşan otokorelasyon ve kısmi otokorelasyon grafikleri	112
Şekil 4.44. Mobil ses trafik hacmi tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim	116
Şekil 4.45. Farklı gizli katman ve epok sayısı denemelerine göre mobil ses trafik hacminin tahmin performansındaki değişimi	119
Şekil 4.46. Aktivasyon fonksiyonlarının mobil ses trafik hacmi tahmin performansına etkisi	121
Şekil 4.47. Mobil ses trafik hacmi tahmin modellerinin karşılaştırılması	122
Şekil 4.48. Tüm hata metrikleri için en iyi sonucun elde edildiği hiper parametrelerle üretilen mobil ses trafik hacmi tahminlerinin karşılaştırılması	123

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

km

%

Açıklamalar

Kilometre

Yüzde

Kısaltmalar

3D CNN

3G

4.5G

5G

ACF

ADF

AGCN

AIC

AR-GE

ARIMA

ARMA

BIC

BiLSTM

BPNN

BTK

CNN

Conv3D

ConvGRU

ConvLSTM

DES

DirAcc

DMFS

Açıklamalar

Üç boyutlu evrişimli sinir ağı

3. nesil mobil şebeke hizmeti

Geliştirilmiş 4. nesil mobil şebeke hizmeti

5. nesil mobil şebeke hizmeti

Otokorelasyon

Augmented Dickey-Fuller

Uyarlanabilir grafik evrimsel ağ

Akaike bilgi kriteri

Araştırma ve geliştirme

Birleştirilmiş otoregresif hareketli ortalama

Otoregresif hareketli ortalama

Bayes bilgi kriteri

Çift yönlü uzun kısa süreli bellek

Geri yayılım yapay sinir ağı

Bilgi Teknolojileri ve İletişim Kurumu

Evrişimli sinir ağı

3D konvolüsyonel sinir ağı

Konvolüsyonel kapı yinelemeli birimler

Çok modlu evrimsel uzun-kısa süreli bellek

Çift üstel düzeltme

Yönsel doğruluk

Çift modüler özellik paylaşım katmanı

Kısaltmalar**Açıklamalar**

DP	Doğrusal tahmin
EMA	Üstel hareketli ortalama
ES	Üstel düzeltme
FNN	İleri beslemeli yapay sinir ağı
GA	Genetik algoritma
GASTN	Uzamsal-zamansal grafik dikkat ağı
Graph WaveNet	Grafik WaveNet
GRNN	Genel regresyon sinir ağı
HA	Tarihsel ortalama
HGCN	Hiyerarşik grafik sinir ağı
HSeq2Seq	Hiyerarşik sıradan sıraya
H-TÜFE	Haberleşme sektörü tüketici fiyat endeksi
KNN	K-En yakın komşu algoritması
LM	Levenberg-Marquardt algoritması
LP	Doğrusal model
LSTM	Uzun kısa süreli bellek
LT	Doğrusal trend modeli
LV	Son değer
MA	Ortalama doğruluk
MAD	Ortalama mutlak hata sapması
MAE	Ortalama mutlak hata
MAPE	Ortalama mutlak yüzde hata
MF	Çoklu görev öğrenme katmanı
MLP	Çok katmanlı algılayıcı
MLPWD	Ağırlık azalmalı çok katmanlı algılayıcı
MMS	Çoklu ortam mesaj hizmeti
MoU	Kullanım dakikası (Minutes of Use)
MSD	Ortalama kare sapma
MSE	Ortalama kare hata
n to n	Çoklu giriş – çoklu çıkış
NRMSE	Normalize edilmiş ortalama kare hatanın karekökü
PACF	Kısmi otokorelasyon

Kısaltmalar**Açıklamalar**

RE	Göreceli hata
ReLU	Düzeltilmiş doğrusal birim
RF	Rastgele orman
RFE	Yinelemeli özellik eleme
RFR	Rastgele orman regresörü
RMSE	Ortalama kare hatanın karekökü
RNN	Yinelemeli sinir ağı
RW	Rastgele yürüyüş
SA	Benzetilmiş tavlama
Seq2Seq	Sıradan sıraya
SES	Basit üstel düzeltme
SIM	Abone kimlik modülü
SMA	Basit hareketli ortalama
SMS	Kısa mesaj hizmeti
STAGCN	Uzamsal-zamansal toplama grafiği evrişimsel ağ
STCnet	Uzamsal-zamansal çapraz alanlı sinir ağı
STDenseNet	Standartlaştırılmış yoğun bağlantılı evrişimli ağ
STGCN	Uzamsal-zamansal grafik evrişimsel ağ
SVM	Destek vektör makinesi
SVMR	Destek vektör makinesi regresyonu
SVR	Destek vektör regresyonu
SVRGA	Genetik algoritma ile optimize edilmiş SVR
Tanh	Hiperbolik tanjant
TÜİK	Türkiye İstatistik Kurumu
WMA	Ağırlıklı hareketli ortalama
YSA	Yapay sinir ağı

1. GİRİŞ

Günümüzde, teknoloji ve bilgisayar kullanımının yaygınlaşması sebebi ile oldukça fazla veri üretimi gerçekleşmektedir. Oluşan bu verilerin belirli yöntemler aracılığı ile değerlendirilerek geleceğe yönelik tahminlerin yapılması, işletmelerin karar destek süreçleri için önemli fırsatlar sunmaktadır. Gelecekteki eğilimlerin öngörülebilmesi; işletmelerin stratejik planlarında, kaynak yönetiminde ve rekabet gücünün korunmasında kritik bir role sahiptir. Bu nedenle, tahminleme yöntemleri günümüzde birçok sektördeki karar alma süreçlerinin temel bileşeni hâline gelmiştir.

Bu bakımdan, elektronik haberleşme sektöründe de diğer sektörlerde olduğu gibi oldukça fazla veri üretimi mevcuttur. Son yıllarda 3G, 4G ve üzeri teknolojiler ile akıllı telefonların yaygın olarak kullanımı sonucunda elektronik haberleşme sektöründe hızlı bir büyüme yaşanmıştır. 2025 yılı Haziran Ayı verilerine göre mobil abone sayısı yaklaşık 96,5 milyon, mobil abonelerin nüfusa göre yaygınlık oranı %112,6, genişbant internet abone sayısı ise 97,4 milyon olmuştur [1]. Bu hızlı gelişim nedeniyle, sektör hem teknik hem de yönetsel açıdan daha karmaşık bir yapıya dönüşmektedir. Bu doğrultuda, gelecekteki talep değişimlerinin, hizmet yoğunluğunun ve kullanıcı davranışlarının doğru şekilde öngörülmesi; altyapı yatırımlarının planlanması ve hizmet sürekliliğinin sağlanması açısından önemli bir durumdur. Nitekim günümüzde yoğun miktarda iletişim araçlarından yararlanılması nedeni ile elektronik haberleşme sektöründeki hizmetlerin kesintiye uğramaması ve 24 saat sürekli ve aksama olmadan hizmet verilmesi söz konusu sektör için önemli bir gerekliliktir.

Ayrıca, sektörde faaliyet gösteren işletmecilerin müşteri kaybını engellemesi ve yeni müşteri kazanımını sağlaması temelde altyapısında herhangi bir aksaklık olmadan çalışmasına bağlıdır. Hizmette yaşanan bir kesinti müşteri ve gelir kaybına neden olmaktadır [2].

Elektronik haberleşme sektöründe faaliyet gösteren işletmeciler hem kullanıcı memnuniyetini sağlamak hem de işletme kârını korumak amacıyla bant genişliğini ve müşteri hizmet düzeylerini etkin bir seviyede tutmak istemektedir. Kullanıcıların faaliyet düzeylerini bilmek yönetim stratejilerinin oluşturulmasına ve operasyonel riskleri azaltmaya yardımcı olmaktadır [3]. Tüm bu sebeplerden ötürü, ağ performansı, talep yoğunluğu, veri trafiği, müşteri davranışları gibi çeşitli değişkenlerin doğru bir şekilde tahmin edilmesi, hem

hizmet kalitesinin korunmasına olanak tanımakta hem de kaynak yönetiminin daha planlı gerçekleştirilmesini sağlayarak elektronik haberleşme sektörü altyapısının müşterilerin ihtiyaçlarına cevap verebilecek en etkin düzeyde kurulmasına neden olmaktadır. Bu bakımdan bu tahminler, sektörde faaliyet gösteren işletmeciler için geleceğe yönelik planlamalarda kilit rol üstlenmektedir.

Literatür incelendiğinde, internet trafik hacmi tahmininin, ses trafik hacmi ile kısa mesaj hizmeti (SMS) ve çoklu ortam mesaj hizmeti (MMS) miktarlarının tahminlerine kıyasla daha yaygın olarak ele alındığı görülmektedir. Ayrıca, mevcut çalışmalarda genellikle eğitim-test oranının sabit tutulduğu, çalışmalarda özellik seçimi metodolojisi kullanımının daha sınırlı olduğu ve model performanslarının karşılaştırılmasında istatistiksel anlamlılık testlerinden yeterince faydalanılmadığı da dikkat çekmektedir. Bu çalışmada ise bu sebeplere istinaden, söz konusu elektronik haberleşme sektörü göstergelerinden Türkiye'deki mobil ve genişbant internet abone sayıları, gönderilen SMS ve MMS miktarları ile mobil ses trafik hacminin yapay sinir ağı (YSA) kullanarak tahmin edilmesi ve çeşitli geleneksel yöntemlerle kıyaslamaların yapılması hedeflenmiştir. Bu doğrultuda, bu çalışma ile literatüre;

- Daha sınırlı sayıda çalışma bulunan alanlara odaklanması,
- Yapay sinir ağı modelinin, geleneksel yöntemlerle karşılaştırılması,
- Model performanslarının karşılaştırılmasında istatistiksel anlamlılık testlerinden yararlanılması,
- Eğitim-test oranları için çeşitli denemelerin yapılması,
- Hem ham hem de birinci dereceden fark alınmış veri kümesi ile özellik seçiminin gerçekleştirilmesi,
- Özellik seçiminin model performansı üzerindeki etkisinin gözlemlenmesi gibi çeşitli konularda katkı sunulması hedeflenmiştir.

Ancak her çalışmada olduğu gibi bu çalışmanın da birtakım sınırlılıkları bulunmaktadır. Bu sınırlılıklar arasında, çalışmanın nispeten az sayıda veri kullanılarak yapılması ve kullanılan bazı verilerin yıllık olarak yayımlanması gösterilebilir.

Çalışmanın devamında, ilk olarak elektronik haberleşme sektörü göstergelerinin tahminine yönelik yapılmış olan çalışmalar incelenecek, ardından tahmin yöntemlerinin kavramsal çerçevesi açıklanacaktır. Uygulama bölümünde, çalışma kapsamında ele alınan

göstergelerin tahmin sürecine yönelik yöntem ve analiz adımları ayrıntılı biçimde sunulacak, son bölümde ise elde edilen bulgular değerlendirilerek sonuç ve öneriler ortaya konacaktır. Ayrıca, çalışma kapsamında tahmini yapılan göstergelerin tanım ve içerik bilgilerine de çalışmanın uygulama bölümünde yer verilecektir.





2. GEÇMİŞ ÇALIŞMALAR

Elektronik haberleşme sektörüne yönelik tahmin çalışmaları özellikle son 10 yıl odağında incelenmiş ve bulgular üç farklı kategoriye ayrılarak çizelgeler hâlinde özetlenmiştir. Çizelgelerdeki hata metrikleri ve yöntemler, çizelge içlerinin daha etkin kullanılabilmesi adına kısaltmaları ile verilmiştir. Söz konusu kısaltmalara, çalışmanın “Simgeler ve Kısaltmalar” bölümünden ulaşılabilir. Buna göre, ilk kategori kapsamında ele alınan internet trafik hacminin tahminine yönelik yapılan çalışmaların özet bilgilerine Çizelge 2.1’de yer verilmiştir.

Çizelge 2.1. İnternet trafik hacminin tahminine yönelik yapılan çalışmalar

Yazar, tarih	Tahmin edilen değişken	Veri kümesi			Hata metrikleri	Yöntemler	En iyi yöntem
		Tarih aralığı	Adet ve özellik bilgisi	Veri bölünmesi			
[4], (2017)	Mobil internet trafik hacmi	11.2013-12.2013	Mobil internet trafiği kayıtları (* ¹)	0,90:0,10 (oran)	MAE, RMSE, MAPE, MA	ARIMA, LM, RNN, CNN, 3D CNN, CNN-RNN	CNN-RNN
[5], (2018)	Mobil internet trafik hacmi	1.08.2014-31.08.2014	10’ar dakikalık trafik verisi ve 52 adet kategorik sınıf verisi (*)	9585:15 (baz istasyonu sayısı)	NRMSE	ARIMA, SVR, RNN, DeepTP	DeepTP (LSTM)
[6], (2018)	Mobil internet trafik hacmi	01.11.2013-01.01.2014	10’ar dakikalık trafik kayıtları (*)	40:10 (gün)	RMSE	RFR	Öznitelik seçimine sahip yöntem
[7], (2020)	Mobil internet trafik hacmi	20.08.2012-26.08.2012	Trafik hacmi, tarih, saat, baz istasyonu konumu verisi (*)	*	MAE, MAPE, RMSE, DirAcc	ARMA, LSTM (n to n tabanlı), 3D CNN	3D CNN
[8], (2021)	Mobil internet trafik hacmi	**2	Konum koordinatları verisi (*)	*	MSE, yanlış tahmin edilen kullanıcı oranı	MLP, CNN, LSTM, LP	YSA tabanlı yöntemler

¹ Net adet bilgisinin bulunmadığı durumlar için “*” işareti kullanılmıştır.

² Net bilginin bulunmadığı durumlar için “**” işareti kullanılmıştır.

Çizelge 2.1. (devam) İnternet trafik hacminin tahminine yönelik yapılan çalışmalar

[9], (2022)	Mobil internet trafik hacmi	Deney 1: 07.06.2005-28.07.2005; Deney 2: 15.06.2021-15.07.2021	5 dakika periyotlu; Deney 1: internet trafik hacmi verisi, Deney 2: ortalama gelen ve giden trafik hacmi ile kullanıcı sayısı verisi (*)	0,80:0,20 (oran)	MAE, MAPE, MSE, RMSE, R ²	YSA, LSTM, ARIMA, SMA	YSA ve LSTM
[10], (2024)	5G hücresel şebekesinde veri aktarım hızı	**	35 alt veri seti (*)	**	MSE, R ²	LSTM, BiLSTM, YSA, RF	LSTM, BiLSTM
[11], (2024)	Mobil internet trafik hacmi	23.12.2019-05.01 2020	Günlük 288 adet mobil internet trafik hacmi verisi (*)	0,70:0,15:0,15 (oran)	MAE, RMSE	HA, SVR, FNN, STGCN, GraphWave Net HGCN, HSeq2Seq	HSeq2Seq
[12], (2024)	Uydu iletişimde internet trafik talebi	**	5555 adet, 5 dakikalık, 14 günlük trafik ölçüm verisi	0,90:0,10 (oran)	MAE, MSE	Seq2Seq-LSTM, DP	Seq2Seq-LSTM

Söz konusu çalışmalardan [4]'te yapılan tahmin çalışmasında hedef değişken minimum, maksimum ve ortalama olmak üzere üç farklı şekilde belirlenmiştir. Tahmin işlemi üç değişkenin ayrı ayrı ele alındığı tekli görev ve üç değişkenin aynı anda tahmin edildiği çoklu görev olarak iki farklı şekilde gerçekleştirilmiştir. Farklı hiper parametre denemelerine yer verilen çalışmada eğitim-test oranı ise sabit bir değer olarak alınmıştır. Yöntem karşılaştırmalarının hata metrikleri yardımıyla yapıldığı çalışmanın sonucunda çoklu görev yaklaşımı tekli göreve göre daha başarılı bulunmuştur.

[5]'te yapılan tahmin çalışması iki aşamalı olarak tasarlanmıştır. İlk aşamada; birleştirilmiş otoregresif hareketli ortalama (ARIMA), destek vektör regresyonu (SVR), yinelemeli sinir ağı (RNN) ve DeepTP yöntemleri kıyaslanmış, ikinci aşamada ise; DeepTP'nin uzun kısa süreli bellek (LSTM), kapı yinelemeli birim (GRU), RNN gibi farklı hücre tipleri ile katman derinlikleri incelenmiştir. Çalışmanın ilk aşamasında ayrıca, DeepTP'de öznitelik seçimi, modelin içinde yer almakta olan Uzamsal korelasyon seçici (pozitif/negatif) ile otomatik olarak yapılmıştır. Yöntem karşılaştırmalarında istatistiksel anlamlılık testlerinden yararlanılmamış, eğitim-test oranı da sabit olarak ele alınmıştır. Çalışmanın sonucunda DeepTP yönteminde kullanılan tek katmanlı LSTM hücre yapısı ile en iyi sonuç elde edilmiş ve dolayısıyla oluşturulan modelin katman derinliğindeki değişimlere karşı duyarsız olduğu

belirtilmiştir.

[6]'da yapılan tahmin çalışmasında öznitelik seçimi kapsamında önemlilik skorları Gini kazancı ile hesaplanmış ve bu sayede en önemli baz istasyonları belirlenmiştir. Deneylerde, eğitim-test oranı sabit tutulmuş; ancak farklı sayıda baz istasyonunun kullanılması ve eksik verilerin iki ayrı yöntemle (sıfır atama veya bir önceki zaman dilimindeki değerle) doldurulması farklı veri kümelerinin oluşmasına neden olmuştur. Öznitelik seçimiyle oluşturulan ve rastgele seçilen veri kümeleri kullanılarak modeller kıyaslanmış, öznitelik seçimiyle elde edilen model daha iyi sonuç vermiştir.

[7]'de yapılan tahmin çalışmasında model yapıları için sabit hiper parametreler kullanılmıştır. Deneyler yoğun ve seyrek bölge olmak üzere iki farklı senaryo için gerçekleştirilmiştir. Çalışmada özellik seçimi yapılmamasının yanı sıra istatistiksel anlamlılık testi de uygulanmamıştır. En iyi sonuç önerilen zamansal ve mekânsal ilişkileri yakaladığı için üç boyutlu evrişimli sinir ağı (3D CNN) ile elde edilmiştir.

[8]'de yapılan tahmin çalışmasında bireysel ve grup kullanıcısı olmak üzere iki ayrı senaryo için internet trafik hacmi hedef değişken olarak ele alınmıştır. Çalışmada yapay sinir ağı tabanlı yöntemler için gizli katman ve gizli katmanlardaki nöron sayısı gibi bazı hiper parametrelerin farklı değerleri kafes arama yöntemi kullanılarak denenmiştir. Eğitim-test oranı sabit tutulmuş, ancak gözlem penceresinin değiştirilmesi nedeni ile veri kümesinin farklı alternatifleri oluşturulmuştur. Ayrıca çalışmada, istatistiksel anlamlılık testi uygulanmamıştır. Çalışma sonucunda, YSA tabanlı modellerin doğrusal tahminleyiciye göre daha başarılı performans gösterdiği ortaya konmuştur.

[9]'da yapılan çalışmada iki farklı kaynaktan, iki farklı dönemi kapsayan veri kümesi kullanılmış ve iki ayrı tahmin işlemi gerçekleştirilmiştir. İlk veri kümesiyle toplam internet trafik hacmi, ikinci veri kümesiyle ortalama gelen ve giden ayrımında internet trafik hacmi tahmin edilmiştir. Farklı hiper parametre denemeleri yapılmayan çalışmada eğitim-test oranı da sabit tutulmuştur. Ayrıca çalışmada, özellik seçimine yer verilmemesinin yanı sıra sonuçların karşılaştırılmasında istatistiksel anlamlılık testleri de kullanılmamıştır. Çalışma sonucunda, YSA ve LSTM'nin istatistiksel yöntemlere kıyasla daha başarılı olduğu, YSA'nın da tahmin süresi açısından LSTM'den daha uygun bulunduğu belirtilmiştir.

[10]'da yapılan çalışmada 5. Nesil (5G) hücresel şebekelerde veri aktarım hızı çeşitli yöntemler kullanılarak tahmin edilmiştir. YSA ve türevleri için katman, epok sayısı, aktivasyon fonksiyonu, yığın boyutu gibi hiper parametrelerin alternatif değerleri denenmiş, Rastgele Orman (RF) yönteminde ise farklı denemeler gerçekleştirilmemiştir. Öznitelik seçimi için Spearman korelasyon analizine başvurulmuş çalışmada, eğitim-test oranına yönelik net bilgi verilmemiştir. Ayrıca, yöntemlerin karşılaştırmaları hata metrikleri kullanılarak yapılmış, istatistiksel anlamlılık testleri kullanılmamıştır. Çalışmasının sonucunda ise, çift yönlü uzun kısa süreli bellek (BiLSTM) ve LSTM modelleri YSA ve RF modellerine kıyasla daha başarılı bulunmuştur.

[11]'de yapılan tahmin çalışmasında iki farklı bölgeden elde edilen iki farklı veri kümesi kullanılmıştır. Çalışmanın ilk aşamasında kurulan tüm modeller performans metrikleri yardımıyla karşılaştırılmış, ikinci aşamasında ise önerilen hiyerarşik sıradan sıraya (Hseq2Seq) yöntemi için farklı tahmin ufukları ile Chebyshev polinomu terim sayısı, katman boyutu gibi parametrelerin farklı değerleri denenmiştir. Ayrıca çalışmada, veri kümesi farklı gruplama şemalarıyla modellenerek grafik yapısının kaç bölgeye bölünmesi gerektiği incelenmiş, bu değerler iki veri kümesi için sırasıyla 20 ve 10 olarak belirlenmiştir. Eğitim, doğrulama ve test oranının sabit tutulduğu çalışmada, sonuçların karşılaştırılmasında istatistiksel anlamlılık testlerinden yararlanılmamıştır. Çalışmanın sonucunda, Hseq2Seq yöntemiyle en iyi sonuç elde edilmiş, uzamsal ve zamansal bağımlılıklarının birlikte modellenmesinin tahmin başarısı için önemli olduğu değerlendirilmiştir.

[12]'de yapılan tahmin çalışmasında ise katman sayısı, gizli birim sayısı, öğrenme oranı gibi bazı hiper parametreler için alternatif değerler denenmiştir. Çalışmada, eğitim-test oranı sabit tutulmuş, öznitelik seçimi uygulanmamış ve sonuçların karşılaştırılmasında istatistiksel anlamlılık testlerine yer verilmemiştir. Çalışma sonucunda, önerilen LSTM-sıradan sıraya (LSTM-Seq2Seq) modelinin en başarılı sonuçları ürettiği görülmüştür.

İkinci kategori kapsamında ele alınan SMS miktarı ve ses trafik hacminin tahinine ilişkin gerçekleştirilen çalışmaların özet bilgilerine Çizelge 2.2'de yer verilmiştir.

Çizelge 2.2. Ses trafiği ve SMS miktarı tahminine ilişkin yapılan çalışmalar

Yazar, tarih	Tahmin edilen değişken	Veri kümesi			Hata metrikleri	Yöntemler	En iyi yöntem
		Tarih aralığı	Adet ve özellik bilgisi	Veri bölünmesi			
[13], (2019)	3G mobil şebekesinde ses ve veri trafiği	10.10.2014-13.08.2015	312 günlük ses ve veri trafiği verisi (*)	Eğitim: farklı senaryolar Test:120 gün	RMSE, MAPE	RW, LT, ES, ARIMA, Theta	ES
[14], (2020)	Mobil ses trafiği	22-27.02.2017	90 000 adet ses trafiği verisi	120:24 (saat)	MSE, MAE	Mevsimsel ARMA	ARMA $(0, 4) \times (1, 0)_{24}$
[15], (2024)	SMS, sesli arama ve internet hacmi	01.11.2013-01.01.2014	10 dakikalık periyotlu; SMS, sesli arama ve internet kayıtlarına ilişkin veri (*)	**	R^2 , RMSE, MAE	LV, HA, STDenseNet, STCnet, GASTN, STAGCN, Dmfs-Mf, Conv 3D, ConvLSTM ConvGRU, ConvLSTM-AGCN	ConvLSTM-AGCN

Söz konusu çalışmalardan [13]'te yapılan tahmin çalışmasında hem üstel düzeltme hem de ARIMA yöntemi için farklı parametre kombinasyonları kullanılarak çeşitli senaryolar test edilmiştir. Çalışmada, eğitim veri kümesi ardışık olarak bir gözlem eklenerek genişletilmiş ancak test veri kümesi sabit olarak ele alınmıştır. Çalışma sonucunda, veri trafiği için eklemeli zayıflatılmış trend ve eklemeli mevsimsellik, ses trafiği için ise zayıflatılmış trend ve çarpımsal mevsimsellik içeren üstel düzeltme modelleri en iyi sonucu vermiştir.

[14]'te yapılan tahmin çalışmasında mevsimsel otoregresif hareketli ortalama (ARMA) tek yöntem olarak tercih edilmiş ve modeldeki p, q, P, Q hiper parametrelerinin farklı değerleri, Akaike bilgi kriteri (AIC) esas alınarak karşılaştırılmıştır. En uygun model olarak seçilen ARMA $(0, 4) \times (1, 0)_{24}$ modeli için parametre anlamlılık, birim kök ve Ljung-Box testi yapılmış, modeldeki tüm katsayıların anlamlı, modelin durağan ve tersinir, artıkların ise beyaz gürültü özellikleri taşıdığı görülmüştür. Çalışmada, eğitim-test oranına ilişkin alternatif değerler ise denenmemiştir.

[15]'te yapılan tahmin çalışmasında SMS, sesli arama ve internet hacimleri üzerine odaklanılmıştır. Çalışmada eğitim-test oranı sabit tutulmuş ancak girdi olarak kullanılan zamansal pencere uzunluğu ile periyodik değer sayısına yönelik alternatif denemeler

yapılmıştır. Öznitelik seçim yöntemleri ile istatistiksel anlamlılık testlerine çalışma kapsamında yer verilmemiş olup en iyi performans çok modlu evrimsel uzun-kısa süreli bellek (ConvLSTM) ve uyarlanabilir grafik evrimsel ağ (AGCN) hibrit modeli ile elde edilmiştir.

Üçüncü kategori kapsamında ele alınan kullanıcı sayıları ile kullanım tercihlerinin tahminine yönelik çalışmalara ise Çizelge 2.3'te yer verilmektedir.

Çizelge 2.3. Elektronik haberleşme sektöründeki kullanıcı sayısı ve kullanım tercihlerine yönelik yapılan çalışmalar

Yazar, tarih	Tahmin edilen değişken	Veri kümesi			Hata metrikleri	Yöntemler	En iyi yöntem
		Tarih aralığı	Adet ve özellik bilgisi	Veri bölünmesi			
[16], (2010)	3G mobil telefon abonelerinin sayısı	01.2006-03.2008	27 adet 3G mobil telefon abonelerinin sayısı	17:5:5 (adet)	MAPE, Mann-Whitney U testi	ARIMA, GRNN, SVRGA, SVRGA-SA	SVRGA-SA
[17], (2016)	Endonezya genişbant kullanıcı sayısı	2005-2013	9 adet, 6 özellikli veri kümesi.	**	MAPE, MAD, MSD	SES, DES, Holt-Winters	Çift üstel düzeltme
[18], (2016)	Şebekedeki aktif kullanıcı sayısı	25.01.2015-31.01.2015	168 adet, 24 özellikli veri kümesi	0,60:0,40 (oran)	MAPE, RMSE	MLP, MLPWD, SVM	Deney 1: SVM; Deney 2: MLPWD
[19], (2016)	Zambiya'daki mobil abone sayısı	2000-2014	15 adet mobil abone sayısı verisi	**	AIC, BIC, RMSE, MAPE, MAD	ARIMA	ARIMA (1,2,1)
[20], (2017)	Deney 1: Çin'deki internet kullanıcı sayısı Deney 2: Kırsal ve kentsel internet kullanıcı ilişkisi	Deney 1: 2007-2014 Deney 2: 2006-2014	Deney 1: 8 adet internet kullanıcı verisi, Deney 2: 9 adet kırsal/kentsel internet kullanıcı verisi	**	MAE, MAPE, RMSE	Deney 1: Gompertz, Lojistik, Bass ve Lotka-Volterra Deney 2: Lotka-Volterra	Lotka-Volterra
[21], (2019)	Çin'deki cep telefonu türlerinin satış potansiyelleri	**	1026 adet, 10 özellikli veri kümesi	En iyi değer: 0,10:0,90 (oran)	3 katlı çapraz doğrulama	SVMR, BPNN, KNN	SVMR
[22], (2021)	Mobil telefon kullanıcı sayısı	12.2008-08.2020	140 adet mobil telefon kullanıcı sayısı	0,70:0,30 (oran)	MSE, RE	MLP	-
[23] (2023)	Mobil telefon işletim sistemi tercihleri	**	229 Android, 168 IOS olmak üzere toplam 397 adet, 11 özellikli veri kümesi	**	Doğruluk oranı, karmaşıklık matrisi, kesinlik, duyarlılık, F1 skoru	RF	-

Buna göre ilgili çalışmalardan [16]'da yapılan tahmin çalışmasında SVR yöntemi için ceza katsayısı, hata tolerans aralığı ve Gaussian kernel genişliği gibi hiper parametre denemeleri genetik algoritma (GA) ve genetik algoritma-benzetilmiş tavlama (GA-SA) hibrit modeli; ARIMA yöntemi için ise istatistiksel yazılım kullanılarak gerçekleştirilmiştir. Genel regresyon sinir ağı (GRNN) yöntemi için ise düzleştirme parametresi özelinde alternatif denemeler yapılmıştır. Çalışmada eğitim-test oranı sabit tutulmuş ancak, eğitim veri seti özelinde kaydırmalı yaklaşım tercih edilmiştir. Çalışma sonucunda, Genetik Algoritma ve Benzetilmiş Tavlama ile Optimize Edilmiş Destek Vektör Regresyonu (SVRGA-SA) modelinin en iyi performansa sahip olduğu gözlemlenmiş, ayrıca Mann-Whitney U testi yapılarak diğer yöntemlere göre üstünlüğü istatistiksel olarak da doğrulanmıştır.

[17]'de yapılan tahmin çalışmasında, genişbant internet kullanıcı sayısı tek özellik olarak ele alınmış ve dolayısıyla öznitelik seçim yöntemlerine başvurulmamıştır. Yöntem kıyaslamaları hata metrikleri ile yapılmış, istatistiksel anlamlılık testleri kullanılmamıştır. Çalışmada en iyi sonuçlar çift üstel düzeltme yöntemi ile elde edilmiştir. Çalışmada ayrıca, korelasyon analizi yardımıyla nüfus, gayrisafi yurt içi hasıla (GSYİH), kişi başına gelir, ekonomik büyüme, enflasyon ve yaygınlık oranı gibi değişkenlerin genişbant kullanıcı sayısı ile arasındaki ilişki de incelenmiş ve nüfus, GSYİH, kişi başına gelir ile çok güçlü ve pozitif yönde; enflasyon oranı ile ise negatif yönde bir ilişkiye sahip olduğu gözlemlenmiştir.

[18]'de yapılan tahmin çalışmasında iki farklı veri kümesi ile iki farklı deney gerçekleştirilmiştir. İlk deneyde korelasyon analizi kullanılarak öznitelik seçimi yapılmış ve 27 özellik 24'e indirgenmiştir. İkinci yapılan deneyde ise tek boyutlu veri kullanılmış ve farklı kayma penceresi boyutları denenmiştir. İlk deney için destek vektör makinesi (SVM) modeli, ikinci deney için ağırlık azalmalı çok katmanlı algılayıcı (MLPWD) modelinin iyi sonuç verdiği gözlemlenmiş, dolayısıyla çalışmadan veri boyutunun model başarısında rolü olduğu ve uygun yöntem seçiminin bu bağlamda farklılık gösterebileceği ifade edilmiştir. Çalışma kapsamında kullanılan yöntemler için farklı hiper parametre ve eğitim-test oranı denemelerine başvurulmamış ve ayrıca kullanılan yöntemlerin kıyaslanmasında istatistiksel anlamlılık testlerinden yararlanılmamıştır.

[19]'da yapılan tahmin çalışmasında ARIMA, tek yöntem olarak tercih edilmiştir. ARIMA modelinin p , d , q parametrelerinin belirlenmesine yönelik farklı kombinasyonların denendiği çalışmada en iyi sonucun elde edildiği ARIMA (1,2,1) modeli ile 2015-2019 yıl aralığı

tahmin edilmiştir.

[20]'de yapılan tahmin çalışmasında tek bir özellik kullanılarak farklı yöntemler ile Çin'deki internet kullanıcı sayısının büyümesi tahmin edilmiş, ardından kırsal ve kentsel internet kullanıcılarının arasındaki ilişki Lotka-Volterra modeli ile incelenmiştir. Sonuçlara göre, kentsel internet kullanıcılarının yaygınlığı kırsal internet kullanıcılarının yaygınlığındaki değişikliklerden etkilenmekte, ancak kırsal internet kullanıcılarının yaygınlığı, kentsel internet kullanıcılarının yaygınlıklarındaki değişikliklerden etkilenmemektedir.

[21]'de yapılan tahmin çalışmasında kullanılan yöntemlerden olan destek vektör makinesi regresyon (SVMR) yöntemi için 2 aşamalı bir süreç gerçekleştirilmiştir. İlk aşamada, farklı Kernel fonksiyonları denenmiş radyal tabanlı fonksiyonun (RBF) seçilmesine karar verilmiş, ikinci aşamada ise ceza katsayısı ve Kernel genişliği için alternatif testler yapılmıştır. Çalışmada, farklı eğitim-test oranları için denemeler de gerçekleştirilmiş, ancak yöntemlerin kıyaslanmasında istatistiksel anlamlılık testlerinden yararlanılmamıştır. Çalışma sonucunda, en iyi performansa sahip model olan SVMR-RBF kullanılarak 2014-2016 yıl aralığı tahmin edilmiştir.

[22]'de yapılan tahmin çalışmasında çok katmanlı algılayıcı kullanılmış ve ilgili yöntem için hiper parametre optimizasyonu nöron, katman ve aktivasyon fonksiyonu özelinde SPSS ile otomatik olarak yapılmıştır. Geleneksel yöntemlerle karşılaştırma yapılmayan çalışmada, girdi olarak yalnızca mobil telefon aktif hat verisi kullanılmıştır. Ayrıca, modellerdeki eğitim-test oranı sabit tutularak farklı alternatifler denenmemiştir.


[23]'te yapılan tahmin çalışmasında tek bir sınıflandırma modeli özelinde işlem yapılmış, farklı yöntemler incelenmemiştir. Ayrıca çalışmada, model parametrelerinin ayarlanması ve veri kümesinin eğitim-test bölünmesine ilişkin herhangi bir optimizasyon çalışmasına yer verilmemiştir.

3. TAHMİN YÖNTEMLERİ

Tahmin yapmak, hayatımızın her anında karşılaştığımız ve sürekli olarak yaptığımız bir eylemdir. Günlük yaşantımızda birçok karar, tahminlere dayalı olarak alınır. Örneğin, hava durumu tahminine bağlı olarak giyilecek kıyafetlere, şemsiye gibi alınacak eşyalara karar verilir. Trafiğin durumuna göre, evden erken çıkılıp çıkılmaması ya da kullanılacak ulaşım türü belirlenir. Yeni tanışılan bir kişinin mesleği, konuşma tarzı ve davranışlarına bakılarak o kişinin karakteri hakkında analiz yapılabilir. Genel olarak tahmin, geçmiş veriler ve gelecekteki durumu etkileyebilecek mevcut bilgiler ışığında, gelecekteki olayların mümkün olan en iyi şekilde belirlenmeye çalışılması olarak özetlenebilir [24].

Tahminleme ise, geçmiş bilgiler ve veri kümeleri sayesinde gelecekteki durumlarla ilgili çıkarımlar yapma, tahmin modeli üretme süreci olarak ifade edilmektedir [25]. Bu süreç sayesinde belirsizliğe sahip durumlarda daha doğru kararlar alınabilmesi sağlanır. Sadece bireyler değil aynı zamanda Kurumlar ve işletmeler de stratejik planlama, kaynak yönetimi, risk analizi gibi konular için tahminlemeye ihtiyaç duymaktadır. Bu bakımdan tahminlemenin sadece bir öngörü olmadığı aynı zamanda bilimsel temellere dayalı bir sistematik analiz süreci olduğu söylenebilir.

Literatürde tahmin yöntemleri genel olarak nitel ve nicel yöntemler olmak üzere iki temel kategoriye ayrılır [26]. Nitel ve nicel tahmin yöntemleri Şekil-1’de gösterilmektedir. Nitel tahmin yöntemlerinde, yönetici görüşleri, senaryo analizi, Delphi yöntemi, anketler ve uzman panelleri bulunmaktadır. Nicel tahmin yöntemleri ise, kendi içinde zaman serileri analizi, nedensel yöntemler ve yapay zekâ temelli yöntemler olarak gruplandırılabilir (Bkz. Şekil 3.1).



Şekil 3.1. Tahmin yöntemleri

3.1. Nitel Tahmin Yöntemleri

Nitel tahmin, konu hakkında uzman kişilerin bilgi birikimi ve tecrübelerine dayanılarak yapılan öngörülerdir [26].

3.1.1. Yönetici görüşleri

Bu tür tahminler, alanında uzman kişilerin ya da üst düzey yöneticilerin görüşlerine dayanılarak gerçekleştirilmektedir [27]. Bu yöntemin tercih edilmesinin nedenleri olarak, işletmenin elinde yeterli düzeyde sayısal verinin bulunmaması veya hızlı karar alınmasının gerekli olması gösterilebilir. Özellikle acil durumlarda, verileri analiz etmek ya da formüllerle çalışmak zaman alabileceğinden, bu tür yaklaşımların kullanımı daha pratiktir. Bu yöntem, karar süreçlerini hızlandırarak işletmeye zaman ve maliyet açısından fayda sağlayabilir. Ancak, tamamen bireysel değerlendirmelere ve yorumlara dayanması, yöntemin en önemli dezavantajlarından biridir [28].

3.1.2. Senaryo analizi

Gerçek hayat, çoğu zaman öngörülemeyen değişiklikler içerir. Bu durum geçmiş verilere dayalı analizleri daha en baştan geçersiz kılabilir. Bu nedenle senaryo analizi, farklı gelecek ihtimallerini ele alarak belirsizliklere karşı yöneticilerin daha güçlü bir bakış açısına sahip olmasına yardımcı olur. Ayrıca, matematiksel formüllere dayanmadan, dikkatli bir çalışmayla kurumun ihtiyaçlarına uygun senaryolar geliştirilmesini sağlar [29].

3.1.3. Delphi tekniği

Bu teknikte, uzmanlar ya da ilgili temsilciler belirli bir konuya dair görüşlerini paylaşır. Süreç, görüşlerin değerlendirilmesi, incelenmesi ve ortak bir anlayışa ulaşılması adımlarını içerir.

Uygulama problemin net bir şekilde tanımlanmasıyla başlar. Daha sonra, panel üyelerinin seçimi gerçekleştirilir. İlk aşamada, açık uçlu sorular içeren bir anket hazırlanarak katılımcılara gönderilir. Gelen yanıtların analizi sonrasında ikinci tur anket hazırlanarak tekrar aynı katılımcılarla paylaşılır. Gerekli görülmesi durumunda üçüncü tur anket de

hazırlanabilir. Her turun sonunda elde edilen veriler değerlendirilir. Sürecin sonunda ise ortak bir görüşe ya da uzlaşmaya ulaşılması hedeflenir [30].

3.1.4. Anketler

Anketler, yeni bir ürünün piyasaya sürülürken ya da mevcut bir üründe değişiklik yapılacağı zaman hedef tüketicilerin taleplerini öngörebilmek amacıyla yapılır. Anketler sayesinde, geniş kitlelere ulaşmak ve araştırmayı daha büyük gruplar üzerinden yürütmek mümkün olur. Bu yöntem, zaman, maliyet ve çaba açısından araştırmacıya önemli avantajlar sunar. Ancak, katılımcıların soruları aynı şekilde algılaması, yanıtlarında tam olarak açık olmamaları ya da rastgele cevap vermeleri, elde edilen verilerin güvenilirliğini düşürebilir. Ayrıca, araştırmacının bu tür yanıtları doğrudan kontrol etme imkânı çoğu zaman sınırlıdır [31].

3.1.5. Uzman panelleri

Bu yöntemde, oluşturulan bir panel aracılığıyla üyelerin çoğunluğunun üzerinde uzlaştığı bir sonuca varılması amaçlanır. Delphi tekniğinden en temel farkı, panelde yer alan katılımcıların bir araya gelerek doğrudan görüş alışverişinde bulunabilmeleridir. Katılımcıların, konuya dair görüşlerini karşılıklı olarak ifade edebilmeleri ve bu sayede birbirlerinin fikirlerinden etkilenebilmelerinden dolayı bu yöntem ile daha zengin bir tartışma ortamı oluşmaktadır. Bu duruma istinaden, bu yöntem özellikle katılımcılar arasındaki etkileşimin güçlü olduğu gruplarda daha etkili şekilde uygulanır [32].

3.2. Nicel Tahmin Yöntemleri

Nicel tahmin yöntemlerinde, çeşitli matematiksel modeller kullanılarak elde edilen verilere dayalı analizler yapılmaktadır [26].

3.2.1. Zaman serileri analizi

Her veri serisi zaman serisi olarak kabul edilemez; bir serinin zaman serisi olarak sayılabilmesi için verilerin zamanla ilişkili bir yapısı olmalıdır [33].

Zaman serilerinde esas önemli nokta, serinin gelecek değerlerinin geçmiş gözlemlerden yararlanılarak öngörülebilmesidir [34]. Zaman serilerinin analizinde kullanılan birçok yöntem bulunmaktadır.

Hareketli ortalama yöntemi

Zaman serisi analizinde yaygın olarak kullanılan yöntemlerden biri hareketli ortalama yöntemidir [35]. Hareketli ortalama yöntemi, en güncel verilerin ortalamalarının alınarak geleceğe yönelik tahminlerde bulunulmasını sağlar. Yöntemde, modele yeni gerçekleşen veri eklenmekte, en eski veri ise modelden çıkarılmakta ve böylelikle sürecin sürekli güncellenmesi sağlanmaktadır [36].

Bu yöntemin farklı çeşitleri bulunsa da, temel amaçları verilen zaman serisi verisinin eğilimlerini belirlemektir. En basit hareketli ortalama türü basit hareketli ortalama (SMA) yöntemidir. SMA’da, zaman serisindeki her bir veri noktası aynı öneme sahip olup eşit ağırlıklarla değerlendirilir. Ağırlıklı hareketli ortalama (WMA) ise SMA’nın geliştirilmiş bir versiyonudur. Burada her veri noktasına belirli bir ağırlık verilir. WMA’nın bir türevi olan üstel hareketli ortalama (EMA) ise, ağırlıkların belirlenmesinde üstel sayılar kullanılır [35].

Basit üstel düzeltme

Yöntem, Brown’un basit üstel düzeltme modeli olarak da bilinmektedir [37]. Hesaplama açısından oldukça basit olmasından dolayı yaygın olarak kullanılmaktadır. Özellikle verilerin yatay seyir izlediği, belirgin bir trend veya döngüsel dalgalanma yapısına sahip olmadığı durumlarda tercih edilir [38]. Bu nedenle, yalnızca 0 ile 1 arasında değişen bir düzeltme katsayısı modelde bulunur. Düzeltme katsayısının düşük değer alması, öğrenmenin yavaş gerçekleşmesi anlamına gelir ve tahminde geçmiş veriler daha fazla dikkate alınır. 1’e yakın yüksek bir değer alması ise öğrenmenin daha hızlı olduğu anlamına gelir ve tahmin işleminde son gözlemlere daha fazla odaklanılır [39]. Üstel düzeltme yöntemleri denklemlerinde kullanılan notasyon Çizelge 3.1’de, basit üstel düzeltme yöntemine ait formül ise Eş. 3.1’de verilmektedir.

Çizelge 3.1. Üstel düzeltme yöntemlerine ait notasyon

Sembol	Açıklama
F_t	t periyodundaki tahmin değeri
D_t	t periyodundaki gerçek değer
S_t	t periyodundaki düzeltilmiş seviye değeri
G_t	t periyodundaki trend değeri
$F_{t,t+\tau}$	τ adım sonraki tahmin değeri
c_t	t periyodundaki mevsimsel bileşen
N	mevsimsel periyot sayısı
α, β ve γ	temel, trend ve mevsimsel düzeltme katsayısı ($0 < \alpha, \beta, \gamma < 1$)

$$F_{t+1} = \alpha D_t + (1 - \alpha) F_t \quad (3.1)$$

Çift üstel düzeltme yöntemi

Holt yöntemi olarak da adlandırılan çift üstel düzeltme yöntemi, durağan olmayan ve belirgin bir trend yapısına sahip olan zaman serilerinin analizinde kullanılır. Yöntemde geçmiş veriler matematiksel olarak düzeltilerek en son gözlem verisine daha yüksek, diğer gözlem verilerine ise giderek daha düşük ağırlıklar atayan bir ağırlıklandırma yaklaşımı benimsenir [40].

Bu yöntemde basit üstel düzeltme yönteminde de yer alan α parametresinin yanı sıra trenddeki değişikliklerin düzeltilmesi amacıyla β parametresi de kullanılır [41]. Buna göre, söz konusu yöntemin denklemlerine Eş. 3.2-3.4'te yer verilmektedir. Ayrıca, yöntemde kullanılan notasyon için Çizelge 3.1'e bakılabilir.

$$S_t = \alpha D_t + (1 - \alpha) (S_{t-1} + G_{t-1}) \quad (3.2)$$

$$G_t = \beta (S_t - S_{t-1}) + (1 - \beta) G_{t-1} \quad (3.3)$$

$$F_{t,t+\tau} = S_t + \tau G_t \quad (3.4)$$

Holt-Winters yöntemi

Holt-Winters yöntemi, zaman serilerinde mevsimsel değişimlerin gözlemlendiği durumlarda kullanılır [41]. Çift üstel düzeltme yöntemi parametrelerine ek olarak bu yöntemde mevsimsel değişimlerin düzeltilmesinde kullanılan γ parametresi de yer alır. Bu doğrultuda, yönteme ait denklemlere Eş. 3.5-3.8'de yer verilmektedir. Ayrıca, yöntemde kullanılan notasyona Çizelge 3.1'den ulaşılabilir.

$$S_t = \alpha (D_t/c_{t-N} + (1 - \alpha) (S_{t-1} + G_{t-1})) \quad (3.5)$$

$$G_t = \beta (S_t - S_{t-1}) + (1 - \beta) G_{t-1} \quad (3.6)$$

$$c_t = \gamma (D_t/S_t) + (1 - \gamma)c_{t-N} \quad (3.7)$$

$$F_{t,t+\tau} = (S_t + \tau G_t) c_{t+\tau-N} \quad (3.8)$$

ARIMA

ARIMA yöntemi, günümüzde özellikle zaman serisi tahminleri için en çok tercih edilen tekniklerden biridir [42]. Buna göre modelde, p , d ve q olmak üzere üç temel parametre bulunur. Bu değerlerin tespiti için en yaygın kullanılan araçlar otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafikleridir [43]. ACF grafiği, zaman serisindeki ardışık gecikmelerin arasındaki korelasyonu göstermekte olup ilgili grafik ile q parametresinin belirlenmesi gerçekleştirilir. PACF grafiği ise her bir gecikmenin seriye olan doğrudan etkisini göstermekte olup ilgili grafik ile, p parametresinin belirlenmesi gerçekleştirilir. d parametresi ise verileri durağan hâle getirmek için kaç kez fark alma işleminin gerçekleştirilmesine bağlı olarak belirlenir [44].

Ayrıca, ARIMA yöntemi durağan zaman serilerinde kullanılabilir. Bu duruma bağlı olarak model kullanılmadan önce, serinin durağan olup olmadığının incelenmesi gerekir. Serinin durağan olmadığı durumda fark alma yöntemi uygulanarak durağan hâle gelmesi sağlanmalıdır. Bu nedenle, ARIMA modelini oluşturmak için önce fark derecesi olan d değeri belirlenir. Daha sonra ise modeldeki otoregresif terim sayısı (p) ve hareketli ortalama terim sayısı (q) belirlenmesiyle süreç devam eder [43]. ARIMA yönteminde kullanılan

notasyon Çizelge 3.2’de, formül ise Eş. 3.9’da yer almaktadır.

Çizelge 3.2. ARIMA yöntemine ait notasyon

Sembol	Açıklama
y_t	t periyodundaki gerçek değer
B	geri kaydırma operatörü
δ	sabit terim
ε_t	t periyodundaki rassal hata
φ_p, θ_p	sırasıyla mevsimsellik içermeyen otoregresif ve hareketli ortalama katsayıları
d	fark alma derecesi
t	periyot sayısı ($2 \leq t \leq p$)

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d y_t = \delta + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p) \varepsilon_t \quad (3.9)$$

SARIMA yöntemi

Mevsimsel birleştirilmiş otoregresif hareketli ortalama (SARIMA) yöntemi zaman serisi verilerinin analizinde sıkça tercih edilen çarpımsal bir modeldir. Bu yöntem, p , d ve q parametreleri bulunan ARIMA yöntemine mevsimsel bileşenlerin eklenmesiyle oluşmuştur. Bu nedenle, SARIMA yöntemi mevsimsel etkilere sahip zaman serilerinin tahmininde tercih edilmektedir. Modelin yapısı hem mevsimsel hem de mevsimsel olmayan parametreleri içerir ve genellikle $(p, d, q) \times (P, D, Q)$ biçiminde ifade edilir. SARIMA yöntemine ait mevsimsellik içeren notasyon Çizelge 3.3’te, formül ise Eş. 3.10’da verilmiştir. ARIMA yöntemi ile ortak kullanılan notasyon için ayrıca Çizelge 3.2’ye bakılabilir.

Çizelge 3.3. SARIMA yöntemine ait mevsimsellik içeren notasyon

Sembol	Açıklama
ϕ_p, θ_q	sırasıyla mevsimsel otoregresif ve hareketli ortalama katsayıları
D	mevsimsel fark alma derecesi
w	mevsimsel periyot sayısı

$$\begin{aligned}
& (1 - \phi_1 B^w - \phi_2 B^{2w} - \dots \\
& \quad - \phi_p B^{pw}) \times (1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) \\
& \quad \times (1 - B^w)^D (1 - B)^d y_t \\
& = \delta + (1 - \Theta_1 B^w - \Theta_2 B^{2w} - \dots \\
& \quad - \Theta_q B^{qw}) \times (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t
\end{aligned} \tag{3.10}$$

3.2.2. Nedensel yöntemler

Nedensel tahmin yöntemleri ile, tahmin edilmek istenen değişken (bağımlı değişken) ve bu değişkeni etkileyen diğer faktörler (bağımsız ya da açıklayıcı değişkenler) arasındaki ilişkiler incelenir. Bu istatistiksel yöntemler, değişkenler arasındaki ilişkinin gücünü sayısal olarak değerlendirerek bu ilişkilerin rastlantısal mı yoksa anlamlı mı olduğunu istatistiksel testler yardımıyla belirlemeye çalışır [45].

Regresyon analizi

İstatistiksel analizlerde iki değişken arasında bir ilişki olup olmadığı ile varsa bu ilişkinin ne derecede olduğunun belirlenmesi yaygın olarak karşılaşılan bir durumdur. Bu durumlarda, değişkenler arasındaki ilişkinin incelenmesinde regresyon tekniği oldukça fazla kullanılır. Değişken sayısına göre regresyon analizi basit ve çoklu olmak üzere 2'ye ayrılmaktadır [46].

Basit Regresyon

Basit doğrusal regresyon analizi, bağımlı değişken olan Y ile yalnızca bir tane bağımsız değişken olan X arasındaki ilişkinin doğrusal bir denklemle açıklanmasını temel alır [46].

Modeldeki bağımlı değişkenin sürekli değer aldığı, bağımsız değişkenlerin ise sürekli veya kesikli değer aldığı modelleme tekniğinde regresyon doğrusu doğrusaldır. Bu yöntemle ilişkin formül Eş. 3.11'de yer almaktadır.

$$Y = a + b X + e \tag{3.11}$$

Eş. 3.11'de; e hata terimini, b doğrunun eğimini ve a kesişim noktasını ifade etmektedir [47].

Çoklu regresyon

Bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkiyi incelemek için kullanılır [48]. Çoklu regresyon metoduna ait notasyon Çizelge 3.4’te, formül ise Eş. 3.12’de verilmiştir.

Çizelge 3.4. Çoklu regresyon metoduna ait notasyon

Sembol	Açıklama
Y	bağımlı değişken
a	sabit değer
n	toplam bağımsız değişken sayısı
e	hata
b_i	i . bağımsız değişkenin regresyon katsayısı
X_i	i . bağımsız değişken

$$Y = a + \sum_{i=1}^n b_i X_i + e \quad (3.12)$$

Korelasyon analizi

Korelasyon analizi, iki veya daha fazla değişken arasındaki ilişkinin yönünü ve gücünü ölçmek amacıyla kullanılan istatistiksel bir yöntemdir. Literatürde farklı türlerde korelasyon analizi kullanılmaktadır. Bunlardan basit korelasyon katsayısı, istatistikte en temel ilişki türlerinden biri olarak düşünülebilir. Bu analiz türü, X ve Y gibi iki rastgele değişken arasındaki doğrusal ilişkinin yönünü ve gücünü betimlemek için kullanılır. Daha kapsamlı ve karmaşık bir yapıya sahip kanonik korelasyon analizi ise, çok değişkenli bir ana kütleden iki değişken veri setinin çekilerek bu veri setleri arasındaki ilişkinin belirlenmesinde kullanılır [49].

3.2.3. Yapay zekâ temelli yöntemler

Yapay zekâ temelli tahmin yöntemleri, geleneksel istatistiksel yöntemlerin de ötesine geçerek büyük hacimli, karmaşık ve yapısal olmayan veri kümelerinden anlamlı öngörüler üretebilen güçlü yöntemlerdir. Bu tahmin yöntemleri içerisinde, makine öğrenmesi ve derin öğrenme yöntemlerini barındırır.

Makine öğrenmesi yöntemleri

Bağımsız değişkenler ve bağımlı değişkenler arasında bulunan karmaşık ilişkilerin modellenmesinde tercih edilen bu yöntemler verilerden öğrenerek tahmin etme işlemini gerçekleştirir.

Destek vektör makinesi

Destek vektör makineleri istatistiksel öğrenme teorisinde kullanılır. Bu yöntemin temelinde, doğrusal olmayan veri kümelerinin daha yüksek boyutlu bir özellik uzayına dönüştürülmesi yer alır. Bu dönüşüm, çekirdek matrisler kullanılarak gerçekleştirilir. Çekirdek matris ise, matris çarpımında kullanılarak çoğunlukla matris bilgilerinin özetlenmesini veya işlenmesini sağlar [50].

K-en yakın komşu

K-en yakın komşu (K-NN) yöntemi sınıflandırma problemlerinde tercih edilen bir algoritmadır [51]. K-NN algoritması, bir veri noktasının en yakın komşularını bulmak için Öklid mesafesi, Mahalanobis mesafesi ya da başka uygun mesafe ölçütlerini kullanır [52].

Lojistik regresyon

Lojistik regresyon tekniğinden, bağımlı değişkenin 0/ 1, Doğru/ Yanlış, Evet/ Hayır gibi ikili bir yapıya sahip olması hâlinde faydalanılmaktadır. Y'nin değeri 0 ile 1 arasında değiştiği Lojistik Regresyon denklemlerine Eş. 3.13-3.16'da yer verilmektedir.

$$Odds = \frac{p}{(1-p)} \quad (3.13)$$

$$\ln(odds) = \ln\left(\frac{p}{(1-p)}\right) \quad (3.14)$$

$$logit(p) = \ln\left(\frac{p}{(1-p)}\right) = a + \sum_{i=1}^n b_i X_i \quad (3.15)$$

$$p = \frac{e^{(a+b_1X_1+\dots+b_iX_i)}}{1 + e^{(a+b_1X_1+\dots+b_iX_i)}} \quad (3.16)$$

Eşitliklerde, p ilgilenilen durumun var olma olasılığını, logit fonksiyonu ise binom dağılımı ya da bağımlı değişkenin seçilmesi için faydalanılabilecek bir ilişki kurma fonksiyonunu ifade etmektedir [47].

Naive Bayes yöntemi

İstatistiksel temellere dayanan Naive Bayes algoritması ile daha önce sınıf etiketleri belirlenmiş verilerden yola çıkılarak, yeni gelen bir verinin hangi sınıfa ait olabileceği bulunmaya çalışılır. Özellikle ikili sınıflandırma problemlerinde etkili sonuçlar veren bu yöntem gerçek zamanlı uygulamalarda da sıkça tercih edilmektedir [53].

Rastgele Orman

Rastgele ormanlar regresyon, sınıflandırma ve diğer problemlerde yaygın olarak kullanılan bir algoritmadır. Birden fazla karar ağacının bir araya getirilmesiyle çalışması tek bir karar ağacının yaşayabileceği aşırı öğrenme sorununun azaltılmasına yardımcı olur. Yöntem, rastgele seçilen özellik kümesi ile eğitim örneklerinden bir orman oluşturur. Böylece, her karar ağacı, eğitim sürecinde farklı veri alt kümeleri ve özellik setleriyle çalıştığı için modelin öğrenme biçimi çeşitlenmiş olur [54].

Yapay sinir ağıları

Yapay sinir ağıları, sosyal, ekonomik, mühendislik alanlarıyla birlikte döviz ve hisse senedi gibi finansal konularda yapılan tahminlerde sıkça tercih edilen, etkili tahmin modellerindendir. Bu yöntem ile kendisine sunulan girdi verilerine karşılık uygun çıktıların üretilmesi sağlanır. Bu yeteneği kazanabilmesi için öncelikle ağı çeşitli örneklerle eğitilmesi gerekir. Eğitim süreci sonunda ağ, genelleme yapabilme ve karar verebilme kabiliyeti kazanır. Daha sonra ise, öğrendiklerini uygulayarak yeni verilere uygun çıktılar üretir [55].

Beynin işleyişinin yapay olarak yansıtılmasıyla geliştirilen YSA'lar nöronların farklı şekillerde birbirine bağlanmasıyla oluşmuş yapılardır [56-57]. İnsanda öğrenme süreci nöronlar arasındaki sinaptik bağlar ile gerçekleşir. Nöronlar çevrelerinden gelen uyarıları dentritleri aracılığıyla alır. Bu uyarılar harekete geçirici ya da engelleyici olabilir. Gelen uyarılar nöron gövdesinde toplanır ve bir eşik seviyesini aştığında nörondan diğer nöronlara akson yardımıyla bir yanıt iletilir. Bu biyolojik mekanizma yapay nöronun işleyişi için bir model oluşturmuştur [56].

Buna göre YSA'da da, her bir nöron veya işlem birimi kendisine gelen girdileri toplar ve bu toplam belirli bir eşik değeri aştığında bir çıktı üretir. Nöronların 5 adet elemanı bulunur. Bunlar; girdi, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır. Girdiler yapay sinir hücresine dış ortamdan iletilen bilgilerdir. Bu bilgiler sadece dış dünyadan değil aynı zamanda diğer nöronlardan ya da nöronun kendisinden de gelebilir. Ağırlık değerleri ise, nörona girdi olarak sunulan bilgilerin önemini ve nöron üzerindeki etkisini gösterir. Toplama fonksiyonu, nörona gelen net girdiyi hesaplar. Toplama fonksiyonu için farklı fonksiyonlar kullanılabilir ancak yaygın olanı girdi değerlerinin kendi ağırlıklarıyla toplamı olarak açıklanabilen ağırlıklı toplamdır.

Aktivasyon fonksiyonu ise, toplama fonksiyonu ile elde edilen net girdiyi işleme tabi tutarak bu işlem sonucunda nöronun çıktısını oluşturur [58]. Nöronların çıktısını belirleyen bu fonksiyon, ağı başarımı üzerinde doğrudan bir etkiye sahiptir. Bu bakımdan, sinir ağı modellerinde kullanılacak olan aktivasyon fonksiyonunun seçimi çok önemli bir konudur. Çok katmanlı ileri beslemeli bir ağda birden fazla aktivasyon fonksiyonu da birlikte kullanılabilir. Literatür çalışmalarındaki YSA uygulamalarında farklı aktivasyon

fonksiyonlarından yararlanılmaktadır. En yaygın kullanıma sahip aktivasyon fonksiyonu düzeltilmiş doğrusal birimdir (ReLU) [59]. Formülasyonu Eş. 3.17’de verilen ReLU aktivasyon fonksiyonunun, giriş değeri 0’dan küçük veya 0’a eşit olduğunda çıktısı 0 olurken, 0’dan büyük değerlerde ise giriş değeri doğrudan çıktısı olur. Giriş değeri 0’dan küçük veya 0’a eşit olduğu durumlarda sonucun 0 olarak alınması, ağıın daha hızlı çalışmasını sağlar. Ayrıca, sigmoid ve hiperbolik tanjant (tanh) fonksiyonlarına kıyasla daha düşük hesaplama yüküne sahip olması, bu fonksiyonun çok katmanlı sinir ağlarında daha fazla tercih edilmesine neden olmaktadır [60].

$$f(x) = \max(0, x) \quad (3.17)$$

Bununla birlikte, literatürde tanh, sigmoid gibi doğrusal olmayan aktivasyon fonksiyonları da popülerdir [59]. Sigmoid aktivasyon fonksiyonu, sürekli ve türevlenebilir yapısıyla özellikle sınıflandırma problemlerinde yaygın olarak tercih edilen doğrusal olmayan bir aktivasyon fonksiyonudur. Girdi değerlerine bağlı olarak 0-1 aralığında sonuç üreten bu fonksiyon, Eş. 3.18’de verilen formül ile tanımlanmaktadır. Ancak, sigmoid aktivasyon fonksiyonunun bir dezavantajı da bulunmaktadır. X ’teki değişimlere $f(x)$ değerleri çok az reaksiyon göstermektedir. Bu durumda türev değerleri oldukça küçülerek 0’a yakınsar. Türevin neredeyse 0’a yaklaşması da öğrenmenin durmasına neden olmaktadır [60].

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.18)$$

Tanh aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonuna benzer bir yapıya sahip olsa da, çıktı aralığı açısından farklılık gösterir. Sigmoid aktivasyon fonksiyonunun çıktıları 0 ile 1 arasında değişirken tanh aktivasyon fonksiyonunun çıktıları -1 ile 1 aralığında yer alır. Tanh aktivasyon fonksiyonu Eş. 3.19’da verilen formül ile tanımlanmaktadır. Türevinin daha fazla değer alabilmesi bu fonksiyonun sigmoid fonksiyonuna kıyasla kullanımının daha avantajlı olmasını sağlar [60].

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.19)$$

Bu fonksiyonların haricinde, doğrusal aktivasyon fonksiyonu özellikle regresyon

problemleri ve çıktı katmanlarında yaygın olarak tercih edildiği için, çalışmalarda temel olarak kullanılan aktivasyon fonksiyonları arasında yer almaktadır [60-61]. Buna göre, doğrusal aktivasyon fonksiyonu, doğrusal problemlerin çözülmesinde modelin yapısına da uyumlu olarak seçilebilir. Doğrusal fonksiyonda elde edilen çıktı, Eş. 3.20'de gösterildiği üzere, girdi değerinin sabit bir katsayı ile çarpılması yoluyla belirlenir. Bu fonksiyonun sınırlılığı olarak türevinin sabit olması gösterilebilir. Çünkü, türevin sabit olduğu sistemlerde doğrusal olmayan öğrenme süreci gerçekleşmez [60].

$$f(x) = ax \quad (3.20)$$

Kullanılan aktivasyon fonksiyonları aracılığıyla ise nöronun çıktısı elde edilmektedir. Nöronun çıktısı da, dış ortama ya da başka bir yapay nörona iletilmektedir. Ayrıca, bu çıktı gerekirse hücrenin kendisine girdi olarak da iletebilir. Buna göre bir nöronun bilgi işleme biçimine ait formüllerinde kullanılan notasyon Çizelge 3.5'te, denklemler ise Eş. 3.21-3.22'de yer almaktadır [58].


Çizelge 3.5. Nöronun bilgi işleme biçimi formülüne ait notasyon

Sembol	Açıklama
y_i	i . nöronun çıktısı
f_i	i . nörondaki aktivasyon fonksiyonu
w_{ij}	i ve j nöronları arasındaki ilişkinin ağırlığı (tek dereceli)
x_j, x_k	j . ve k . nöronun girdisi
θ_i	i . nöronun eşiği
w_{ijk}	i, j ve k nöronları arasındaki ilişkinin ağırlığı (yüksek dereceli)

$$y_i = f_i (\sum_{j=1}^n w_{ij} x_j - \theta_i) \quad (3.21)$$

$$y_i = f_i (\sum_{j=1}^n \sum_{k=1}^n w_{ijk} x_j x_k - \theta_i) \quad (3.22)$$

Bunların yanı sıra, YSA'da yapı, genellikle üç temel katmandan oluşmaktadır. Bu katmanlardaki nöronlar paralel şekilde dizilerek ağı meydana getirmektedir [58]. Şekil 3.2'de 1 adet gizli katmana sahip örnek bir YSA modeli yapısı yer almaktadır.



Şekil 3.2. Bir adet gizli katmanlı yapay sinir ağı modeli yapısı örneği

Buna göre, girdi katmanında yer alan nöronlar, dışarıdan aldıkları bilgileri ara katmanlara iletmekle sorumludurlar. Ara katmanlar ya da gizli katmanlar, girdi katmanından gönderilen bilgileri işleyerek çıktı katmanına iletirler. Ayrıca, bir ağda birden fazla gizli katman bulunabilir. Çıktı katmanındaki nöronlar, gizli katmandan gönderilen bilgilerin işlenmesinden ve bu işleme sonucunda girdi katmanından ağa verilen bilgilere yönelik çıktıların üretilmesinden sorumludur. Üretilen bu çıktı ise dış dünyaya sunulur [58].

Bu bilgiler ışığında, yapay sinir ağlarının tahminleme yöntemi olarak tercih edilmesi çeşitli avantajlar sunmaktadır. İlk olarak, YSA diğer geleneksel model tabanlı yöntemlerin aksine veriye dayalı olarak kendi kendine öğrenme ve uyum sağlama yeteneğine sahiptir. İkinci olarak, YSA kendisine girdi olarak sunulan veriler ile öğrenme işlemini gerçekleştirerek daha önce karşılaşılmayan veriler üzerinde genelleme yapabilir. Hatta eğitim verilerinin kusursuz olmaması durumunda da YSA daha önce karşılaşmadıkları veriler ile doğru bir tahmin çalışması yürütebilir. Üçüncü olarak ise, YSA'nın doğrusal bir yapıya sahip olmaması gösterilebilir. Gerçek hayattaki sistemlerin çoğu doğrusal yapıda değildir. Ancak,

çoğu geleneksel yöntem ele alınan zaman serilerinin genellikle doğrusal süreçlerden elde edildiğini varsayar [62].

Derin öğrenme modelleri

Derin öğrenme mimarileri, sinir ağlarından türetilen yöntemler olup genel olarak veri hacmi ve karmaşıklığı çok yüksek olduğu durumlarda tercih edilmektedir.

Evrişimli sinir ağları

Evrişimli sinir ağları (CNN), farklı konumlardaki bilgileri yüksek doğrulukla tanıyabilen, bir YSA türüdür. Çok katmanlı bir yapıya sahip olan bu modelde katmanlar kendinden önceki katmandan gelen bilgiyi işler ve bir sonraki katmana aktarır. Genel yapısı 1 adet girdi, 1 veya birkaç adet gizli ve 1 adet çıktı katmanından oluşur [63].

Yinelemeli sinir ağları

Yinelemeli sinir ağları nöronların w ağırlığa sahip yaylarla bağlandığı, birbirine bağlı ve etkileşimli bir nöron ağıdır. Bu tür yapay sinir ağlarında bilgi akışı çift yönlü olup dâhili belleğinin olması sayesinde önceki girdileri hatırlayarak uzun ardışık veri girişleri arasında ilişkiler kurulabilir [63].

Uzun Kısa Süreli Bellek Sinir Ağları

Uzun kısa süreli bellek sinir ağları, üç farklı kapıdan veriyi okumayı, yazmayı ve silmeyi mümkün kılan belleğe sahip olması nedeniyle gradyan kaybı problemini çözeabilen bir RNN türevli yöntemdir [63].




4. UYGULAMA

Bu bölümde, gerçekleştirilen deneysel çalışmalar önce genel hatlarıyla ele alınacak, ardından tahmini yapılan elektronik haberleşme göstergeleri bazında ayrıntılı olarak incelenecektir.

4.1. Uygulamanın Genel Yapısı

Bu tez çalışması kapsamında genişbant internet abone sayısı, mobil abone sayısı, mobil ses trafik hacmi, MMS ve SMS miktarı gibi elektronik haberleşme sektörüne ilişkin çeşitli göstergelerin tahmin işlemleri gerçekleştirilmektedir. Mobil trafik hacmi göstergesi, Türkiye'nin Avrupa ülkeleri ile yapılan kıyaslamasında (Bkz. Şekil 4.1) bir abonenin aylık ortalama konuşma süresini ifade eden MoU değerinin yüksek olması sebebiyle sadece ses trafiği ile sınırlandırılmıştır.



Şekil 4.1. Türkiye ile Avrupa Ülkelerinin MoU Değerlerinin Karşılaştırılması [1]

4.1.1. Veri kümesi

Tüm göstergelerin tahmininde kullanılan girdiler Bilgi Teknolojileri ve İletişim Kurumu'nun (BTK) üçer aylık dönemlerle yayımladığı Türkiye Elektronik Haberleşme

Sektörü Üç Aylık Pazar Verileri Raporları ile Türkiye İstatistik Kurumu'nun (TÜİK) gerçekleştirdiği çalışmalardan derlenmiştir [64-65]. Girdilere ait değerlere erişilebilme durumuna göre her göstergenin veri seti aralığı değişiklik göstermektedir. Çalışmada yıllık olarak yayımlanan verilerin (örneğin; ulusal eğitim istatistikleri, yaş grubuna göre nüfus) mevsimsellik içermeyeceği ve belirgin dalgalanmalara sahip olmayacağından hareket edilerek üçer aylık dönemlere dönüştürülmesi işlemi zaman serisi verilerinin tahminlerinde yaygın olarak kullanılan doğrusal interpolasyon yöntemi ile gerçekleştirilmiştir. Oran olarak verilen bazı verilerin yıllık değerleri temsil etmesi dolayısıyla (örneğin; SMS ve MMS gelir oranı, mobil işletmecilerin konuşma gelirleri oranı) tüm yıl için sabit kabul edilerek aynı değer olarak kullanılmıştır. Araştırma ve geliştirme (AR-GE) faaliyetleri için ulaştırma/haberleşme harcamaları ise, yıllık toplam değerler olarak raporlandığından, ilgili yılın çeyrek dönemlerinde eşit tutarda gerçekleştiği yaklaşımı benimsenerek üçer aylık dönemlere dönüştürülmüştür. Çalışmada ayrıca, YSA modelleme sürecinde işlem kolaylığı sağlanması adına, SMS ve MMS miktarı verileri 1 000 000'a, mobil ses trafik hacmi verisi ise 1 000 000 000'a ölçeklendirilmiş ve ele alınan tüm metotların analizlerinde söz konusu ölçekli veri kullanılmıştır. Bu doğrultuda, bu veriler için elde edilen MAE ve MSE hata metrik değerleri de ölçeklendirilmiş veri üzerinden elde edilmiştir.

Her bir gösterge için oluşturulan YSA modellerinde 10'dan fazla özelliğin kullanılması planlanmaktadır. Bu bağlamda, modelin performansını artırmak ve modelin daha sade, zamansal açıdan daha verimli olmasını sağlamak amacıyla, daha az ama daha etkili değişkenlerle bir yapay sinir ağı modeli kurulmasının daha uygun olacağı değerlendirilmiştir. Bu doğrultuda, girdi olması düşünülen değişkenlerin, tahmin edilecek parametreleri açıklamada istatistiksel olarak anlamlı olup olmadıkları regresyon analizi ile test edilmiş ve p -değerleri hesaplanmıştır. Hem deneysel çalışmaların sayıca fazla olması ve zamansal anlamda uzun sürmesi dikkate alınarak hem de model karmaşıklığını azaltma gereksinimi göz önünde bulundurularak, anlamlılık düzeyi (α) 0,01 olarak belirlenmiş ve bu eşik değerin üzerinde p -değerine sahip değişkenler elenerek anlamlı değişkenler belirlenmeye çalışılmıştır. Tahmin edilen her bir göstergenin regresyon analizine ilişkin oluşturulan hipotezlere aşağıda yer verilmiştir.

- H_{0mn} : n . değişken, m . göstergeyi açıklamada istatistiksel olarak anlamlı değildir.
- H_{1mn} : n . değişken, m . göstergeyi açıklamada istatistiksel olarak anlamlıdır.

$m = \{(1) \text{ Geniřbant internet abone sayısı, (2) mobil abone sayısı, (3) MMS miktarı, (4) SMS miktarı, (5) mobil ses trafik hacmi}\}; n = 1,2,\dots,k \text{ ve } k = \{\text{sırasıyla; (1) için 18, (2) için 16, (3) için 14, (4) için 16, (5) için 18}\}$

Regresyon analizinin ardından, özellik seçimini daha sistematik hâle getirmek amacıyla Yinelemeli Özellik Eleme (RFE) yöntemi uygulanmıştır. Özellik seçimi sürecinde iki farklı veri kümesi kullanılmıştır. Bunlardan ilki ham yani işlenmemiş veri kümesi, ikincisi ise bağımlı ve bağımsız değişkenlerin birinci dereceden farklarının alınmasıyla oluşturulan türetilmiş veri kümesidir. Her bir gösterge için bu iki veri kümesine ayrı ayrı RFE yöntemi uygulanması sonucunda değişkenlerin önem düzeylerine göre iki farklı özellik sıralaması elde edilmiştir. RFE yöntemi sonucunda elde edilen özellik önem sıralamaları dikkate alınarak, YSA modelinin performanslarını değerlendirmek amacıyla, sıralamada en az önem değerine sahip özellikler kademeli olarak modelden çıkarılmıştır. Bu kapsamda, ilk veri setindeki özellik sayısı ile modele başlanmış ve 1 adet özellik kalana kadar söz konusu sürece devam edilmiştir. Ayrıca, ham veri ve fark verisi ile elde edilen özellik sıralamalarına göre oluşturulan YSA modellerinde girdi veri kümesi olarak yalnızca ham veriler kullanılmış ve dolayısıyla sadece RFE'deki özellik sıralama işleminde fark alınmış verilerden yararlanılmıştır. RFE yönteminin aşamalarının özetlendiği sözde kod Çizelge 4.1'de verilmiştir.

Çizelge 4.1. RFE yöntemi aşamaları

Ham ve birinci dereceden fark alınmış veriler için:
 Veri kümesini girdi ve çıktı değişkenleri olarak ayır.
 n girdi sayısı olmak üzere $(n-1)$ 'den 1'e kadar:
 Rastgele orman tekniğini kullanan RFE yöntemini uygula.
 Elenen özellikleri belirle.

4.1.2. Hata metrikleri

Çalışma kapsamında performans kıyaslamalarında, aykırı değerleri çok fazla cezalandırmayan ve sezgisel bir anlayışa sahip olan ortalama mutlak hata (MAE), göreceli hata açısından sezgisel yorumlama sunan ortalama mutlak yüzde hata (MAPE) ve aykırı değerleri cezalandırmasıyla bilinen ortalama kare hata (MSE) metriklerinden yararlanılmıştır [66-67]. Bununla birlikte, SARIMA metodunda en iyi parametrelerin

belirlenmesi için yapılan denemelerin kıyaslanmasında, ilgili yöntemin model seçimi aşamasında en çok kullanılan uyum istatistiklerinden AIC ile Bayes bilgi kriteri (BIC) tercih edilmiştir [68-70]. İlgili metriklerde kullanılan notasyon Çizelge 4.2’de, formülleri ise Eş. 4.1-4.5’te verilmiştir.

Çizelge 4.2. Hata metriklerinde kullanılan notasyon

Semboller	Açıklama
X_i	i . gözlemin gerçek değeri
Y_i	i . gözlemin tahmin değeri
n	gözlem sayısı
SSE	kare hataların toplamı
K	$(p+q+P+Q+d+s)$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (4.1)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - Y_i}{X_i} \right| \quad (4.2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2 \quad (4.3)$$

$$AIC = \ln(SSE) + \frac{2k}{n} \quad (4.4)$$

$$BIC = \ln(SSE) + \frac{k}{n} \ln(n) \quad (4.5)$$

4.1.3. Yöntem

Çalışmadaki tüm göstergelerin tahmini yapay sinir ağları kullanılarak gerçekleştirilmiştir. Karşılaştırmalarda kullanılan geleneksel yöntemler ise ilgili göstergelerin zaman serisi grafiklerinden gözlemlenen yapısal özellikler dikkate alınarak belirlenmiştir. Tüm

yöntemler için oluşturulan modeller Python Programlama dilinde kodlanmış ve JupyterLab üzerinde çalıştırılmıştır. Bu kapsamda, veri okuma ve ön işleme aşamaları için pandas ve numpy kütüphaneleri kullanılmıştır. Zaman serisi analizleri statsmodels kütüphanesi aracılığıyla gerçekleştirilmiş; yapay sinir ağı modelleri ise TensorFlow kütüphanesi ile geliştirilmiştir. Verilerin ölçeklendirilmesi ve hata metriklerinin (MAE, MAPE ve MSE) hesaplanmasında scikit-learn kütüphanesinden yararlanılmış; grafiksel gösterimler ise matplotlib kütüphanesi kullanılarak elde edilmiştir.

ARIMA

ARIMA yöntemi uygulanmadan önce, serinin bağımlılık yapısı ACF ve PACF grafikleri çizilerek incelenmiştir. Seri durağanlığının belirlenmesinde ise Augmented Dickey-Fuller (ADF) testi kullanılmış ve ilgili test için anlamlılık düzeyi (α) 0,05 olarak esas alınmıştır. Buna göre, elde edilen p -değeri 0,05'in üzerinde olduğu sürece fark alma işlemi tekrarlanmış, p -değeri 0,05'in altına düştüğünde ise fark alma süreci sonlandırılmıştır. Modelde kullanılacak p ve q parametreleri ise ACF ve PACF grafiklerinin yardımıyla belirlenmiştir. Ardından veriler 0,25:0,75, 0,50:0,50, 0,75:0,25 oranlarında eğitim ve test gruplarına ayrılmış ve üç farklı oran için ARIMA modelleri kurulmuştur. Son aşamada, oluşturulan modellerin performansları MAE, MAPE ve MSE hata metrikleri kullanılarak karşılaştırılmıştır. Söz konusu ARIMA modelinin adımlarını özetleyen sözde kod Çizelge 4.3'te verilmektedir.

Çizelge 4.3. ARIMA yöntemine ait sözde kod

```
Veri setini yükle.
ACF ve PACF grafiklerini oluştur.
ADF testi ile serinin durağanlığını kontrol et.
 $p < 0,05$  sağlanana kadar:
     $i = 1$ 'den başlayarak  $d$  defa:
         $i$ . dereceden fark al.
        ADF testini uygula.
 $i = d$  için ACF ve PACF grafiklerini çiz.
Modeldeki  $p$  ve  $q$  değerlerini belirle.
Veriyi 0,25:0,75, 0,50:0,50 ve 0,75:0,25 olmak üzere üç farklı eğitim-test oranında ayır.
Üç farklı oran için modeli çalıştır.
MAE, MAPE ve MSE değerlerini hesapla.
```

Çift üstel düzeltme

Çift üstel düzeltme yönteminde gerçekleştirilen hesaplamalar, raporun “3.2.1 Zaman serileri analizi” bölümünde ayrıntılı olarak açıklanan yöntem kapsamında, Eş. 3.2-3.4’te verilen formüller kullanılarak yapılmıştır. Söz konusu formüllerin uygulanabilmesi için öncelikle G_0 ve S_0 ’ın başlangıç değerleri hesaplanmıştır. α ve β değerleri $[0,1, 1)$ aralığında 0,1’lik artışlarla denenerek MAE, MAPE ve MSE hata metrikleri hesaplanmıştır. Çalışma kapsamındaki ilgili yönteme ait adımları özetleyen sözde kod ise Çizelge 4.4’te verilmiştir.

Çizelge 4.4. Çift üstel düzeltme yöntemi sözde kodu

```

Veri kümesini yükle.
Başlangıç değerlerini ilk 4 gözleme göre belirle.
0,1 ≤ β < 1 için 0,1’lik artışla:
    0,1 ≤ α < 1 için 0,1’lik artışla:
        Her t ∈ {5,6, ..., n} için:
            St değerini Eş. (3.2) ile hesapla.
            Gt değerini Eş. (3.3) ile hesapla.
            Ft,t+τ değerini Eş. (3.4) ile hesapla.
Her (α, β) denemesi için MAE, MAPE ve MSE performans metriklerini hesapla
  
```

Yapay sinir ağları

Yapay sinir ağlarında kullanılacak hiper parametrelerin seçimi ele alınan problem türüne göre farklılık gösterir (Ataseven, 2013). Genel olarak, gizli katmanlardaki nöron sayısının az olmasındansa daha yüksek seçilmesi tercih edilir. Pratikte bu sayı çoğunlukla 5-100 aralığında belirlenirken, gizli katman ve epok sayıları ise deneylere bağlı olarak ayarlanır [72-73]. Literatürde çok çeşitli epok sayısı, gizli katman sayısı, nöron sayısı tercihleri mevcuttur [74-78]. Bu çalışmada süre kısıtı da hesap edilerek YSA hiper parametrelerinden epok sayısı 200, 300; gizli katman sayısı 1-5; nöron sayısı ise 5-40 aralığında olacak şekilde belirlenmiştir.

Oluşturulan YSA yapısında optimize edici algoritma olarak Adam Algoritması, hem derin öğrenme mimarilerinde kullanımının popüler olması, hem de daha az belleğe ihtiyaç duyması nedenlerine bağlı olarak tercih edilmiştir [79]. Kayıp fonksiyonu olarak ise

regresyon analizlerinde sıklıkla tercih edilen MSE kullanılmıştır [80]. Verilerin normalizasyonunda ise Min-Max normalizasyon yönteminden faydalanılmıştır. Notasyonu Çizelge 4.5'te formülü ise Eş. 4.6'da verilen bu yöntem ile veriler, doğrusal olarak normalize edilmekte ve 0-1 aralığında ölçeklendirilmektedir [81].

Çizelge 4.5. Min-Max normalizasyon yöntemine ait notasyon

Semboller	Açıklama
x_{maks}	veri setinde bulunan en büyük sayı
x_{min}	veri setinde bulunan en küçük sayı
x	x değişkeninin gerçek değeri
x_n	x değişkeninin normalize değeri

$$x_n = \frac{x - x_{min}}{x_{maks} - x_{min}} \quad (4.6)$$

Belirlenen temel özelliklerle oluşturulan her YSA modeli 10 kez çalıştırılmış ve elde edilen sonuçlardan ortalama tahmin değerleri ve performans metrikleri elde edilmiştir. Bu kapsamda, çalışmada oluşturulan yapay sinir ağı modelinin temel yapısı üç aşamadan meydana gelmektedir.

İlk aşamada, modelin genel başarımını üst düzeye çıkarmak ve hesaplamalarda en uygun girdileri kullanabilmek amacıyla farklı eğitim-test oranları (0,25:0,75, 0,50:0,50, 0,75:0,25) ve RFE yöntemi sonucunda belirlenen özellik sıralamaları dikkate alınarak tüm girdi sayıları için çeşitli özellik kombinasyonları denenmiş; bu denemeler sonucunda en uygun eğitim-test oranı ile en iyi sonucu veren özellik kombinasyonları belirlenmeye çalışılmıştır. Tüm özellikleri içeren veri seti ile yapılan denemeler mükerrerliği önlemek adına sadece ham veri kapsamında ele alınmıştır. Dolayısıyla, fark verisi ile elde edilen özellik seçim sıralamasına bağlı yapılan denemeler ise 1 adet özelliğin çıkarılması ile başlatılmıştır. Söz konusu denemelerdeki YSA modeli, 1 adet girdi, 1 adet gizli ve 1 adet çıktı katmanına sahip olup, 200 epok ve nöron aralığı [5-40] olacak şekilde tasarlanmıştır. İlk aşamada farklı eğitim-test oranları için çeşitli girdi sayıları ve nöron kombinasyonlarının denenmesi dolayısıyla, elde edilen bulgular her bir oran için en iyi hata metriklerine sahip model hiper parametreleri verilerek sınırlandırılmıştır. YSA'da kullanılacak özellik sayısının belirlenmesi amacıyla gerçekleştirilen söz konusu denemelerin ardından ise, modele dâhil edilen özellik sayısı

artışının hata metrikleri üzerindeki etkisi ayrı ayrı incelenmiştir. Bu incelemede, birinci aşamada özellik seçiminde kullanılan ham ve fark verisi için en iyi sonuçların elde edildiği; özellik seçiminde kullanılan veri tipi, eğitim-test oranı ve nöron sayısı sabit tutulmuştur.

İkinci aşama denemelerinde, ilk aşama denemelerindeki en iyi performansa sahip eğitim-test oranı ve özellik sayısı sabit olarak ele alınmıştır. Bu aşamada, modelin öğrenme sürecini etkileyen birtakım hiper parametrelerde değişiklikler yapılarak modelin doğruluğunun artırılması amaçlanmıştır. Buna göre, ilk aşamada kurulan YSA modelinin hiper parametrelerinden epok sayısı 200, 300; gizli katman sayısı ise [1, 5] aralığında olacak şekilde farklı senaryolar oluşturularak test edilmiştir. Denemelerdeki nöron sayısı, gizli katmanlarda aynı değer olacak şekilde tasarlanmıştır. Ayrıca, ilk iki aşama modellerinde aktivasyon fonksiyonu olarak, modern sinir ağlarında kullanımı önerilen ReLU aktivasyon fonksiyonu gizli katmanlarda; sinir ağlarının katmanlarında yaygın olarak kullanılan sigmoid aktivasyon fonksiyonu ise çıktı katmanında tercih edilmiştir [72; 82]. İkinci aşama kapsamında elde edilen bulgular, kullanılan veri kümesi için her bir gizli katman ve epok sayısı denemesinde en iyi hata metriklerini sağlayan nöron sayısı esas alınarak sınırlandırılmıştır. Ağ yapısının incelendiği söz konusu ikinci aşama denemelerinin ardından ise, gizli katman ve epok sayılarının model performansı üzerindeki etkisi incelenmiştir. Bu inceleme için ikinci aşamada en iyi sonucu veren modellerin; özellik seçiminde kullanılan veri tipi, eğitim-test oranı, özellik sayısı ve nöron sayısı sabit tutulmuştur.

İkinci aşama sonucunda elde edilen en iyi eğitim-test oranı, özellik seti, epok ve gizli katman sayıları sabit tutularak üçüncü aşama denemelerine geçilmiştir. Üçüncü aşamada ise, çıktı katmanında kullanılacak aktivasyon fonksiyonu seçimine odaklanılmış; literatürde de sıklıkla tercih edilen aktivasyon fonksiyonlarından olan doğrusal, ReLU ve tanh aktivasyon fonksiyonlarının ikinci aşamadaki en iyi performanslı modelin çıktısı üzerindeki etkileri karşılaştırılmıştır. Üçüncü aşama kapsamında elde edilen bulgular, çıktı katmanında kullanılan her bir aktivasyon fonksiyonu için yapılan denemelerde en iyi hata metriklerini sağlayan nöron sayısı esas alınarak sınırlandırılmıştır. Bu denemelerin ardından ise, çıktı katmanında kullanılan farklı aktivasyon fonksiyonlarının modele etkisi incelenmiştir. Bu inceleme için, üçüncü aşamada en iyi sonuçların elde edildiği modellerin; özellik seçiminde kullanılan veri tipi, eğitim-test oranı, özellik sayısı, gizli katman sayısı ve epok sayısı sabit tutulmuştur. Bu sabit yapı altında çıktı katmanında kullanılan tüm aktivasyon fonksiyonu denemelerinin nöron sayısına göre hata metriklerindeki değişimi gözlemlenmiştir. Tüm bu

üç aşamada kullanılan YSA modellerinin hiper parametre özellikleri Çizelge 4.6’da, aşamaların adımlarının özetlendiği sözde kod ise Çizelge 4.7’de yer almaktadır.

Çizelge 4.6. Üç aşama için oluşturulan YSA modellerinin yapısı

Hiper parametreler	İlk Aşama	İkinci aşama	Üçüncü aşama
Gizli katman sayısı	1	1-5	*** ³
Nöron sayısı	5-40	5-40	5-40
Epok sayısı	200	{200, 300}	***
Optimize edici algoritma	Adam	Adam	Adam
Kayıp fonksiyonu	MSE	MSE	MSE
Gizli katman aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Çıktı katmanı aktivasyon fonksiyonu	Sigmoid	Sigmoid	Doğrusal, ReLU, tanh

Çizelge 4.7. YSA yöntemi aşamalarına ait sözde kod

Birinci aşama: Ham veri ve birinci dereceden fark alınmış veri için RFE yöntemini uygula. Elde edilen özellik sıralamasına göre özellik setlerini hazırla. YSA ile her özellik seti için denemeler yap. En uygun özellik sayısı ve eğitim-test oranını belirle. İkinci aşama: Birinci aşamadaki en iyi özellik sayısı ve eğitim-test oranı için: Gizli katman sayısı $\in \{1, 2, 3, 4, 5\}$ olmak üzere: Epok sayısı $\in \{200, 300\}$ olmak üzere: Denemeler yaparak MAE, MAPE ve MSE performans metriklerini hesapla. En uygun katman ve epok sayısını belirle. Üçüncü aşama: İkinci aşamadaki en iyi katman ve epok sayısını sabitle: Çıktı katmanındaki aktivasyon fonksiyonu doğrusal, ReLU ve tanh aktivasyon fonksiyonu olacak şekilde farklı modeller kur. Modelleri çalıştırarak MAE, MAPE ve MSE performans metriklerini hesapla. En iyi çıktı katmanındaki aktivasyon fonksiyonunu belirle.

³Gizli katman sayısının, ikinci aşamadaki en iyi modellerin parametrelerine bağlı olarak farklılık gösterdiği durumlar için “***” işareti kullanılmıştır.

Modellerin karşılaştırılması

Çalışmanın sonucunda tahmin edilen her gösterge için en iyi performans metriklerinin elde edildiği modellerin karşılaştırılmalarında MAE, MAPE ve MSE hata metriklerinden yararlanılmıştır. Ayrıca, istatistiksel açıdan daha güçlü ve güvenilir sonuçlara ulaşmak adına, kullanılan en iyi model yapıları arasındaki performans farklılıklarının anlamlılıkları parametrik olmayan Kruskal-Wallis testi ile değerlendirilmiştir [83]. Analizlerde anlamlılık düzeyi $\alpha = 0,05$ olarak alınmıştır. Bu kapsamda, genişbant abone sayısı, mobil abone sayısı, SMS ve MMS miktarlarının tahmininde aşağıda yer alan hipotezler kurulmuştur.

- H_0 : MAE, MAPE, MSE performans metrikleri açısından ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımları aynıdır.
- H_1 : MAE, MAPE, MSE performans metrikleri açısından ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık gösterir.

Mobil ses trafik hacminin tahmininde ise aşağıda yer alan hipotezler kurulmuştur.

- H_0 : MAE, MAPE, MSE performans metrikleri açısından Holt-Winters, SARIMA ve YSA modellerinin olasılık dağılımları aynıdır.
- H_1 : MAE, MAPE, MSE performans metrikleri açısından Holt-Winters, SARIMA ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık gösterir.


Çalışmanın sonucunda en iyi performans metriklerinin elde edildiği modellerle üretilen tahminlere ait karşılaştırmalar yapılmıştır. Ancak, farklı eğitim-test oranlarının kullanılması ARIMA ve YSA özelinde üretilen tahmin sayısının sınırlı olmasına neden olmuştur. Bu bakımdan, istatistiksel açıdan daha güvenilir, daha tutarlı görsel karşılaştırılmanın yapılabilmesi adına her hata metriği için en iyi sonucu sağlayan hiper parametrelerle tüm değerlerin tahmini gerçekleştirilmiş ve tahminlerin görsel grafikleri bu verilerle oluşturulmuştur. Ayrıca, çalışma boyunca çizelgelerdeki karşılaştırmalarda en iyi bulgular arka plan rengi kullanılarak vurgulanmıştır.

4.2. Geniřbant İnternet Abone Sayısı

Bu bölümde, geniřbant internet abone sayısı özelinde gerekleřtirilen alıřmalar veri kümesi, özellik seimi ve yöntem alt bařlıkları altında ayrıntılı olarak ele alınacaktır.

4.2.1. Veri kümesi

Geniřbant internet abone sayısı, yüksek hızlı veri iletimi saėlayan sabit ve mobil internet baėlantılarına sahip toplam abone sayısı olarak ifade edilebilir. Geniřbant internet abone sayısına iliřkin tahminler, 2010 yılı 1. eyreğinden bařlayıp 2023 yılı 4. eyreğine kadar olan dönemi kapsayan ve toplam 56 adet gözlemden oluřan veri seti kullanılarak yapılmıřtır. řekil 4.2’de Türkiye’deki geniřbant internet abone sayısının eyrek dönemler itibarıyla zamansal deėiřimi yer almaktadır. Veriler, ilgili göstergenin zaman ierisinde artıř eėilimi sergilediėini ve serinin artan bir trend yapısına sahip olduėunu göstermektedir.



řekil 4.2. Geniřbant internet abone sayısının zaman serisi grafiėi

Geniřbant internet abone sayısının tahmininde, “4.1.3 Yöntem” bölümünde ayrıntılı olarak ele alınan ARIMA, ift üstel düzeltme ve YSA metotlarından yararlanılmıřtır. Bu doėrultuda, bu yöntemler iin girdi olarak kullanılan özellikler birbirinden farklılıklar iermektedir. Nitekim, ARIMA ve ift üstel düzeltme yöntemlerinde özellik olarak sadece geniřbant internet abone sayısı kullanılmıř, YSA ile oluřturulan modellerde ise 17 adet özellikten yararlanılmıřtır. Geniřbant internet abone sayısı iin YSA özelinde kullanılan özelliklerden:

- Haberleşme sektörü tüketici fiyat endeksi (H-TÜFE), haberleşme sektöründe gerçekleşen fiyatların genişbant internet aboneliklerini etkileyebileceği;
 - diğer işletmeci yatırımları, internet servis sağlayıcılığı işletmecilerinin yapacakları yatırımlar ile sunulacak hizmet kalitesinin yükselmesine bağlı olarak genişbant internet aboneliklerinde artış meydana gelebileceği;
 - ulusal eğitim istatistikleri, eğitim durumuna göre bireylerin sahip oldukları genişbant internet abonelik sayılarında farklılık oluşabileceği;
 - yaş grubuna göre nüfus, 15-64 yaş grubu bireylerin ekonomik yaşamda aktif rol almaları ve eğitim, sosyal gibi çeşitli faaliyet alanlarında dijital araçlardan yoğun bir şekilde yararlanmaları dolayısıyla doğrudan genişbant abonelik sayısını etkileyebileceği, 65 yaş üstü nüfus ise ilgili yaş grubuna sahip bireylerin son üç ay içerisinde internet kullanım oranı verisinde giderek artış (2025 yılında %53,2) gerçekleştiği göz önüne alındığında bu durumun mobil genişbant internet aboneliklerinde de bir artışa sebebiyet verebileceği [64];
 - AR-GE faaliyetleri için ulaştırma/ haberleşme harcamaları, yapılan harcamaların haberleşme altyapısında iyileştirmeler sağlayabileceği, yeni teknolojilerin (geçmişte 2G, 3G, 4.5G teknolojileri, gelecekte ise 5G ve ötesi teknolojilerin) devreye alınabileceği ve bu gelişmelerin genişbant internet abonelik sayısını da önemli oranda etkileyebileceği;
 - Fiber uzunlukları, daha büyük bant genişliği ve daha yüksek hızlı internet sağlaması ve kapsama alanının genişletmesi nedenleri ile genişbant internet abone sayısını olumlu yönde etkileyebileceği;
 - Evden internete erişim imkânı olan hane oranı, ilgili hanelerde yaşayan bireylerin birer genişbant internet abonesi olabileceği,
- düşünceleriyle,
- zamansal sıra ise genişbant abone sayısının bir zaman serisi olması nedeniyle seçilmiştir (Bkz. Çizelge 4.8).

4.2.2. Özellik seçimi


Genişbant internet abone sayısına ilişkin özellik seçim sürecinin ilk adımı olarak, girdi olması düşünülen özelliklerin genişbant internet abone sayısını açıklamada istatistiksel olarak anlamlı olup olmadıklarının tespitinin yapılabilmesi için regresyon analizine başvurulmuş ve her bir özelliğin p -değeri hesaplanmıştır. Bu kapsamda, hesaplanan p -

değerlerine ilişkin sonuçlar Çizelge 4.8’de sunulmuştur. Analiz sonucunda, 18 özelliğten yalnızca 5 numaralı İlkokul Mezunu kişi sayısı özelliğinin p -değeri 0,01’den büyük çıkmıştır. Bu duruma istinaden, 5. özellik haricindeki diğer özelliklere ait hipotezler reddedilmiş ancak, H_{015} ’in reddedilebilmesi için yeterli kanıtın olmadığı görülmüştür. Analiz sonucunda, ilgili özelliğın bağımlı değışken üzerinde anlamlı bir etkisi olmadığı değıerlendirilmiş ve YSA modeline dâhil edilmemiştir.

Çizelge 4.8. Geniřbant internet abone sayısı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları

Regresyon özellik sıralaması	Özellikler	p -değerleri	H_{01n} kararı	Sonuç	YSA özellik sıralaması
1	H-TÜFE	0,0000	Ret	Anlamlı	1
2	Diğeri işletmeci yatırım değıerleri	0,0000	Ret	Anlamlı	2
3	Okuma yazma bilmeyen kişi sayısı	0,0000	Ret	Anlamlı	3
4	Okuma yazma bilen fakat bir okul bitirmeyen kişi sayısı	0,0000	Ret	Anlamlı	4
5	İlkokul mezunu kişi sayısı	0,0131	Yeterli kanıt yok.	Anlamlı değıil.	-
6	Orta okul veya dengi mezunu kişi sayısı	0,0000	Ret	Anlamlı	5
7	İlköğretim mezunu kişi sayısı	0,0000	Ret	Anlamlı	6
8	Lise veya dengi meslek okulu mezunu kişi sayısı	0,0000	Ret	Anlamlı	7
9	Yüksek okul veya fakülte mezunu kişi sayısı	0,0000	Ret	Anlamlı	8
10	Yüksek lisans mezunu kişi sayısı	0,0000	Ret	Anlamlı	9
11	Doktora mezunu kişi sayısı	0,0000	Ret	Anlamlı	10
12	Eğitim durumu bilinmeyen kişi sayısı	0,0000	Ret	Anlamlı	11
13	15-64 yaş grubundaki kişi sayısı	0,0000	Ret	Anlamlı	12
14	65 yaş grubundaki kişi sayısı	0,0000	Ret	Anlamlı	13
15	AR-GE faaliyetleri için ulaştırma/ haberleşme harcamaları	0,0000	Ret	Anlamlı	14
16	Fiber uzunlukları (km)	0,0000	Ret	Anlamlı	15
17	İnternete erişim imkânı olan hane oranı	0,0000	Ret	Anlamlı	16
18	Zamansal sıra	0,0000	Ret	Anlamlı	17

Regresyon analizi sonucunda anlamlı bulunan 17 özellekle, RFE yönteminin kullanıldığı özellik seçim sürecine başlanmış ve ham veri ile fark verisi için Şekil 4.3'te yer alan sıralamalar elde edilmiştir. Buna göre, 16 özellikli modelde ham veri için 2. özellik, fark verisi için ise 11. özellik çıkarılarak veri kümeleri oluşturulmuştur. Bu süreç her adımda Şekil 4.3'te verilen sıralamaya bağlı olarak 1 adet özelliğin elenmesiyle devam ettirilmiş ve tek bir özellik kalana kadar sürdürülmüştür.




Şekil 4.3. Ham veri ve fark verisi ile uygulanan RFE yöntem sonucuna göre genişbant internet abone sayısı tahminindeki özelliklerin elenme sırası

4.2.3. Yöntem

Genişbant internet abone sayısının tahmini için ARIMA, çift üstel düzeltme ve YSA yöntemleri kullanılmıştır.


ARIMA

Geniřbant internet abone sayısının incelenen dönemde, artış eğilimli zaman serisi yapısına sahip olması nedeniyle tercih edilen yöntemlerden biri ARIMA'dır. ARIMA metodunun uygulanabilmesi için, öncelikle ACF ve PACF grafikleri çizilerek serinin sergilediğı yapı analiz edilmiştir (Bkz. Şekil 4.4). Buna göre, ACF grafiğinden değerlerin yavaş bir şekilde azaldığı, PACF grafiğinden ise ilk birkaç gecikmede anlamlı değerlerin bulunduğu ancak sonrasında değerlerin sıfırın etrafında dalgalandığı görülmektedir. Bu durum, serinin durağan olmadığını ve durağanlaştırma yöntemlerinin uygulanması gerekliliğini ortaya koymaktadır. Bu bulgunun istatistiksel olarak teyidi ADF testi ile gerçekleştirilmiştir. İlk testin sonucunda elde edilen p -değeri 0,104833'tür. Bu değer, serinin durağan bir yapısı olmadığını istatistiksel kanıttır.



Şekil 4.4. Geniřbant internet abone sayısı tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Bu bulgular doğrultusunda, seriye birinci dereceden fark alma işlemi ($d=1$) uygulanarak test işlemi tekrar edilmiştir. İkinci yapılan test sonucunda p -değeri 0,165390 olarak hesaplanmıştır. Elde edilen bu sonuç, serinin hâlâ durağan hâle gelmediğini ifade etmektedir. Bu sebeple, seriye bir kez daha fark alma işlemi ($d=2$) uygulanmış ve p -değeri 0,000000 olarak elde edilmiştir. Bu sonuç ise serinin durağan hâle geldiğı göstermektedir. Son adım ise, ARIMA yöntemindeki (p, d, q) parametre değerlerinin belirlenmesidir. Durağanlaştırılmış serinin ACF ve PACF grafiklerine Şekil 4.5'te yer verilmekte olup ilgili grafiklerin incelenmesi sonucunda; ACF grafiğinde 3 adet, PACF grafiğinde ise 2 adet anlamlı gecikmenin olduğu görülmektedir. Bu bulgular doğrultusunda, eğitim-test oranı denemelerinde ARIMA (2,2,3) modelinin kullanılmasına karar verilmiştir.



Şekil 4.5. Genişbant internet abone sayısı tahmininde ikinci dereceden fark alınmış verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Üç farklı eğitim-test oranı kullanılarak ARIMA (2,2,3) modeliyle gerçekleştirilen denemelere ait sonuçlar Çizelge 4.9’da yer almaktadır. Buna göre, tüm performans metrikleri için en iyi değerler 0,75:0,25 eğitim test oranına sahip veri seti özelinde elde edilmiştir.

Çizelge 4.9. Genişbant internet abone sayısının tahmininde ARIMA (2,2,3) modelinin farklı eğitim-test oranındaki deneme sonuçları

Eğitim-test oranı	MAE	MAPE	MSE
0,25:0,75	16 059 611	0,202398	429 717 853 642 262
0,50:0,50	13 206 941	0,154101	246 635 746 201 309
0,75:0,25	3 465 993	0,037804	22 445 533 782 641

Çift üstel düzeltme

Genişbant internet abone sayısının incelenen dönemde artış eğilimine sahip zaman serisi yapısı nedeniyle tercih edilen tahmin yöntemlerinden bir diğeri de çift üstel düzeltme yöntemidir. İlgili yönteme ait analiz sonuçları, α 'nın her değeri için en iyi MAE, MAPE ve MSE hata metriklerinin elde edildiği β değerleri olacak şekilde özetlenerek Çizelge 4.10’da verilmiştir. En iyi sonuçlar tüm hata metriklerinde $\alpha=0,9$ ve $\beta=0,2$ değerleriyle elde edilmiştir.

Çizelge 4.10. Genişbant abone sayısı tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi sonuçları

α	β	MAE	MAPE	MSE
0,1	0,6	2 627 121	0,068424	10 282 380 017 395
0,1	0,7	2 755 730	0,068351	10 624 485 445 405
0,2	0,9	1 870 816	0,045480	5 191 469 569 592
0,3	0,9	1 360 367	0,035172	3 195 475 968 278
0,4	0,7	1 231 125	0,032051	2 822 717 800 919
0,4	0,9	1 213 906	0,031180	2 881 745 909 880
0,5	0,5	1 162 053	0,030320	2 599 692 214 889
0,5	0,8	1 120 523	0,028828	2 716 815 214 944
0,6	0,4	1 088 123	0,028360	2 441 903 148 949
0,6	0,6	1 063 059	0,027498	2 511 174 522 051
0,7	0,3	1 048 564	0,027418	2 344 833 605 354
0,7	0,4	1 034 786	0,026940	2 357 765 389 746
0,8	0,3	1 011 464	0,026508	2 296 830 434 924
0,9	0,2	989 803	0,026207	2 284 138 351 231

Yapay sinir ağıları


Genişbant internet abone sayısının YSA kullanılarak tahmin edilmesine yönelik süreç, raporun “4.1.3 Yöntem” bölümünde detaylandırılan YSA yönteminin temel yapısı esas alınarak birinci aşama denemeleriyle başlatılmıştır. Söz konusu denemeye ait sonuçlar, her bir eğitim-test oranı için en iyi hata metriklerini sağlayan model hiper parametreleri dikkate alınarak Çizelge 4.11’de verilmektedir. Buna göre, ham veri için MAE, MAPE ve MSE hata metriklerine göre en iyi performans 0,75:0,25 eğitim-test oranıyla, 16 girdi özelliğine ve 39 nörona sahip model ile elde edilmiştir. Birinci dereceden fark alınmış veri setiyle yapılan özellik seçim sıralamasına göre yürütülen denemelerde, MAE ve MAPE hata metriklerine göre en iyi performans 0,75:0,25 eğitim-test oranıyla, 16 girdi özelliğine ve 40 nörona sahip

model ile elde edilmiştir. Öte yandan, MSE hata metriği açısından en başarılı sonuç yine 0,75:0,25 eğitim-test oranıyla ancak 15 girdi ve 39 nöron içeren modelde gözlemlenmiştir.

Çizelge 4.11. Genişbant internet abone sayısı tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları

Veri tipi	Eğitim-test oranı	Özellik sayısı	Nöron	MAE	MAPE	MSE
Ham veri	0,25:0,75	14	36	5 647 280	0,260641	43 689 865 730 187
	0,25:0,75	17	20	5 240 918	0,291148	40 875 501 228 494
	0,50:0,50	17	37	3 614 357	0,185672	18 991 569 297 017
	0,50:0,50	11	38	3 359 672	0,195732	18 741 555 836 176
	0,75:0,25	16	39	2 569 570	0,128762	8 754 191 850 759
Fark alınmış veri	0,25:0,75	13	39	4 826 884	0,256969	34 451 945 084 290
	0,50:0,50	15	37	3 885 211	0,205394	23 453 299 798 911
	0,75:0,25	16	40	2 786 045	0,149884	10 821 770 161 949
	0,75:0,25	15	39	2 816 309	0,157367	10 756 735 905 693

Birinci aşama sonuçlarına göre, ham veri için en iyi sonuçlar tek bir modelle (0,75:0,25 eğitim-test oranı ve 39 nöron); fark verisi için ise iki farklı modelle (0,75:0,25 eğitim-test oranı ve 40 nöron; 0,75:0,25 eğitim-test oranı ve 39 nöron) elde edilmiştir. Bu modellerin ilgili hiper parametreleri sabit tutularak, genişbant internet abone sayısı için yapılan özellik seçiminin model performansı üzerindeki etkisi Şekil 4.6’da incelenmiştir. Şekillerden elde edilen bulgulara göre, modele eklenen özellik sayısı artışının genel olarak performans değerlerinde iyileşme sağladığı, ancak, özellikle girdi olarak 7 özelliğin kullanıldığı modelden sonra, performans artışlarının sınırlı düzeyde kaldığı ve belirgin bir iyileşmenin olmadığı görülmektedir.



Şekil 4.6. Genişbant internet abone sayısı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim

Birinci aşamada elde edilen 0,75:0,25 eğitim-test oranı, ham veri özelinde 16 adet özellik içeren veri kümesi, fark verisi özelinde ise 15 ve 16 adet özellik içeren veri kümeleri sabitlenerek toplamda üç farklı veri kümesi ile ikinci aşama denemelerine geçilmiştir. Bu aşamaya ait sonuçlar, kullanılan veri kümesi için her bir gizli katman ve epok sayısı denemesinde en iyi performansı sağlayan nöron sayısı dikkate alınarak Çizelge 4.12’de özet hâlinde verilmiştir. Tüm performans metrikleri için en iyi sonuçların 0,75:0,25 eğitim-test oranı, 4 gizli katman ve 300 epok kullanıldığında elde edildiği görülmektedir. Spesifik olarak, MAE ve MSE hata metrikleri açısından en iyi sonuç birinci dereceden farkı alınmış veri, 15 özellik ve 30 nörona sahip model, MAPE metriği açısından en iyi sonuç ise ham

veri, 16 özellik ve 38 nörona sahip model ile üretilmiştir.


Çizelge 4.12. Genişbant internet abone sayısı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Veri tipi, eğitim-test oranı, özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAE	MAPE	MSE
Ham veri; 0,75:0,25; 16	1	33	300	1 987 576	0,084691	4 864 903 321 485
	2	38	200	1 861 763	0,069474	4 661 057 268 887
	2	31	300	1 562 101	0,055976	3 309 910 280 834
	3	40	200	1 584 162	0,049858	3 405 045 985 423
	3	30	300	1 516 744	0,050540	3 097 485 875 256
	3	33	300	1 623 898	0,048091	3 759 494 928 712
	3	34	300	1 482 130	0,048523	3 112 972 745 347
	4	30	200	1 318 494	0,045421	2 523 015 047 472
	4	29	300	1 445 295	0,044282	2 984 849 220 696
	4	38	300	1 599 888	0,043756	3 731 953 233 667
	5	30	200	1 416 840	0,045571	2 801 972 373 914
	5	28	300	1 393 006	0,045444	2 958 268 956 038
	5	31	300	1 450 236	0,043978	3 034 970 532 480
Fark alınmış veri; 0,75:0,25; 15	1	40	300	2 235 022	0,103439	6 679 582 936 130
	2	35	200	1 986 054	0,088529	5 572 796 575 079
	2	36	200	1 816 466	0,088869	4 722 022 362 994
	2	39	300	1 479 846	0,055969	2 916 252 063 772
	3	37	200	1 476 209	0,060332	3 088 231 399 401
	3	38	200	1 499 508	0,059486	3 245 303 605 154
	3	37	300	1 475 600	0,048896	3 168 569 705 161
	3	39	300	1 454 410	0,053322	3 045 510 462 812
	4	26	200	1 378 439	0,061359	2 596 560 497 868
	4	33	200	1 443 666	0,052592	2 965 900 134 664
	4	30	300	1 285 534	0,048845	2 189 121 139 608
	4	37	300	1 350 762	0,048042	2 517 732 118 132

Çizelge 4.12. (devam) Genişbant internet abone sayısı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Fark alınmış veri; 0,75:0,25; 15	5	36	200	1 362 805	0,056159	2 484 943 608 779
	5	37	200	1 463 680	0,050264	2 918 046 091 332
	5	26	300	1 339 513	0,046677	2 392 464 396 344
Fark alınmış veri; 0,75:0,25; 16	1	37	300	2 125 200	0,106529	5 868 104 842 133
	1	39	300	2 329 735	0,103453	6 729 228 982 554
	2	30	200	1 925 606	0,092946	5 135 425 300 717
	2	32	200	1 964 271	0,086344	5 019 310 661 908
	2	36	200	1 999 756	0,082657	5 435 468 702 041
	2	37	300	1 550 489	0,060364	3 101 712 072 670
	3	40	200	1 491 897	0,055916	3 017 033 713 417
	3	27	300	1 444 498	0,057703	2 788 677 802 598
	3	40	300	1 501 306	0,051620	3 158 919 329 413
	4	36	200	1 452 327	0,052266	2 952 966 240 640
	4	27	200	1 450 316	0,061595	2 800 208 676 667
	4	27	300	1 363 524	0,051925	2 585 271 581 387
	4	35	300	1 550 391	0,048671	3 367 784 329 899
	5	33	200	1 360 629	0,051468	2 676 252 858 759
	5	39	200	1 378 861	0,050716	2 761 677 469 587
	5	21	300	1 383 188	0,052094	2 591 117 977 153
	5	29	300	1 409 851	0,045482	2 693 030 930 084

Gizli katman sayısı ile epok sayısının model performansına etkileri, ikinci aşama denemelerindeki en iyi sonuçların elde edildiği iki farklı model hiper parametreleri (ham veri, 0,75:0,25 eğitim-test oranı, 16 özellik, 38 nöron; fark verisi, 0,75:0,25 eğitim-test oranı, 15 özellik, 30 nöron) sabit tutularak incelenmiştir. Analize ait grafikler Şekil 4.7’de yer almakta olup ilgili grafiklerden genel olarak en başarılı sonuçların 300 epok, 4 veya 5 gizli katmana sahip modeller ile elde edildiği görülmektedir. Ayrıca, ikinci aşamadaki üç performans metriği özelinde de en iyi değerlere sahip sonuçların, epok ve nöron sayılarına göre değişimleri ise Ek-1-3’te yer almaktadır.




Şekil 4.7. Farklı gizli katman ve epok sayısına göre genişbant internet abone sayısının tahmin performansındaki değişimi

İkinci aşamada en iyi sonuçların iki farklı veri kümesi ile elde edilmesi dolayısıyla, üçüncü aşama denemeleri de ilgili veri kümeleriyle sürdürülmüştür. Spesifik olarak, 15 ve 16 özelliğe sahip veri kümeleri için 4 gizli katman, 300 epok ile çıktı katmanında kullanılan aktivasyon fonksiyonunun model performansı üzerindeki etkisinin incelendiği üçüncü aşama denemeleri gerçekleştirilmiştir. Buna göre, üçüncü aşama denemelerinden elde edilen en iyi sonuçlar Çizelge 4.13'te görülmektedir. En iyi sonuçlar, tüm hata metrikleri açısından doğrusal aktivasyon fonksiyonu ile elde edilmiştir. Tüm performans metriklerinin en iyi değerlerine 16 adet özellikli veri kümesi kullanılarak ulaşılmış olup ayrıca modeller, 4 gizli katman ve 300 epok hiper parametre değerlerine sahiptir. Spesifik olarak, MAE ve MAPE hata metriklerinde 20 nöronlu model; MSE hata metriğinde ise 14 nöronlu model en iyi performansı göstermiştir.

Çizelge 4.13. Genişbant internet abone sayısı tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları

Aktivasyon fonksiyonu	Özellik sayısı	Gizli katman sayısı	Nöron sayısı	MAE	MAPE	MSE
Doğrusal	15	4	25	1 217 124	0,041364	2 524 489 955 295
Doğrusal	15	4	37	1 292 488	0,038191	2 770 021 297 229
Doğrusal	15	4	38	1 266 550	0,041786	2 439 303 683 804
Doğrusal	16	4	14	1 129 716	0,038612	2 038 189 532 991
Doğrusal	16	4	20	1 129 434	0,030912	2 099 347 022 194
ReLU	15	4	34	1 257 768	0,037761	2 646 522 319 638
ReLU	16	4	16	5 710 503	0,100763	302 425 334 542 337
Tanh	15	4	25	1 376 521	0,043433	2 800 656 277 618
Tanh	15	4	40	1 470 303	0,040584	3 231 249 397 173
Tanh	16	4	20	1 388 987	0,035252	3 002 722 420 862
Tanh	16	4	36	1 428 183	0,034175	3 195 548 142 743

Üçüncü aşama denemelerinden elde edilen hata metriklerinin en iyi değerlerine ait parametreler (tüm hata metrikleri için, ham veri, 0,75:0,25 eğitim-test oranı, 16 özellik, 4 gizli katman, 300 epok) sabit tutularak, aktivasyon fonksiyonlarının model performansına etkisinin incelendiği grafikler Şekil 4.8’de yer almaktadır. İlgili grafiklerden, her üç performans metriğinde de doğrusal, sigmoid, tanh aktivasyon fonksiyonlarının birbirine yakın sonuçlar ürettiği, ReLU aktivasyon fonksiyonunun ise genellikle daha dalgalı bir yapı sergilediği ve diğer aktivasyon fonksiyonlarından daha farklı değerler ortaya koyduğu görülebilir. Ayrıca, genel olarak, nöron sayısı artışının bir önceki nörondan elde edilen değerlere göre iyileşme sağladığı görülse de özellikle 16 nörondan sonra performanslardaki iyileşme daha sınırlıdır.




Şekil 4.8. Aktivasyon fonksiyonlarının genişbant internet abone sayısının tahmin performansına etkisi

Modellerin karşılaştırılması

Genişbant internet abone sayısı tahmini için kurulan ARIMA, çift üstel düzeltme ve YSA modellerinin MAE, MAPE ve MSE hata ölçüt metriklerindeki en iyi performanslarına ait karşılaştırmalara Şekil 4.9’da yer verilmektedir. Buna göre, MAE ve MAPE metriklerinde çift üstel düzeltme yöntemi, MSE metriğinde ise YSA en iyi performansı sergilemiştir. YSA

ve çift üstel düzeltme yöntemleri birbirine yakın sonuçlar üretirken, ARIMA modeli diğer iki yöntemle kıyasla belirgin biçimde daha düşük performans göstermiştir.



Şekil 4.9. Genişbant internet abone sayısı tahmin modellerinin karşılaştırılması


Her hata metriği için ayrı olacak şekilde, üç yöntemin en iyi model performanslarına uygulanan Kruskal-Wallis testine ait sonuçlar Çizelge 4.14'te görülmektedir. Elde edilen bulgular doğrultusunda H_0 hipotezi reddedilmiştir. Buna göre, tüm performans metrikleri açısından ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık göstermektedir. Bu farklılıkların hangi gruplar arasında olduğunun belirlenebilmesi için ise, ikili karşılaştırmalar yapılarak sürece devam edilmiştir.

Yapılan testler sonucunda, her üç performans metriği açısından ARIMA modelinin, çift üstel düzeltme metoduna kıyasla anlamlı düzeyde farklı sonuçlar ürettiği; YSA modelinin ise, ARIMA ve çift üstel düzeltme modellerine göre anlamlı düzeyde farklı sonuçlar ürettiğine dair yeterli kanıtın bulunmadığı görülmüştür. Bu bulgular, genişbant internet abone sayısının tahmininde ARIMA model performansının çift üstel düzeltme modeline göre belirgin şekilde farklı olduğunu, YSA modelinin ise ARIMA ve çift üstel düzeltme modelleri ile benzer performansa sahip olduğunu ortaya koymaktadır.


Çizelge 4.14. Genişbant internet abone sayısı tahmini için yapılan Kruskal-Wallis testine ait sonuçlar

Performans metriği	Karşılaştırılan modeller	Test istatistiği	<i>p</i> -değeri
MAE-MAPE	ARIMA-DES-YSA	6,1806	0,0455
	ARIMA-DES	5,8347	0,0157
	ARIMA-YSA	3,5489	0,0596
	DES-YSA	0,2214	0,6380
MSE	ARIMA-DES-YSA	6,1015	0,0473
	ARIMA-DES	5,8347	0,0157
	ARIMA-YSA	3,5490	0,0596
	DES-YSA	0,0062	0,9375

En iyi performans metriklerinin elde edildiği modellerle üretilen tahminlere ait karşılaştırmalar Şekiller 4.10-4.11’de sunulmuştur. İlgili grafiklerden, üç yöntemin de tüm hata metrikleri açısından trend tahmininde başarılı bir performansa sahip olduğu görülmektedir. Kısa vadeli dalgalanmalar dikkate alındığında ise, ARIMA’nın diğer yöntemlere kıyasla daha başarılı olduğu sonucuna ulaşılabilir. Ancak son dönem tahminlerinde ARIMA diğer yöntemlere göre daha zayıf kalmıştır. Genel olarak bakıldığında, YSA daha esnek ve güçlü bir modelleme yaklaşımı sunsa da çift üstel düzeltme yönteminin daha basit bir yapıya sahip olması genişbant internet abone sayısının tahmininde tercih edilebilir bir alternatif olmasına neden olmaktadır.



Şekil 4.10. En iyi MAE ve MAPE hata metrik sonuçlarının elde edildiği hiper parametrelerle üretilen genişbant abone sayısı tahminlerinin karşılaştırılması




Şekil 4.11. En iyi MSE metriği sonucunun elde edildiği hiper parametrelerle üretilen genişbant abone sayısı tahminlerinin karşılaştırılması

4.3. Mobil Abone Sayısı

Bu bölümde, mobil abone sayısı özelinde gerçekleştirilen çalışmalar veri kümesi, özellik seçimi ve yöntem alt başlıkları altında ayrıntılı olarak ele alınacaktır.

4.3.1. Veri kümesi

Mobil abone sayısı, fiilen kullanılıp kullanılmadığına bakılmaksızın abonelik tanımlı abone kimlik modülü (SIM) kartlarının sayısı olarak ifade edilebilir. İlgili veri, makineden makineye iletişim gibi ses trafiği üretmeyen abonelikleri de kapsamaktadır. Mobil abone sayısına ilişkin tahminler, 2009 yılı 1. çeyreğinden başlayıp 2023 yılı 4. çeyreğine kadar olan dönemi kapsayan ve toplam 60 adet gözlemden oluşan veri seti kullanılarak yapılmıştır. Şekil 4.12’de Türkiye’deki mobil abone sayısının çeyrek dönemler itibarıyla zamansal değişimi yer almaktadır. Veriler, ilgili göstergenin zaman içerisinde artış eğilimi sergilediğini ve serinin artan bir trend yapısına sahip olduğunu göstermektedir.



Şekil 4.12. Mobil abone sayısının zaman serisi grafiği

Mobil abone sayısının tahmininde, “4.1.3 Yöntem” bölümünde ayrıntılı olarak ele alınan ARIMA, çift üstel düzeltme ve YSA metotlarından yararlanılmıştır. Bu doğrultuda, bu yöntemler için girdi olarak kullanılan özellikler birbirinden farklılıklar içermektedir. Nitekim, ARIMA ve çift üstel düzeltme yöntemlerinde özellik olarak sadece mobil abone sayısı kullanılmış, YSA ile oluşturulan modellerde ise 15 adet özellikten yararlanılmıştır. Mobil abone sayısı için YSA özelinde kullanılan özelliklerden:

- H-TÜFE, haberleşme sektöründe gerçekleşen fiyatların mobil abonelikleri etkileyebileceği;
- mobil yatırım, işletmecilerin yapacakları yatırımlar ile sunulacak hizmet kalitesinin yükselmesine bağlı olarak mobil aboneliklerde artış meydana gelebileceği;

- ulusal eğitim istatistikleri, eğitim durumuna göre bireylerin sahip oldukları mobil abonelik sayılarında farklılık oluşabileceği;
 - yaş grubuna göre nüfus, mobil telefon kullanan 15-64 yaş grubu bireylerin aktif ekonomik hayata sahip olmaları dolayısıyla doğrudan mobil abonelik sayısını etkileyebileceği, 65 yaş üstü nüfus ise ilgili yaş grubuna sahip bireylerin son üç ay içerisinde internet kullanım oranı verisinde giderek artış (2025 yılında %53,2) gerçekleştiği göz önüne alındığında mobil telefon aboneliklerinde de bir artışa neden olabileceği;
 - AR-GE faaliyetleri için ulaştırma/ haberleşme harcamaları, yapılan harcamaların haberleşme altyapısında iyileştirmeler sağlayabileceği, yeni teknolojilerin (geçmişte 2G, 3G, 4.5G teknolojileri, gelecekte ise 5G ve ötesi teknolojilerin) devreye alınabileceği ve bu gelişmelerin mobil abonelik sayısını da önemli oranda etkileyebileceği;
- düşünceleriyle seçilirken,
- zamansal sıra ise mobil abone sayısının bir zaman serisi olması nedeniyle seçilmiştir.


4.3.2. Özellik seçimi

Mobil abone sayısına ilişkin özellik seçim sürecinin ilk adımında, girdi olması düşünülen 16 adet özelliğin mobil abone sayısını açıklamada istatistiksel olarak anlamlı olup olmadığının tespitinin yapılabilmesi için regresyon analizine başvurulmuş ve her bir özelliğin p -değeri hesaplanmıştır. Bu kapsamda, hesaplanan p -değerlerine ilişkin sonuçlar Çizelge 4.15'te sunulmuştur. Analiz sonucunda, 16 özellikten yalnızca 5 numaralı İlkokul Mezunu kişi sayısı özelliğinin p -değeri 0,01'den büyük çıkmıştır. Bu duruma istinaden, 5. özellik haricindeki diğer özelliklere ait hipotezler reddedilmiş ancak, H_{025} 'in reddedilebilmesi için yeterli kanıtın olmadığı görülmüştür. Analiz sonucunda, ilgili özelliğin bağımlı değişken üzerinde anlamlı bir etkisi olmadığı değerlendirilmiş ve YSA modeline dâhil edilmemiştir.

Çizelge 4.15. Mobil abone sayısı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları

Regresyon özellik sıralaması	Özellikler	p -değerleri	H_{02n} kararı	Sonuç	YSA özellik sıralaması
1	H-TÜFE	0,0000	Ret	Anlamlı	1
2	Mobil yatırım değerleri	0,0000	Ret	Anlamlı	2
3	Okuma yazma bilmeyen kişi sayısı	0,0000	Ret	Anlamlı	3
4	Okuma yazma bilen fakat bir okul bitirmeyen kişi sayısı	0,0000	Ret	Anlamlı	4
5	İlkokul mezunu kişi sayısı	0,3070	Yeterli kanıt yok.	Anlamlı değil.	-
6	Orta okul veya dengi mezunu kişi sayısı	0,0000	Ret	Anlamlı	5
7	İlköğretim mezunu kişi sayısı	0,0000	Ret	Anlamlı	6
8	Lise veya dengi meslek okulu mezunu kişi sayısı	0,0000	Ret	Anlamlı	7
9	Yüksek okul veya fakülte mezunu kişi sayısı	0,0000	Ret	Anlamlı	8
10	Yüksek lisans mezunu kişi sayısı	0,0000	Ret	Anlamlı	9
11	Doktora mezunu kişi sayısı	0,0000	Ret	Anlamlı	10
12	Eğitim durumu bilinmeyen kişi sayısı	0,0000	Ret	Anlamlı	11
13	15-64 yaş grubundaki kişi sayısı	0,0000	Ret	Anlamlı	12
14	65 yaş grubundaki kişi sayısı	0,0000	Ret	Anlamlı	13
15	AR-GE faaliyetleri için ulaştırma/ haberleşme harcamaları	0,0000	Ret	Anlamlı	14
16	Zamansal sıra	0,0000	Ret	Anlamlı	15

Regresyon analizi sonucunda anlamlı bulunan 15 özellikle, RFE yöntemi özellik seçimi gerçekleştirilmiş ve ham veri ve fark verisi için Şekil 4.13'te yer alan sıralamalar elde edilmiştir. Buna göre, 14 özellikli modelde ham veri için 2. özellik, fark verisi için ise 10. özellik çıkarılarak veri kümeleri oluşturulmuştur. Bu süreç her adımda Şekil 4.13'te verilen sıralamaya bağlı olarak bir özelliğin elenmesiyle devam ettirilmiş ve tek bir özellik kalana kadar sürdürülmüştür.



Şekil 4.13. Ham veri ve fark verisi ile uygulanan RFE yöntem sonucuna göre mobil abone sayısı tahminindeki özelliklerin elenme sırası


4.3.3. Yöntem

Mobil abone sayısının tahmini için, ARIMA, çift üstel düzeltme ve YSA yöntemleri kullanılmıştır.

ARIMA


Mobil abone sayısının incelenen dönemde, artış eğilimli zaman serisi yapısına sahip olması nedeniyle tercih edilen yöntemlerden biri ARIMA'dır. ARIMA metodunun uygulanabilmesi için, öncelikle ACF ve PACF grafikleri çizilerek serinin sergilediği yapı analiz edilmiştir (Bkz. Şekil 4.14). Buna göre, ACF grafiğinden değerlerin yavaş bir şekilde azaldığı, PACF grafiğinden ise ilk birkaç gecikmede anlamlı değerlerin bulunduğu ancak sonrasında değerlerin sıfırın etrafında dalgalandığı görülmektedir. Bu durum, serinin durağan olmadığını ve durağanlaştırma yöntemlerinin uygulanması gerekliliğini ortaya koymaktadır. Bu bulgunun istatistiksel olarak teyidi ADF testi ile gerçekleştirilmiştir. İlk testin sonucunda elde edilen p -değeri 0,993603'tür. Bu değer, serinin durağan bir yapısı olmadığını

istatistiksel kanıttır.



Şekil 4.14. Mobil abone sayısı tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Bu bulgular doğrultusunda, seriye birinci dereceden fark alma işlemi ($d=1$) uygulanarak test işlemi tekrar edilmiştir. İkinci yapılan test sonucunda p -değeri 0,000051 olarak hesaplanmıştır. Elde edilen bu sonuç, serinin durağan hâle geldiğini göstermektedir. Son adım ise, ARIMA yöntemindeki (p, d, q) parametre değerlerinin belirlenmesidir. Durağanlaştırılmış serinin ACF ve PACF grafiklerine Şekil 4.15'te yer verilmekte olup ilgili grafiklerin incelenmesi sonucunda; ACF grafiğinde 2, PACF grafiğinde ise 3 adet anlamlı gecikmenin olduğu görülmektedir. Bu bulgular doğrultusunda, eğitim-test oranı denemelerinde ARIMA (3,1,2) modelinin kullanılmasına karar verilmiştir.



Şekil 4.15. Mobil abone sayısı tahmininde birinci dereceden fark alınmış verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Üç farklı eğitim-test oranı kullanılarak ARIMA (3,1,2) modeliyle gerçekleştirilen denemelere ait sonuçlar Çizelge 4.16'da verilmiştir. Buna göre, tüm performans metrikleri için en iyi değerler 0,75:0,25 eğitim test oranına sahip veri seti özelinde elde edilmiştir.

Çizelge 4.16. Mobil abone sayısının tahmininde ARIMA (3,1,2) modelinin farklı eğitim-test oranındaki deneme sonuçları

Eğitim-test oranı	MAE	MAPE	MSE
0,25:0,75	13 896 625	0,168587	246 834 992 633 201
0,50:0,50	9 494 037	0,110519	118 125 470 914 233
0,75:0,25	5 672 334	0,063165	45 744 730 506 794

Çift üstel düzeltme

Mobil abone sayısının incelenen dönemde artış eğilimine sahip zaman serisi yapısı nedeniyle tercih edilen tahmin yöntemlerinden bir diğeri de çift üstel düzeltme yöntemidir. İlgili yöntemle ait analiz sonuçları, α 'nın her değeri için en iyi MAE, MAPE ve MSE hata metriklerinin elde edildiği β değerleri olacak şekilde özetlenerek Çizelge 4.17'de verilmiştir. Buna göre, en iyi sonuçlar MAE hata metriğinde $\alpha=0,7$ ve $\beta=0,3$ değerleriyle, MAPE hata metriğinde $\alpha=0,8$ ve $\beta=0,3$ değerleriyle, MSE hata metriğinde ise $\alpha=0,7$ ve $\beta=0,4$ değerleriyle elde edilmiştir.

Çizelge 4.17. Mobil abone sayısı tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi sonuçları

α	β	MAE	MAPE	MSE
0,1	0,9	1 686 113	0,022394	4 033 258 444 342
0,2	0,9	992 663	0,013194	1 612 644 225 617
0,3	0,9	775 667	0,010353	907 190 615 625
0,4	0,9	687 140	0,009041	717 679 370 321
0,5	0,7	656 147	0,008598	692 899 307 597
0,5	0,8	651 223	0,008512	693 862 502 363
0,6	0,4	641 177	0,008412	693 804 023 600
0,6	0,5	642 009	0,008398	686 004 408 204
0,6	0,6	643 233	0,008388	689 927 862 399
0,7	0,3	628 814	0,008233	686 959 158 190
0,7	0,4	634 216	0,008269	685 959 805 186
0,8	0,3	629 614	0,008193	691 556 672 130
0,9	0,2	639 818	0,008331	702 666 830 870
0,9	0,3	640 260	0,008287	719 245 716 195

Yapay sinir ağıları


Mobil abone sayısının YSA kullanılarak tahmin edilmesine yönelik süreç, raporun “4.1.3 Yöntem” bölümünde detaylandırılan YSA yönteminin temel yapısı esas alınarak birinci aşama denemeleriyle başlatılmış ve ilgili aşamaya ait sonuçlar, her bir eğitim-test oranı için en iyi hata metriklerini sağlayan model hiper parametreleri dikkate alınarak Çizelge 4.18’de verilmiştir. Buna göre, ham veri için MAE ve MSE metriklerine göre en iyi performans 0,75:0,25 eğitim-test oranıyla, 14 girdi özeliğine ve 38 nörona sahip model ile elde edilmiştir. Öte yandan, MAPE metriği açısından en başarılı sonuç yine 0,75:0,25 eğitim-test oranıyla ancak 15 girdi ve 40 nöron içeren modelde gözlemlenmiştir. Birinci dereceden fark alınmış veri setiyle yapılan özellik seçim sıralamasına göre yürütülen denemelerde, tüm performans metrikleri açısından en iyi sonuç 0,75:0,25 eğitim-test oranı, 13 girdi ve 39 nöronlu model ile elde edilmiştir.

Çizelge 4.18. Mobil abone sayısı tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları

Veri tipi	Eğitim-test oranı	Özellik sayısı	Nöron sayısı	MAE	MAPE	MSE
Ham veri	0,25:0,75	9	39	2 265 868	0,031173	6 659 643 389 425
	0,25:0,75	10	34	2 260 656	0,031274	6 776 276 025 363
	0,50:0,50	11	26	1 540 201	0,021400	3 708 679 079 520
	0,50:0,50	14	35	1 543 008	0,021371	3 645 599 379 930
	0,75:0,25	14	38	956 010	0,012405	1 416 033 968 657
	0,75:0,25	15	40	959 966	0,012375	1 468 695 109 244
Fark alınmış veri	0,25:0,75	14	33	2 402 321	0,033229	7 734 526 071 340
	0,50:0,50	14	34	1 608 605	0,022160	3 776 364 685 140
	0,50:0,50	14	36	1 616 796	0,022351	3 770 450 563 487
	0,75:0,25	13	39	900 254	0,011693	1 357 556 054 102

Birinci aşama sonuçlarına göre, ham veri için en iyi sonuçlar iki farklı modelle (0,75:0,25 eğitim-test oranı ve 38 nöron; 0,75:0,25 eğitim-test oranı ve 40 nöron); fark verisi için ise tek bir modelle (0,75:0,25 eğitim-test oranı ve 39 nöron) elde edilmiştir. Bu modellerin ilgili hiper parametreleri sabit tutularak, mobil abone sayısı için yapılan özellik seçiminin model performansı üzerindeki etkisi Şekil 4.16’da incelenmiştir. Elde edilen bulgulara göre, modele eklenen özellik sayısı artışının genel olarak performans değerlerinde iyileşme

sağladığı, ancak, özellikle girdi olarak 7 özelliğin kullanıldığı modelden sonra, performans artışlarının sınırlı düzeyde kaldığı ve belirgin bir iyileşmenin olmadığı görülmektedir.



Şekil 4.16. Mobil abone sayısı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim

Birinci aşamada elde edilen 0,75:0,25 eğitim-test oranı, ham veri özelinde 14 ve 15 özellik içeren veri kümeleri, fark verisi özelinde ise 13 özellik içeren veri kümesi sabitlenerek toplamda üç farklı veri kümesi ile ikinci aşama denemelerine geçilmiştir. Bu aşamaya ait sonuçlar, kullanılan veri kümesi için her bir gizli katman ve epok sayısı denemesinde en iyi performansı sağlayan nöron sayısı dikkate alınarak Çizelge 4.19’da özet hâlinde verilmiştir. Bulgular, tüm performans metrikleri için en iyi sonuçların 0,75:0,25 eğitim-test oranı ve 300 epok kullanıldığında elde edildiğini göstermektedir. Ancak, üç performans metriğinin de en iyi değerleri farklı hiper parametre kombinasyonlarına sahiptir. Spesifik olarak, MAE

metriği açısından en iyi sonuç birinci dereceden farkı alınmış veri, 13 özellik, 5 gizli katman ve 40 nörona sahip model, MAPE metriği açısından en iyi sonuç ham veri, 15 özellik, 4 gizli katman ve 38 nörona sahip model, MSE metriği açısından ise en iyi sonuç ham veri, 14 özellik, 5 gizli katman ve 36 nörona sahip model ile üretilmiştir.


Çizelge 4.19. Mobil abone sayısı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Veri tipi, eğitim-test oranı, özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAE	MAPE	MSE
Ham veri, 0,75:0,25, 14	1	30	300	811 893	0,010592	1 116 936 579 648
	1	34	300	818 517	0,010689	1 052 091 306 290
	2	35	200	799 170	0,010420	1 048 185 071 242
	2	40	200	795 432	0,010367	1 052 733 873 287
	2	27	300	769 695	0,010042	951 845 858 035
	3	35	200	760 675	0,010004	907 004 088 555
	3	36	300	708 192	0,009263	814 761 436 023
	4	40	200	698 787	0,009152	838 532 450 352
	4	31	300	731 001	0,009559	788 654 304 605
	4	39	300	723 193	0,009395	796 170 958 877
	5	27	200	740 111	0,009696	891 836 894 619
	5	35	300	696 690	0,009151	749 303 633 618
	5	36	300	704 870	0,009195	715 427 982 836
Ham veri, 0,75:0,25, 15	1	27	300	849 039	0,011005	1 227 289 946 078
	1	39	300	850 215	0,010999	1 143 451 939 974
	2	38	200	814 283	0,010655	1 038 468 298 716
	2	27	300	772 048	0,010094	966 597 974 281
	2	37	300	773 553	0,010171	938 433 124 537
	3	36	200	775 325	0,010175	970 068 040 152
	3	40	200	776 932	0,010213	951 971 872 837
	3	35	300	715 385	0,009328	813 652 372 053
	3	38	300	710 905	0,009364	827 317 514 699

Çizelge 4.19. (devam) Mobil abone sayısı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Ham veri, 0,75:0,25, 15	4	28	200	742 614	0,009775	902 956 007 756
	4	38	300	671 433	0,008798	747 113 379 132
	5	36	200	736 493	0,009699	937 467 270 778
	5	40	200	755 025	0,009871	909 909 951 275
	5	39	300	699 981	0,009191	738 560 502 781
	5	40	300	702 045	0,009161	797 707 628 601
Fark alınmış veri, 0,75:0,25, 13	1	33	300	835 536	0,010835	1 170 877 146 272
	1	39	300	851 430	0,011122	1 141 747 102 688
	2	40	200	779 582	0,010189	993 882 998 758
	2	38	300	733 307	0,009623	889 830 937 545
	3	38	200	757 343	0,009956	898 125 716 293
	3	35	300	712 425	0,009337	861 704 191 157
	3	40	300	730 305	0,009551	852 528 799 413
	4	30	200	719 097	0,009499	888 891 027 731
	4	29	300	707 155	0,009257	840 145 174 056
	4	38	300	710 416	0,009302	791 375 916 787
	5	40	200	738 673	0,009647	943 977 723 010
	5	40	300	668 963	0,008829	727 193 676 577

Gizli katman sayısı ile epok sayısının model performansına etkileri, ikinci aşama denemelerindeki en iyi sonuçların elde edildiği üç farklı model hiper parametreleri (ham veri, 0,75:0,25 eğitim-test oranı, 14 özellik, 36 nöron; ham veri, 0,75:0,25 eğitim-test oranı, 15 özellik, 38 nöron; fark verisi, 0,75:0,25 eğitim-test oranı, 13 özellik, 40 nöron) sabit tutularak incelenmiştir. Analize ait grafikler Şekil 4.17’de yer almakta olup ilgili grafiklerden genel olarak en başarılı sonuçların 300 epok, 4 veya 5 gizli katmana sahip modeller ile elde edildiği görülmektedir. Ayrıca, ikinci aşamadaki üç performans metriği özelinde de en iyi değerlere sahip sonuçların, epok ve nöron sayılarına göre değişimleri ise Ek-4-6’da yer almaktadır.




Şekil 4.17. Farklı gizli katman ve epok sayısı denemelerine göre mobil abone sayısının tahmin performansındaki değişimi

İkinci aşamada en iyi sonuçların üç farklı veri kümesi ile elde edilmesi dolayısıyla, üçüncü aşama denemeleri de ilgili veri kümeleriyle sürdürülmüştür. Spesifik olarak, 13 ve 14 özelliğe sahip veri kümeleri için 5 gizli katman, 300 epok; 15 özelliğe sahip veri kümesi için ise 4 gizli katman, 300 epok ile üçüncü aşama denemeleri gerçekleştirilmiştir. Buna göre, çıktı katmanında kullanılan aktivasyon fonksiyonunun model performansı üzerindeki etkisinin incelendiği üçüncü aşama denemelerinden elde edilen en iyi sonuçlar Çizelge 4.20’de görülebilir. En iyi sonuçlar, MAPE ve MAE hata metrikleri açısından doğrusal aktivasyon fonksiyonu ile, MSE hata metriği açısından ise ReLU aktivasyon fonksiyonu ile elde edilmiştir. Tüm performans metriklerinin en iyi değerleri 5 gizli katman ve 300 epok hiper parametre değerlerine sahiptir. Spesifik olarak, MAE performans metriğinde 14 özellik, 37 nöronlu model; MAPE performans metriğinde 14 özellik, 26 nöronlu model; MSE performans metriğinde ise 13 özellik, 34 nöronlu model en iyi performansı göstermiştir

Çizelge 4.20. Mobil abone sayısı tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları

Aktivasyon fonksiyonu	Özellik sayısı	Gizli katman sayısı	Nöron sayısı	MAE	MAPE	MSE
Doğrusal	13	5	39	624 497	0,008058	641 196 118 738
Doğrusal	13	5	31	627 727	0,008091	636 916 450 016
Doğrusal	14	5	26	601 092	0,007735	665 026 360 432
Doğrusal	14	5	37	600 843	0,007764	649 613 474 968
Doğrusal	14	5	38	612 785	0,007980	628 957 340 980
Doğrusal	15	4	28	623 762	0,008039	734 927 750 048
Doğrusal	15	4	31	627 120	0,008066	623 574 720 357
ReLU	13	5	34	635 344	0,008242	611 839 575 459
ReLU	14	5	26	2 117 335	0,025982	35 219 894 335 654
ReLU	14	5	33	2 125 154	0,026178	35 124 909 937 823
ReLU	15	4	35	632 711	0,008169	671 469 898 671
Tanh	13	5	40	660 853	0,008398	662 917 668 060
Tanh	14	5	40	670 313	0,008616	667 274 449 571
Tanh	15	4	38	692 290	0,008861	709 990 489 789


Üçüncü aşama denemelerinden elde edilen hata metriklerinin en iyi değerlerine ait parametreler (MAE ve MAPE hata metrikleri için, ham veri, 0,75:0,25 eğitim-test oranı, 14 özellik, 5 gizli katman, 300 epok; MSE hata metriği için ise, fark verisi, 0,75:0,25 eğitim-test oranı, 13 özellik, 5 gizli katman, 300 epok) sabit tutularak, aktivasyon fonksiyonlarının model performansına etkisinin incelenmiş ve elde edilen grafikler Şekil 4.18’de verilmiştir. İlgili grafiklerden, her üç performans metriğinde de doğrusal, sigmoid, tanh aktivasyon fonksiyonlarının birbirine yakın sonuçlar ürettiği, ReLU aktivasyon fonksiyonunun ise genellikle daha dalgalı bir yapı sergilediği ve diğer aktivasyon fonksiyonlarından daha farklı değerler ortaya koyduğu görülmektedir. Ayrıca genel olarak, nöron sayısı artışının bir önceki nöronlardan elde edilen değerlere göre iyileşme sağladığı görülse de özellikle 10 nörondan sonra performanslardaki iyileşme daha sınırlıdır.



Şekil 4.18. Aktivasyon fonksiyonlarının mobil abone sayısının tahmin performansına etkisi

Modellerin karşılaştırılması

Mobil abone sayısı tahmini için kurulan ARIMA, çift üstel düzeltme ve YSA modellerinin MAE, MAPE ve MSE hata ölçüt metriklerindeki en iyi performanslarına ait karşılaştırmalarına Şekil 4.19’da yer verilmektedir. Buna göre, tüm hata metriklerinde en iyi sonuçlar YSA yöntemi ile üretilmiştir. Bununla birlikte, YSA ve çift üstel düzeltme yöntemlerinin birbirlerine yakın performans sergilediği, ARIMA modelinin ise diğer iki modele kıyasla daha düşük performans gösterdiği görülmektedir.



Şekil 4.19. Mobil abone sayısı tahmin modellerinin karşılaştırılması


Her hata metriği için ayrı olacak şekilde, üç yöntemin en iyi model performanslarına uygulanan Kruskal-Wallis testine ait sonuçlar Çizelge 4.21’de görülmektedir. Elde edilen bulgular H_0 hipotezinin reddedilmesine yol açmıştır. Buna göre, MAE, MAPE ve MSE performans metrikleri açısından ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık göstermektedir. Bu farklılıkların hangi gruplar arasında olduğunun belirlenebilmesi için ise, ikili karşılaştırmalar yapılarak sürece devam edilmiştir. Yapılan testler sonucunda, her üç performans metriği açısından ARIMA modelinin, çift üstel düzeltme ve YSA modellerine kıyasla anlamlı düzeyde farklı sonuçlar ürettiği; çift üstel düzeltme ve YSA modelleri arasında ise anlamlı düzeyde farklı sonuçlar

üretildiğine dair yeterli kanıtın bulunmadığı görülmüştür. Bu bulgular, mobil abone sayısının tahmininde, ARIMA model performansının diğer iki modele göre belirgin şekilde farklı olduğunu, çift üstel düzeltme ve YSA'nın ise benzer performansa sahip olduğunu ortaya koymaktadır.


Çizelge 4.21. Mobil abone sayısı tahmini için yapılan Kruskal-Wallis testine ait sonuçlar

Performans metriği	Karşılaştırılan modeller	Test istatistiği	<i>p</i> -değeri
MAE	ARIMA- DES -YSA	21,7811	0,0000
	ARIMA- DES	19,8127	0,0000
	ARIMA-YSA	13,7811	0,0002
	DES -YSA	0,6222	0,4302
MAPE	ARIMA- DES -YSA	21,4421	0,0000
	ARIMA- DES	19,8127	0,0000
	ARIMA-YSA	13,4748	0,0002
	DES -YSA	0,3175	0,5731
MSE	ARIMA- DES -YSA	20,8330	0,0000
	ARIMA- DES	19,5627	0,0000
	ARIMA-YSA	12,8727	0,0003
	DES -YSA	0,0716	0,7890


En iyi performans metriklerinin elde edildiği modellerle üretilen tahminlere ait karşılaştırmalar Şekiller 4.20-4.22'de sunulmuştur. İlgili grafiklerden, YSA ve çift üstel düzeltme yönteminin hem MAE hem de MAPE hata metriği açısından trend tahmininde başarılı bir performansa sahip olduğu görülmektedir. Kısa vadeli dalgalanmalar dikkate alındığında ise, YSA'nın çift üstel düzeltme yöntemine kıyasla daha başarılı olduğu sonucuna ulaşılabilir. Ancak, MSE metriği açısından en iyi YSA modelinin hiper parametreleri kullanılarak elde edilen tahminler çift üstel düzeltme yöntemine göre zayıf kalmıştır. Bu durum modelin genelleme kabiliyetinin zayıf olmasından ya da test setindeki örneklemin dağılımından kaynaklanabilir. Genel olarak bakıldığında, YSA daha esnek ve güçlü bir modelleme yaklaşımı sunsa da çift üstel düzeltme yönteminin daha basit bir yapıya sahip olması mobil abone sayısının tahmininde tercih edilebilir bir alternatif olmasına neden olmaktadır.



Şekil 4.20. En iyi MAE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen mobil abone sayısı tahminlerinin karşılaştırılması



Şekil 4.21. En iyi MAPE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen mobil abone sayısı tahminlerinin karşılaştırılması




Şekil 4.22. En iyi MSE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen mobil abone sayısı tahminlerinin karşılaştırılması

4.4. MMS Miktarı

Bu bölümde, MMS miktarı özelinde gerçekleştirilen çalışmalar veri kümesi, özellik seçimi ve yöntem alt başlıkları altında ayrıntılı olarak ele alınacaktır.

4.4.1. Veri kümesi

MMS miktarı verisi, abonelerin üç aylık dönemler içinde gönderdiği multimedya mesaj sayısını ifade etmektedir. MMS miktarına ilişkin tahminler, 2009 yılı 1. çeyreğinden başlayıp 2023 yılı 4. çeyreğine kadar olan dönemi kapsayan ve toplam 60 adet gözlemden oluşan veri seti kullanılarak yapılmıştır. Şekil 4.23'te Türkiye'de gönderilen MMS miktarının çeyrek dönemler itibarıyla zamansal değişimi yer almaktadır. Veriler, ilgili göstergenin zaman içerisinde dalgalı bir yapı sergilediğini ve serinin genellikle azalan bir trend yapısına sahip olduğunu göstermektedir.



Şekil 4.23. MMS miktarının zaman serisi grafiği

MMS miktarının tahmininde, “4.1.3 Yöntem” bölümünde ayrıntılı olarak ele alınan ARIMA, çift üstel düzeltme ve YSA metotlarından yararlanılmıştır. Bu doğrultuda, bu yöntemler için girdi olarak kullanılan özellikler birbirinden farklılıklar içermektedir. Nitekim, ARIMA ve çift üstel düzeltme yöntemlerinde özellik olarak sadece MMS miktarı kullanılmış, YSA ile oluşturulan modellerde ise 14 adet özellikten yararlanılmıştır. Söz konusu özelliklerden:

- mobil abone sayısı, mobil aboneliğe sahip bireylerin MMS hizmetinden yararlanabileceği;
 - H-TÜFE, haberleşme sektöründe gerçekleşen fiyatların abonelikleri ve abonelerin haberleşme tercihlerini etkileyebileceği;
 - ulusal eğitim istatistikleri, pazarlama, bankacılık vb. sektörler için eğitim durumuna göre iletilen MMS sayısında değişimler yaşanabileceği;
 - SMS ve MMS gelir oranı, işletmelerin gelir oranı gibi stratejilerini önceden belirleyebilecekleri ve hangi gelir türünün kendileri için daha önemli olduğuna karar verip yatırımlarını bu doğrultuda yapabilecekleri;
- düşünceleriyle;
- zamansal sıra ise, MMS'nin zaman serisi olması sebebiyle seçilmiştir.


4.4.2. Özellik seçimi

MMS miktarına ilişkin özellik seçim sürecinin ilk adımı olarak, girdi olması düşünülen özelliklerin MMS miktarını açıklamada istatistiksel olarak anlamlı olup olmadıklarının tespiti için regresyon analizine başvurulmuş ve her bir özelliğin p -değeri hesaplanmıştır. Hesaplanan p -değerlerine ilişkin sonuçlar Çizelge 4.22'de sunulmuştur. Analiz sonucunda, tüm özelliklerin p -değerleri 0,01'den küçük çıkmıştır. Bu duruma istinaden, tüm özelliklerin bağımlı değişken üzerinde anlamlı bir etkisi olduğu değerlendirilmiş ve YSA modeline tüm özellikler kullanılarak devam edilmiştir.

Çizelge 4.22. MMS miktarı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları

Özellik sıralaması	Özellikler	p -değerleri	H_{03n} kararı	Sonuç
1	Mobil abone sayısı	0,0000	Ret	Anlamlı
2	H-TÜFE	0,0005	Ret	Anlamlı
3	Okuma yazma bilmeyen kişi sayısı	0,0053	Ret	Anlamlı
4	İlkokul mezunu kişi sayısı	0,0000	Ret	Anlamlı
5	Okuma yazma bilen fakat bir okul bitirmeyen kişi sayısı	0,0000	Ret	Anlamlı
6	Ortaokul veya dengi mezunu kişi sayısı	0,0000	Ret	Anlamlı
7	İlköğretim mezunu kişi sayısı	0,0000	Ret	Anlamlı
8	Lise veya dengi meslek okulu mezunu kişi sayısı	0,0000	Ret	Anlamlı
9	Yüksekokul veya fakülte mezunu	0,0000	Ret	Anlamlı
10	Yüksek lisans mezunu kişi sayısı	0,0000	Ret	Anlamlı
11	Doktora mezunu kişi sayısı	0,0000	Ret	Anlamlı
12	Eğitim durumu bilinmeyen kişi sayısı	0,0004	Ret	Anlamlı
13	SMS ve MMS gelir oranı	0,0000	Ret	Anlamlı
14	Zamansal sıra	0,0000	Ret	Anlamlı

Regresyon analizi sonucunda anlamlı bulunan 14 özellikle, RFE yöntemi özellik seçimi gerçekleştirilmiş ve ham veri ve fark verisi için Şekil 4.24'te yer alan sıralamalar elde edilmiştir. Buna göre, 13 özellikli modelde ham veri için 8. özellik, fark verisi için ise 10. özellik çıkarılarak veri kümeleri oluşturulmuştur. Bu süreç her adımda Şekil 4.24'te verilen sıralamaya bağlı olarak bir özelliğin elenmesiyle devam ettirilmiş ve tek bir özellik kalana kadar sürdürülmüştür.



Şekil 4.24. Ham veri ve fark verisi ile uygulanan RFE yöntem sonucuna göre MMS miktarı tahminindeki özelliklerin elenme sırası


4.4.3. Yöntem

MMS miktarının tahmininde, “4.1.3 Yöntem bölümünde” de değinilen ARIMA, çift üstel düzeltme ve YSA yöntemleri kullanılmıştır.

ARIMA


MMS miktarının incelenen dönemde, azalış eğilimine sahip zaman serisi yapısına sahip olması nedeniyle tercih edilen yöntemlerden biri ARIMA’dır. ARIMA metodunun uygulanabilmesi için, öncelikle ACF ve PACF grafikleri çizilerek serinin sergilediği yapı analiz edilmiştir (Bkz. Şekil 4.25). Buna göre, ACF grafiğinden değerlerin yavaş bir şekilde azaldığı, PACF grafiğinden ise ilk birkaç gecikmede anlamlı değerlerin bulunduğu ancak sonrasında değerlerin sıfırın etrafında dalgalandığı görülmektedir. Bu durum, serinin durağan olmadığını ve durağanlaştırma yöntemlerinin uygulanması gerekliliğini ortaya

koymaktadır. Bu bulgunun istatistiksel olarak teyidi ADF testi ile gerçekleştirilmiştir. İlk testin sonucunda elde edilen p -değeri 0,570824'tür. Bu değer, serinin durağan bir yapısı olmadığını istatistiksel kanıttır.



Şekil 4.25. MMS miktarının tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Bu bulgular doğrultusunda, seriye birinci dereceden fark alma işlemi ($d=1$) uygulanarak test işlemi tekrar edilmiştir. İkinci yapılan test sonucunda p -değeri 0,010486 olarak hesaplanmıştır. Elde edilen bu sonuç, serinin durağan hâle geldiğini göstermektedir. Son adım ise, ARIMA yöntemindeki (p, d, q) parametre değerlerinin belirlenmesidir. Durağanlaştırılmış serinin ACF ve PACF grafiklerine Şekil 4.26'da yer verilmekte olup ilgili grafiklerin incelenmesi sonucunda; ACF grafiğinde 1, PACF grafiğinde ise 2 adet anlamlı gecikmenin olduğu görülmektedir. Bu bulgular doğrultusunda, eğitim-test oranı denemelerinde ARIMA (2,1,1) modelinin kullanılmasına karar verilmiştir.



Şekil 4.26. MMS miktarının tahmininde birinci dereceden fark alınmış verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Üç farklı eğitim-test oranı kullanılarak ARIMA (2,1,1) modeliyle gerçekleştirilen denemelere ait sonuçlar Çizelge 4.23'te yer almaktadır. Buna göre, tüm performans metrikleri için en iyi değerler 0,75:0,25 eğitim test oranına sahip veri seti özelinde elde

edilmiştir.

Çizelge 4.23. MMS miktarının tahmininde ARIMA (2,1,1) modelinin farklı eğitim-test oranlarındaki deneme sonuçları

Eğitim-test oranı	MAE	MAPE	MSE
0,25:0,75	59,93338	4,600652	798,9768
0,50:0,50	20,55045	1,910958	453,6167
0,75:0,25	1,398853	0,123276	4,249365

Çift üstel düzeltme

MMS miktarının incelenen dönemde azalış eğilimine sahip olması nedeniyle tercih edilen tahmin yöntemlerinden bir diğeri de çift üstel düzeltme yöntemidir. İlgili yönteme ait analiz sonuçları, α 'nın her değeri için en iyi hata metriklerinin elde edildiği β değerleri olacak şekilde Çizelge 4.24'te verilmiştir. Buna göre en iyi sonuçlar, MAE ve MAPE hata metriklerinde $\alpha=0,9$ ve $\beta=0,1$ değerleriyle, MSE hata metriğinde $\alpha=0,9$ ve $\beta=0,4$ değerleriyle elde edilmiştir.

Çizelge 4.24. MMS miktarının tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi sonuçları

α	β	MAE	MAPE	MSE
0,1	0,1	13,490694	0,530465	394,716856
0,2	0,9	9,702008	0,361432	222,288932
0,3	0,9	6,728344	0,234134	123,641203
0,4	0,7	5,727599	0,201124	92,038555
0,4	0,9	5,675698	0,207029	86,282758
0,5	0,6	5,086047	0,184632	73,146479
0,5	0,7	5,048433	0,187550	70,768967
0,5	0,9	5,182450	0,198110	67,321859
0,6	0,4	4,671133	0,171489	64,562068
0,6	0,5	4,659501	0,173509	62,179255
0,6	0,9	4,812043	0,189357	57,805792
0,7	0,1	4,394395	0,162347	60,899796
0,7	0,4	4,391707	0,164993	55,240900
0,7	0,7	4,562299	0,178221	52,559280
0,8	0,1	4,063736	0,155101	53,195266
0,8	0,6	4,309653	0,168490	48,578594
0,9	0,1	3,881403	0,150283	47,769148
0,9	0,4	4,011609	0,155088	45,592211

Yapay sinir ağları


MMS miktarının YSA kullanılarak tahmin edilmesine yönelik süreç, raporun “4.1.3 Yöntem” bölümünde detaylandırılan YSA yönteminin temel yapısı esas alınarak birinci aşama denemeleriyle başlatılmıştır. Söz konusu denemeye ait sonuçlar, her bir eğitim-test oranı için en iyi hata metriklerini sağlayan model hiper parametreleri dikkate alınarak Çizelge 4.25’te verilmektedir. Buna göre, ham veri özelinde MAE ve MAPE hata

metriklerine göre en iyi performans 0,75:0,25 eğitim-test oranıyla, 14 girdi özeliğine ve 37 nörona sahip model ile elde edilmiştir. Öte yandan, MSE hata metriği açısından en başarılı sonuç yine 0,75:0,25 eğitim-test oranıyla ancak 13 girdi ve 39 nöron içeren modelde gözlemlenmiştir. Birinci dereceden fark alınmış veri setiyle yapılan özellik seçim sıralamasına göre yürütülen denemelerde, tüm performans metrikleri açısından en iyi sonuç 0,75:0,25 eğitim-test oranı, 13 girdi ve 36 nöronlu model ile elde edilmiştir.

Çizelge 4.25. MMS miktarı tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları

Veri tipi	Eğitim-test oranı	Özellik sayısı	Nöron sayısı	MAE	MAPE	MSE
Ham veri	0,25:0,75	14	31	7,015370	0,234423	125,662664
	0,25:0,75	11	29	6,829261	0,237422	118,650884
	0,25:0,75	8	26	7,297489	0,321144	111,283198
	0,50:0,50	14	36	6,056961	0,228930	93,946575
	0,50:0,50	13	39	6,090461	0,230995	93,433160
	0,75:0,25	14	37	4,566216	0,161143	58,115132
	0,75:0,25	13	39	4,651105	0,166784	57,836349
Fark alınmış veri	0,25:0,75	13	37	6,756837	0,234431	115,011195
	0,50:0,50	13	35	6,188773	0,233554	97,330290
	0,50:0,50	13	27	6,208602	0,237536	95,783438
	0,75:0,25	13	36	4,677138	0,167584	59,528083

Birinci aşama sonuçlarına göre, ham veri için en iyi sonuçlar iki farklı modelle (0,75:0,25 eğitim-test oranı ve 37 nöron; 0,75:0,25 eğitim-test oranı ve 39 nöron); fark verisi için ise tek bir modelle (0,75:0,25 eğitim-test oranı ve 36 nöron) elde edilmiştir. Bu modellerin ilgili hiper parametreleri sabit tutularak, MMS miktarı için yapılan özellik seçiminin model performansı üzerindeki etkisi Şekil 4.27’de incelenmiştir. Elde edilen bulgulara göre, modele eklenen özellik sayısı artışının genel olarak performans değerlerinde iyileşme sağladığı, ancak, özellikle girdi olarak 8 özelliğin kullanıldığı modelden sonra, performans artışlarının sınırlı düzeyde kaldığı ve belirgin bir iyileşmenin olmadığı görülmektedir.



Şekil 4.27. MMS miktarı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim

Birinci aşamada elde edilen 0,75:0,25 eğitim-test oranı, ham veri özelinde 13 ve 14 özellik içeren veri kümeleri, fark verisi özelinde ise 13 özellik içeren veri kümesi sabitlenerek toplamda üç farklı veri kümesi ile ikinci aşama denemelerine geçilmiştir. Bu aşamaya ait sonuçlar, kullanılan veri kümesi için her bir gizli katman ve epok sayısı denemesinde en iyi performansı sağlayan nöron sayısı dikkate alınarak Çizelge 4.26’da özet hâlinde verilmiştir. Bulgular, tüm performans metrikleri için en iyi sonuçların 0,75:0,25 eğitim-test oranı, 5 gizli katman, 300 epok kullanıldığında elde edildiğini göstermektedir. Spesifik olarak, MAE ve MSE hata metrikleri açısından en iyi sonuç ham veri, 14 özellik ve 40 nörona sahip model,

MAPE metriği açısından en iyi sonuç birinci dereceden farkı alınmış veri, 13 özellik ve 35 nörona sahip model ile üretilmiştir.


Çizelge 4.26. MMS miktarı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Veri tipi, eğitim-test oranı, özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAE	MAPE	MSE
Ham veri, 0,75:0,25, 13	1	37	300	4,220553	0,143585	49,659153
	1	39	300	4,019460	0,144100	42,301476
	2	38	200	3,416106	0,132188	28,272320
	2	39	200	3,475446	0,129976	30,302238
	2	40	200	3,375863	0,131321	28,301110
	2	34	300	2,583713	0,120530	12,172884
	3	38	200	2,629343	0,118582	13,968027
	3	39	200	2,455410	0,120745	10,978888
	3	35	300	2,087304	0,117185	7,241705
	3	38	300	2,142626	0,115346	8,134727
	3	40	300	2,067391	0,120499	7,274676
	4	38	200	2,262075	0,117360	8,915509
	4	39	200	2,198593	0,117192	8,922423
	4	23	300	2,117479	0,114915	7,914740
	4	34	300	2,040179	0,123663	7,063374
	5	33	200	2,098760	0,117837	7,572412
	5	37	200	2,054532	0,117001	7,578907
	5	27	300	1,874737	0,114637	6,160444
	5	34	300	1,920380	0,113667	6,259431
Ham veri, 0,75:0,25, 14	1	40	300	3,806094	0,136085	37,957540
	2	30	200	3,560808	0,130217	32,235686
	2	34	200	3,524058	0,138269	28,467873
	2	36	300	2,594070	0,117822	13,153050
	2	37	300	2,615687	0,123496	12,954266
	3	34	200	2,674307	0,118168	15,336499

Çizelge 4.26. (devam) MMS miktarı tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Ham veri, 0,75:0,25, 14	3	40	200	2,485936	0,121301	11,237977
	3	33	300	2,198560	0,114246	8,513224
	3	35	300	2,118735	0,114687	7,717902
	3	39	300	2,150814	0,120542	7,605011
	4	28	200	2,416053	0,113389	11,840048
	4	38	200	2,105272	0,118470	7,477682
	4	25	300	2,162644	0,112852	9,327525
	4	37	300	1,986691	0,120533	6,464569
	4	39	300	1,946047	0,116147	6,690539
	5	39	200	2,006736	0,114905	6,795845
	5	40	300	1,803905	0,113685	5,735837
Fark alınmış veri, 0,75:0,25, 13	1	32	300	4,186795	0,147386	47,353751
	1	34	300	4,127711	0,149010	45,555864
	2	39	200	3,260370	0,129683	25,229040
	2	31	300	2,933790	0,120378	18,817238
	2	33	300	2,639753	0,121158	13,017278
	3	36	200	2,520988	0,123224	11,882957
	3	35	300	2,171355	0,119905	7,990259
	3	39	300	2,176720	0,116045	8,394855
	4	25	200	2,322085	0,115856	10,123199
	4	39	200	2,184520	0,119981	7,953829
	4	26	300	2,174641	0,114389	9,702077
	4	32	300	1,995999	0,118997	6,812713
	4	36	300	2,003671	0,118301	6,772453
	5	34	200	2,046864	0,119615	7,376567
	5	38	200	2,088668	0,120772	7,338971
	5	40	200	2,078842	0,116610	7,678714
	5	35	300	1,869677	0,112305	47,353751

Gizli katman sayısı ile epok sayısının model performansına etkileri, ikinci aşama denemelerindeki en iyi sonuçların elde edildiği iki farklı model hiper parametreleri (ham veri, 0,75:0,25 eğitim-test oranı, 14 özellik, 40 nöron; birinci dereceden fark alınmış veri, 0,75:0,25 eğitim-test oranı, 13 özellik, 35 nöron) sabit tutularak incelenmiştir. Analize ait grafikler Şekil 4.28’de yer almakta olup ilgili grafiklerden genel olarak en başarılı sonuçların 300 epok ve 5 gizli katmana sahip modeller ile elde edildiği görülmektedir. Ayrıca, ikinci aşamadaki üç performans metriği özelinde de en iyi değerlere sahip sonuçların, epok ve nöron sayılarına göre değişimleri ise Ek-7-9’da yer almaktadır.




Şekil 4.28. Farklı gizli katman ve epok sayısı denemelerine göre MMS miktarı tahmininin performans değişimi

İkinci aşamada en iyi sonuçların iki farklı veri kümesi ile elde edilmesi dolayısıyla, üçüncü aşama denemeleri de ilgili veri kümeleriyle sürdürülmüştür. Spesifik olarak, 13 ve 14 özelliğe sahip veri kümeleri için 5 gizli katman, 300 epok ile üçüncü aşama denemeleri gerçekleştirilmiştir. Buna göre, çıktı katmanında kullanılan aktivasyon fonksiyonunun model performansı üzerindeki etkisinin incelendiği üçüncü aşama denemelerinden elde edilen en iyi sonuçlar Çizelge 4.27’de görülebilir. En iyi sonuçlar, sigmoid aktivasyon fonksiyonu kullanılan ikinci aşama denemelerinden elde edilen bulgulardır. Tüm performans metriklerinin en iyi sonuçları 5 gizli katman ve 300 epok hiper parametre değerleriyle üretilmiştir. Spesifik olarak, MAE ve MSE hata metriklerinde ham veri, 14 özellik ve 40 nöronlu model; MAPE hata metriğinde ise fark verisi, 13 özellik ve 35 nöronlu model en iyi performansı göstermiştir.

Çizelge 4.27. MMS miktarı tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları

Aktivasyon fonksiyonu	Özellik sayısı	Gizli katman sayısı	Nöron sayısı	MAE	MAPE	MSE
Doğrusal	13	5	32	2,338509	0,126312	10,481287
Doğrusal	13	5	25	2,119208	0,127360	8,179216
Doğrusal	14	5	33	2,164819	0,125881	7,958102
ReLU	13	5	19	2,276436	0,131975	9,259807
ReLU	14	5	27	3,572912	0,157935	69,568137
ReLU	14	5	36	3,375321	0,158986	68,189297
Tanh	13	5	26	1,951083	0,122553	6,495129
Tanh	13	5	39	1,838874	0,124686	6,151942
Tanh	14	5	14	2,313624	0,121679	10,100383
Tanh	14	5	34	1,819292	0,122137	5,808139
Sigmoid	13	5	35	1,869677	0,112305	47,353751
Sigmoid	14	5	40	1,803905	0,113685	5,735837

Üçüncü aşama denemelerinden elde edilen hata metriklerinin en iyi değerlerine ait parametreler (MAE ve MSE hata metrikleri için, ham veri, 0,75:0,25 eğitim-test oranı, 14 özellik, 5 gizli katman, 300 epok; MAPE hata metriği için ise, fark verisi, 0,75:0,25 eğitim-test oranı, 13 özellik, 5 gizli katman, 300 epok) sabit tutularak, aktivasyon fonksiyonlarının model performansına etkisinin incelendiği grafikler Şekil 4.29'da yer almaktadır. İlgili grafiklerden, her üç performans metriğinde de doğrusal, sigmoid ve tanh aktivasyon fonksiyonlarının birbirine yakın sonuçlar ürettiği, ReLU aktivasyon fonksiyonunun ise genellikle daha dalgalı bir yapı sergilediği ve diğer aktivasyon fonksiyonlarından daha farklı değerler ortaya koyduğu görülebilir. Ayrıca, genel olarak, nöron sayısı artışının bir önceki nöronlardan elde edilen değerlere göre iyileşme sağladığı görülse de özellikle 27 nörondan sonra performanslardaki iyileşme daha sınırlıdır.



Şekil 4.29. Aktivasyon fonksiyonlarının MMS miktarının tahmin performansına etkisi

Modellerin karşılaştırılması

MMS miktarı tahmini için kurulan ARIMA, çift üstel düzeltme ve YSA yöntemlerinin MAE, MAPE ve MSE hata ölçüt metriklerindeki en iyi performanslarına ait karşılaştırmalara Şekil 4.30’da yer verilmektedir. Buna göre, söz konusu modellerden ARIMA metodu ile YSA’nın birbirlerine yakın performans sergilediği, çift üstel düzeltme yönteminin ise diğer iki modele kıyasla daha düşük performans gösterdiği görülmektedir.



Şekil 4.30. MMS miktarı tahmin modellerinin karşılaştırılması


Her hata metriği için ayrı olacak şekilde, üç yöntemin en iyi model performanslarına uygulanan Kruskal-Wallis testine ait sonuçlar Çizelge 4.28’de görülmektedir. Buna göre, MAE ve MAPE hata metrikleri için ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık göstermektedir. Bu farklılıkların hangi gruplar arasında olduğunun belirlenebilmesi için ise, ikili karşılaştırmalar yapılarak sürece devam edilmiştir. Yapılan testler sonucunda, ilgili performans metrikleri açısından ARIMA modelinin yalnızca çift üstel düzeltme modeline kıyasla anlamlı düzeyde farklı sonuçlar ürettiği; YSA modelinin ise ARIMA ve çift üstel düzeltme modellerine kıyasla anlamlı düzeyde farklı sonuçlar ürettiğine dair yeterli kanıtın

bulunmadığı görülmüştür. MSE performans metriği açısından ise, ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımlarının konum açısından farklılık gösterdiğine dair yeterli kanıt bulunmamıştır. Bu bulgular, MMS miktarının tahmininde ARIMA model performansının sadece çift üstel düzeltme modeline göre belirgin şekilde farklı olduğu, YSA modelinin ise ARIMA ve çift üstel düzeltme modeli ile benzer performansa sahip olduğu şekliyle yorumlanabilir.


Çizelge 4.28. MMS miktarı tahmini için yapılan Kruskal-Wallis testine ait sonuçlar

Performans metriği	Karşılaştırılan modeller	Test istatistiği	<i>p</i> -değeri
MAE	ARIMA-DES-YSA	6,4390	0,0400
	ARIMA-DES	5,3365	0,0209
	ARIMA-YSA	1,7071	0,1914
	DES- YSA	1,7907	0,1808
MAPE	ARIMA-DES-YSA	6,3886	0,0410
	ARIMA-DES	5,3365	0,0209
	ARIMA-YSA	1,3011	0,2540
	DES- YSA	1,8669	0,1718
MSE	ARIMA-DES-YSA	5,2370	0,0729


En iyi performans metriklerinin elde edildiği modellerle üretilen tahminlere ait karşılaştırmalar Şekiller 4.31-4.33'te sunulmuştur. Grafiklerden ARIMA, YSA ve çift üstel düzeltmenin tüm hata metrikleri açısından trend tahmininde başarılı olduğu görülmektedir. Kısa vadeli dalgalanmalar dikkate alındığında ise, ARIMA'nın diğer yöntemlere kıyasla daha başarılı olduğu sonucuna ulaşılabilir. Genel olarak bakıldığında, YSA daha esnek ve güçlü bir modelleme yaklaşımı sunsa da ARIMA yönteminin daha basit bir yapıya sahip olması, MMS miktarının tahmininde tercih edilebilir bir alternatif olmasına neden olmaktadır.



Şekil 4.31. En iyi MAE metriği sonucunun elde edildiği hiper parametrelerle üretilen MMS miktarı tahminlerinin karşılaştırılması



Şekil 4.32. En iyi MAPE metriği sonucunun elde edildiği hiper parametrelerle üretilen MMS miktarı tahminlerinin karşılaştırılması



Şekil 4.33. En iyi MSE metriği sonucunun elde edildiği hiper parametrelerle üretilen MMS miktarı tahminlerinin karşılaştırılması

4.5. SMS Miktarı

Bu tez kapsamında ele alınan metodoloji, [84]'te SMS miktarının tahminine yönelik yapılan çalışmada da uygulanmıştır. Ancak söz konusu çalışmadaki sonuçların değerlendirilmesi sadece MAPE ve MSE hata metrikleri kullanılarak yapılmıştır. Bu bakımdan bu bölümde, MAE hata metriği açısından elde edilen bulgulara ve ilgili çalışmada bulunmayan bölümlere yer verilmektedir.

4.5.1. Özellik seçimi

SMS miktarına ilişkin özellik seçim sürecinin ilk adımı olarak, girdi olması düşünülen bu özelliklerin SMS miktarını açıklamada istatistiksel olarak anlamlı olup olmadıklarının tespiti için regresyon analizine başvurulmuş ve her bir özelliğin p -değeri hesaplanmıştır. Hesaplanan p -değerlerine ilişkin sonuçlar Çizelge 4.29'da sunulmuştur. Analiz sonucunda, 16 özellikten yalnızca 6 numaralı İlkokul Mezunu kişi sayısı özelliğinin p -değeri 0,01'den büyük çıkmıştır. Bu duruma istinaden, 6. özellik haricindeki diğer özelliklere ait hipotezler reddedilmiş ancak, H_{046} 'nın reddedilebilmesi için yeterli kanıtın olmadığı görülmüştür. Analiz sonucunda, ilgili özelliğin bağımlı değişken üzerinde anlamlı bir etkisi olmadığı değerlendirilmiş ve YSA modeline dâhil edilmemiştir.

Çizelge 4.29. SMS miktarı tahmini için regresyon ve YSA modellerinde kullanılan özellikler ile numaralandırmaları

Regresyon özellik sıralaması	Özellikler	p -değerleri	H_{04n} kararı	Sonuç	YSA özellik sıralaması
1	Mobil abone sayısı	0,0000	Ret	Anlamlı	1
2	2G ve 3G abone sayısı	0,0000	Ret	Anlamlı	2
3	H-TÜFE	0,0000	Ret	Anlamlı	3
4	Okuma yazma bilmeyen kişi sayısı	0,0000	Ret	Anlamlı	4
5	Okuma yazma bilen fakat bir okul bitirmeyen kişi sayısı	0,0000	Ret	Anlamlı	5
6	İlkokul mezunu kişi sayısı	0,0113	Yeterli kanıt yok.	Anlamlı değil.	-
7	Orta okul veya dengi mezunu kişi sayısı	0,0000	Ret	Anlamlı	6
8	İlköğretim mezunu kişi sayısı	0,0000	Ret	Anlamlı	7
9	Lise veya dengi meslek okulu mezunu kişi sayısı	0,0000	Ret	Anlamlı	8
10	Yüksek okul veya fakülte mezunu kişi sayısı	0,0000	Ret	Anlamlı	9
11	Yüksek lisans mezunu kişi sayısı	0,0000	Ret	Anlamlı	10
12	Doktora mezunu kişi sayısı	0,0000	Ret	Anlamlı	11
13	Eğitim durumu bilinmeyen kişi sayısı	0,0000	Ret	Anlamlı	12
14	SMS ve MMS gelir oranı	0,0000	Ret	Anlamlı	13
15	Mobil genişbant abone sayısı	0,0000	Ret	Anlamlı	14
16	Zamansal sıra	0,0000	Ret	Anlamlı	15

4.5.2. Yöntem

SMS miktarının tahmini için “4.1.3 Yöntem” bölümünde de değinilen ARIMA, çift üstel düzeltme ve YSA yöntemleri kullanılmıştır.

ARIMA

Çalışmanın “4.1.3 Yöntem” bölümünde yer verilen metodoloji uygulanarak ARIMA (1,1,0) modeli kullanılmasına karar verilmiştir. Eğitim-test oranı denemelerinde MAE metriği için elde edilen sonuçlar Çizelge 4.30’da yer almakta olup en iyi değer 0,75:0,25 eğitim-test oranı ile üretilmiştir.

Çizelge 4.30. SMS miktarının tahmininde ARIMA (1,1,0) modelinin farklı eğitim-test oranındaki deneme sonuçları

Eğitim-Test	MAE
0,25:0,75	26 924
0,50:0,50	12 487
0,75:0,25	4074

Çift üstel düzeltme

SMS miktarının tahmininde uygulanan çift üstel düzeltme yöntemine ait analiz sonuçları, α ’nın her değeri için en iyi MAE hata metriğinin elde edildiği β değerleri olacak şekilde özetlenerek Çizelge 4.31’de verilmiştir. Buna göre, en iyi sonuç MAE metriğinde $\alpha=0,8$ ve $\beta=0,2$ değerleriyle elde edilmiştir.

Çizelge 4.31. SMS miktarı tahmini için α değerlerine göre en iyi çift üstel düzeltme yöntemi MAE hata metriği sonuçları

α	β	MAE
0,1	0,3	4223
0,2	0,9	2617
0,3	0,9	2070
0,4	0,6	1843
0,5	0,9	1688
0,6	0,3	1596
0,7	0,2	1538
0,8	0,2	1487
0,9	0,2	1502


Yapay sinir ağıları

SMS miktarının YSA kullanılarak tahmin edilmesine yönelik süreç, raporun “4.1.3 Yöntem” bölümünde detaylandırılan YSA yönteminin temel yapısı esas alınarak birinci aşama denemeleriyle başlatılmıştır. Söz konusu denemenin sonuçları, her bir eğitim-test oranı için en iyi MAE hata metrik değerini sağlayan model hiper parametreleri dikkate alınarak Çizelge 4.32’de verilmektedir. Buna göre, ilgili metriğe göre en iyi performans ham veri özelinde 0,50:0,50 eğitim-test oranıyla, 15 girdi özeliğine ve 38 nörona sahip model ile; fark verisi özelinde ise 0,50:0,50 eğitim-test oranıyla, 13 girdi özeliğine ve 39 nörona sahip model ile elde edilmiştir.

Çizelge 4.32. SMS miktarının tahmininde YSA yöntemine ait birinci aşamanın en iyi MAE metriği sonuçları

Veri tipi	Eğitim-test oranı	Özellik sayısı	Nöron sayısı	MAE
Ham veri	0,25:0,75	14	31	2608
	0,25:0,75	15	24	2680
	0,25:0,75	15	36	2679
	0,50:0,50	15	38	2105
	0,75:0,25	15	37	2140
Fark alınmış veri	0,25:0,75	11	37	2414
	0,25:0,75	12	34	2397
	0,50:0,50	13	39	2155
	0,50:0,50	14	31	2161
	0,50:0,50	14	39	2184
	0,75:0,25	12	33	2170
	0,75:0,25	14	38	2290

Birinci aşamadan elde edilen MAE sonuçlarına göre iki farklı model (0,50:0,50 eğitim test oranı, 38 nöron ve 0,50:0,50 eğitim test oranı 39 nöron) [84]’teki yapılan çalışmaya eklenmiş ve tüm modellerin ilgili hiper parametreleri sabit tutularak, SMS miktarı için yapılan özellik seçiminin model performansı üzerindeki etkisi Şekil 4.34’te incelenmiştir.



Şekil 4.34. SMS miktarı tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim

Birinci aşamadan elde edilen 5 farklı veri kümesi sabitlenerek ikinci aşama denemeleri gerçekleştirilmiştir. Bu aşamaya ait sonuçlar, kullanılan veri kümesi için her bir gizli katman ve epok sayısı denemesinde en iyi performansı sağlayan nöron sayısı dikkate alınarak Çizelge 4.33'te özet hâlinde verilmiştir. MAE hata metriği açısından fark verisi, 0,50-0,50 eğitim-test oranı, 13 özellik, 3 gizli katman, 300 epok ve 24 nörona sahip model daha iyi performans göstermiştir.

Çizelge 4.33. SMS miktarının tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Veri tipi, eğitim-test oranı, özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAE	MAPE	MSE
Ham veri, 0,50:0,50 15	1	33	300	1850	0,078684	5 928 469
	2	34	200	1912	0,080297	6 297 625
	2	38	200	1864	0,081305	5 784 359
	2	37	300	1781	0,075219	5 303 232
	3	35	200	1774	0,075712	5 162 024
	3	38	200	1817	0,075380	5 792 114
	3	25	300	1767	0,074392	5 269 402
	3	39	300	1763	0,076824	4 966 323
	4	39	200	1767	0,074770	5 126 512
	4	31	300	1754	0,075990	4 737 349
	4	34	300	1740	0,074595	4 955 357
	5	30	200	1766	0,075167	5 035 763
	5	23	300	1786	0,076028	5 151 390
	5	35	300	1771	0,078206	4 832 972
Ham veri, 0,75:0,25, 15	1	20	300	2286	0,098135	8 255 654
	1	30	300	2223	0,099747	7 139 096
	2	34	200	2085	0,092215	6 876 626
	2	40	200	2077	0,092735	6 680 840
	2	26	300	2012	0,091175	6 072 133
	3	24	200	2032	0,091578	6 231 353
	3	37	300	2075	0,096836	6 466 148
	4	31	200	2065	0,094882	6 513 967
	4	20	300	2131	0,098618	6 773 953
	4	32	300	2104	0,100089	6 306 123
	5	35	200	2006	0,093087	6 110 056
	5	10	300	2190	0,101317	6 886 820
	5	20	300	2150	0,102933	6 780 095

Çizelge 4.33. (devam) SMS miktarının tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları


Fark alınmış veri, 0,50:0,50 13	1	38	300	1895	0,080407	6 340 037
	2	34	200	1895	0,082109	5 943 865
	2	39	200	1950	0,080608	6 753 689
	2	27	300	1820	0,076708	5 624 040
	2	39	300	1765	0,076763	5 065 417
	3	39	200	1749	0,074330	5 131 660
	3	24	300	1732	0,074029	4 977 440
	4	32	200	1863	0,076475	5 847 710
	4	39	200	1794	0,076941	5 206 270
	4	28	300	1752	0,076152	4 947 906
	5	32	200	1823	0,079036	5 282 785
	5	37	200	1814	0,076042	5 467 544
	5	19	300	1770	0,075445	5 037 392
	5	31	300	1754	0,076286	4 940 822
	5	33	300	1781	0,077650	4 905 387
Fark alınmış veri, 0,50:0,50, 14	1	38	300	1858	0,079273	5 995 044
	2	40	200	1818	0,075973	5 749 600
	2	36	200	1856	0,081801	5 668 842
	2	38	300	1760	0,074658	5 104 798
	3	34	200	1803	0,076830	5 372 284
	3	38	300	1755	0,073757	5 143 250
	4	33	200	1814	0,075086	5 630 001
	4	35	200	1786	0,075173	5 355 797
	4	40	200	1802	0,077054	5 131 178
	4	31	300	1733	0,074982	4 814 042
	4	36	300	1743	0,074951	4 786 122
	5	29	200	1802	0,075691	5 510 914
	5	38	200	1794	0,075866	5 092 965

Çizelge 4.33. (devam) SMS miktarının tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Fark alınmış veri, 0,50:0,50, 14	5	24	300	1764	0,075326	5 137 498
	5	40	300	1744	0,077363	4 638 883
Fark alınmış veri, 0,75:0,25, 12	1	27	300	2129	0,092783	7 101 385
	1	33	300	2142	0,092442	7 158 851
	1	40	300	2156	0,096423	7 006 669
	2	39	200	2030	0,090776	6 428 311
	2	34	300	2073	0,093745	6 437 627
	2	27	300	2048	0,094462	6 425 916
	3	19	200	2103	0,092321	6 817 775
	3	35	200	2009	0,093674	6 025 971
	3	13	300	2109	0,095408	6 723 493
	3	22	300	2099	0,096771	6 491 928
	3	38	300	2093	0,098704	6 662 756
	4	14	200	2124	0,095380	7 036 219
	4	27	200	2060	0,096205	6 294 917
	4	13	300	2109	0,096092	6 611 422
	4	21	300	2052	0,096793	6 207 855
	4	40	300	2044	0,098057	6 332 241
	5	18	200	2086	0,092925	6 722 284
	5	28	200	2052	0,095748	6 291 052
	5	35	200	2078	0,098586	6 265 286
	5	33	300	2055	0,096703	6 483 223

Gizli katman sayısı ile epok sayısının model performansına etkileri, ikinci aşama denemelerindeki en iyi sonuçların elde edildiği üç farklı model hiper parametreleri (fark alınmış veri, 0,50:0,50 eğitim-test oranı, 13 özellik, 24 nöron; fark alınmış veri, 0,50:0,50 eğitim-test oranı, 14 özellik, 38 nöron; fark alınmış veri, 0,50:0,50 eğitim-test oranı, 14 özellik, 40 nöron) sabit tutularak incelenmiştir. Analize ait grafikler Şekil 4.35'te yer almakta olup ilgili grafiklerden genel olarak en başarılı sonuçların 300 epok, 3 veya 5 gizli

katmana sahip modeller ile elde edildiği görülmektedir. Ayrıca, ikinci aşamadaki üç performans metriği özelinde de en iyi değerlere sahip sonuçların, epok ve nöron sayılarına göre değişimleri ise Ek-10'da yer almaktadır.




Şekil 4.35. Farklı gizli katman ve epok sayısı denemelerine göre SMS miktarı tahmininin performans değişimi

İkinci aşamada en iyi sonuçların fark verisiyle yapılan özellik seçimi sıralamasının kullanıldığı iki farklı veri kümesi ile elde edilmesi dolayısıyla, üçüncü aşama denemeleri de ilgili veri kümeleriyle sürdürülmüştür. Spesifik olarak, 13 özelliğe sahip veri kümesi için 3 gizli katman ve 300 epok; 14 özelliğe sahip veri kümesi için ise 3 ve 5 gizli katman, 300 epok ile üçüncü aşama denemeleri gerçekleştirilmiştir. Buna göre, çıktı katmanında kullanılan aktivasyon fonksiyonunun model performansı üzerindeki etkisinin incelendiği üçüncü aşama denemelerinden elde edilen en iyi MAE metriği sonuçları Çizelge 4.34'te görülmektedir. MAE hata metriği açısından en iyi değer doğrusal aktivasyon fonksiyonu ile elde edilmiştir.

Çizelge 4.34. SMS miktarının tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları

Aktivasyon fonksiyonu	Özellik sayısı	Gizli katman sayısı	Nöron sayısı	MAE	MAPE	MSE
ReLU	13	3	37	1828	0,085955	5 198 441
ReLU	14	3	20	1796	0,081685	4 971 176
ReLU	14	5	15	3648	0,135647	6 377 473
Tanh	13	3	25	1937	0,078014	6 284 251
Tanh	13	3	39	1898	0,081659	5 880 896
Tanh	14	3	12	1947	0,077469	6 858 741
Tanh	14	3	38	1878	0,081454	5 714 426
Tanh	14	5	33	1853	0,077708	5 885 620
Tanh	14	5	39	1822	0,080609	5 298 009
Doğrusal	13	3	31	1665	0,073503	4 371 489
Doğrusal	14	3	27	1709	0,072853	4 888 124
Doğrusal	14	3	40	1650	0,074697	4 196 943
Doğrusal	14	5	27	1751	0,076807	5 006 053
Doğrusal	14	5	32	1715	0,078543	4 678 437
Doğrusal	14	5	39	1725	0,080796	4 490 899


Üçüncü aşama denemelerinden elde edilen en iyi MAE hata metrik değerine sahip modelin parametreleri (fark verisi, 14 özellik, 3 gizli katman, 300 epok) sabit tutularak, aktivasyon fonksiyonlarının model performansına etkisinin incelendiği grafikler Şekil 4.36'da yer almaktadır. İlgili grafikten, her üç performans metriğinde de doğrusal, sigmoid, tanh aktivasyon fonksiyonlarının birbirine yakın sonuçlar ürettiği, ReLU aktivasyon fonksiyonunun ise genellikle daha dalgalı bir yapı sergilediği ve diğer aktivasyon fonksiyonlarından daha farklı değerler ortaya koyduğu görülebilir. Ayrıca genel olarak, nöron sayısı artışının bir önceki nörondan elde edilen değerlere göre iyileşme sağladığı görülse de özellikle 12 nörondan sonra performanslardaki iyileşme daha sınırlıdır.



Şekil 4.36. Aktivasyon fonksiyonlarının SMS miktarı tahmin performansına MAE hata metriği özelindeki etkisi

Modellerin karşılaştırılması

MMS miktarı tahmini için kurulan ARIMA, çift üstel düzeltme ve YSA yöntemlerinin MAE hata ölçüt metriğindeki en iyi performanslarına ait karşılaştırmalarına Şekil 4.37’de yer verilmektedir. Buna göre, söz konusu modellerden çift üstel düzeltme ve YSA’nın birbirlerine yakın performans sergilediği, ARIMA modelinin ise diğer iki modele kıyasla daha düşük performans gösterdiği görülmektedir.




Şekil 4.37. MAE hata metriği açısından SMS miktarı tahmin modellerinin karşılaştırılması

MAE hata metriği için, üç yöntemin en iyi model performanslarına uygulanan Kruskal-Wallis testine ait sonuçlar Çizelge 4.35'te görülmektedir. Elde edilen bulgular H_0 hipotezinin reddedilmesine yol açmıştır. Buna göre, MAE performans metriği açısından ARIMA, çift üstel düzeltme ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık göstermektedir. Bu farklılıkların hangi gruplar arasında olduğunun belirlenebilmesi için ise, ikili karşılaştırmalar yapılarak sürece devam edilmiştir. Yapılan testler sonucunda, MAE performans metriği açısından ARIMA modelinin çift üstel düzeltme ve YSA modellerine kıyasla anlamlı düzeyde farklı sonuçlar ürettiği; çift üstel düzeltme ve YSA modelleri arasında ise anlamlı düzeyde farklı sonuçlar üretildiğine dair yeterli kanıtın bulunmadığı görülmüştür. Bu bulgular, SMS miktarının tahmininde ARIMA model performansının diğer iki modele göre belirgin şekilde farklı olduğunu, çift üstel düzeltme ve YSA'nın ise benzer performansa sahip olduğunu ortaya koymaktadır.

Çizelge 4.35. SMS miktarının tahmini için yapılan Kruskal-Wallis testine ait sonuçlar

Performans metriği	Karşılaştırılan modeller	Test istatistiği	<i>p</i> -değeri
MAE	ARIMA-DES-YSA	20,4417	0,0000
	ARIMA-DES	18,1691	0,0000
	ARIMA-YSA	15,4006	0,0001
	DES- YSA	0,8407	0,3592

En iyi performans metriklerinin elde edildiği modellerle üretilen tahminlere ait karşılaştırmalar ARIMA'nın düşük performansı dikkate alınarak sadece çift üstel düzeltme ve YSA için yapılmıştır. Şekil 4.38'de yer alan grafikten YSA ve çift üstel düzeltme yöntemlerinin MAE hata metriği açısından trend tahmininde başarılı bir performans sergilediği görülmektedir. Kısa vadeli dalgalanmalar dikkate alındığında ise, YSA'nın çift üstel düzeltme yöntemine kıyasla daha başarılı olduğu sonucuna ulaşılabilir. Genel olarak bakıldığında, YSA daha esnek ve güçlü bir modelleme yaklaşımı sunsa da çift üstel düzeltme yönteminin daha basit bir yapıya sahip olması SMS miktarının tahmininde tercih edilebilir bir alternatif olmasına neden olmaktadır.




Şekil 4.38. En iyi MAE hata metrik sonucunun elde edildiği hiper parametrelerle üretilen SMS miktarı tahminlerinin karşılaştırılması

4.6. Mobil ses trafik hacmi

Bu bölümde, mobil ses trafik hacmi özelinde gerçekleştirilen çalışmalar veri kümesi, özellik seçimi ve yöntem alt başlıkları altında detaylı olarak ele alınacaktır.

4.6.1. Veri kümesi

Mobil ses trafik hacmi, üç mobil işletmecinin şebekelerinde başlatılan ses trafiğinin dakika olarak toplamını ifade etmektedir. Mobil ses trafik hacmine ilişkin tahminler, 2009 yılı 1. çeyreğinden başlayıp 2023 yılı 4. çeyreğine kadar olan dönemi kapsayan ve toplam 60 adet gözlemden oluşan veri seti kullanılarak yapılmıştır. Şekil 4.39'da Türkiye'deki mobil ses trafik hacminin çeyrek dönemler itibarıyla zamansal değişimi yer almaktadır. Veriler, ilgili göstergenin zaman içerisinde artış eğilimi sergilediğini ve düzenli aralıklarla tekrar eden mevsimsel dalgalanma yapısına sahip olduğunu göstermektedir.



Şekil 4.39. Mobil ses trafik hacminin zaman serisi grafiği

4.6.2. Özellik seçimi

Mobil ses trafik hacminin tahmininde, “4.1.3 Yöntem” bölümünde ayrıntılı olarak ele alınan YSA yönteminden ve Holt-Winters ile SARIMA metotlarından yararlanılmıştır. Bu doğrultuda, bu yöntemler için girdi olarak kullanılan özellikler birbirinden farklılıklar içermektedir. Nitekim, Holt-Winters ve SARIMA yöntemlerinde özellik olarak mobil ses trafik hacmi verisi kullanılmış, YSA ile oluşturulan modellerde ise 17 adet özellikten yararlanılmıştır. Mobil ses trafik hacmi için YSA özelinde kullanılan özelliklerden:

- H-TÜFE, haberleşme sektöründe gerçekleşen fiyatların mobil abonelikleri ve dolayısıyla mobil ses trafik hacmini etkileyebileceği;
- mobil yatırım, işletmecilerin yapacakları yatırımlar ile sunulacak hizmet kalitesinin yükselebileceği ve bu doğrultuda mobil ses trafik hacminin de artabileceği;
- ulusal eğitim istatistikleri, eğitim durumuna göre bireylerin sahip oldukları mobil abonelik sayılarında farklılık oluşabileceği ve bireylerin haberleşme tercihlerinde değişiklikler meydana gelebileceği;
- SMS ve MMS miktarları, kişilerin ilgili teknolojik haberleşme araçlarını tercih etmeleri mobil ses trafik hacminin azalmasına sebebiyet verebileceği ve dolayısıyla aralarında tercih edilme anlamında bir ilişki olabileceği;
- AR-GE faaliyetleri için ulaştırma/ haberleşme harcamaları, yapılan harcamaların haberleşme altyapısında iyileştirmeler sağlayabileceği, yeni teknolojilerin (geçmişte 2G,

3G, 4.5G teknolojileri, gelecekte ise 5G ve ötesi teknolojilerin) devreye alınabileceği ve bu gelişmelerin mobil ses trafik hacmini etkileyebileceği;

- Mobil işletmecilerin konuşma gelirleri oranı, işletmelerin gelir oranı gibi stratejilerini önceden belirleyebilecekleri ve hangi gelir türünün kendileri için daha önemli olduğuna karar verip yatırımlarını bu doğrultuda yapabilecekleri;
- mobil abone sayısı, mobil aboneliğe sahip bireylerin mobil ses trafik hacminin oluşmasına etki edebileceği;

düşünceleriyle,

- zamansal sıra ise mobil ses trafik hacminin bir zaman serisi olması nedeniyle seçilmiştir (Bkz. Çizelge 4.36).


Mobil ses trafik hacmine ilişkin özellik seçim sürecinin ilk adımı olarak, girdi olması düşünülen özelliklerin mobil ses trafik hacmini açıklamada istatistiksel olarak anlamlı olup olmadıklarının tespiti regresyon analizi ile yapılmış ve her bir özelliğin p -değeri hesaplanmıştır. Bu kapsamda, hesaplanan p -değerlerine ilişkin sonuçlar Çizelge 4.36'da sunulmuştur. Analiz sonucunda, 18 özellikten yalnızca 5 numaralı İlkokul Mezunu kişi sayısı özelliğinin p -değeri 0,01'den büyük çıkmıştır. Bu duruma istinaden, 5. özellik haricindeki diğer özelliklere ait hipotezler reddedilmiş ancak, H_{055} 'in reddedilebilmesi için yeterli kanıtın olmadığı görülmüştür. Analiz sonucunda, ilgili özelliğin bağımlı değişken üzerinde anlamlı bir etkisi olmadığı değerlendirilmiş ve YSA modeline dâhil edilmemiştir.

Çizelge 4.36. Mobil ses trafik hacmi tahmini için YSA ve regresyon modellerinde kullanılan özellikler ile numaralandırmaları

Regresyon için özellik sıralaması	Özellikler	p -değerleri	H_{05n} kararı	Sonuç	YSA özellik sıralaması
1	H-TÜFE	0,0000	Ret	Anlamlı	1
2	Mobil yatırım değerleri	0,0001	Ret	Anlamlı	2
3	Okuma yazma bilmeyen kişi sayısı	0,0000	Ret	Anlamlı	3
4	Okuma yazma bilen fakat bir okul bitirmeyen kişi sayısı	0,0000	Ret	Anlamlı	4
5	İlkokul mezunu kişi sayısı	0,1588	Yeterli kanıt yok.	Anlamlı değil.	-
6	Orta okul veya dengi mezunu kişi sayısı	0,0000	Ret	Anlamlı	5
7	İlköğretim mezunu kişi sayısı	0,0000	Ret	Anlamlı	6
8	Lise veya dengi meslek okulu mezunu kişi sayısı	0,0000	Ret	Anlamlı	7
9	Yüksek okul veya fakülte mezunu kişi sayısı	0,0000	Ret	Anlamlı	8
10	Yüksek lisans mezunu kişi sayısı	0,0000	Ret	Anlamlı	9
11	Doktora mezunu kişi sayısı	0,0000	Ret	Anlamlı	10
12	Eğitim durumu bilinmeyen kişi sayısı	0,0000	Ret	Anlamlı	11
13	SMS miktarı	0,0000	Ret	Anlamlı	12
14	MMS miktarı	0,0000	Ret	Anlamlı	13
15	AR-GE faaliyetleri için ulaştırma/ haberleşme harcamaları	0,0000	Ret	Anlamlı	14
16	Mobil işletmecilerin konuşma gelirleri oranı	0,0000	Ret	Anlamlı	15
17	Mobil abone sayısı	0,0000	Ret	Anlamlı	16
18	Zamansal sıra	0,0000	Ret	Anlamlı	17

Regresyon analizi sonucunda anlamlı bulunan 17 özellikle RFE yönteminin kullanıldığı özellik seçim sürecine başlanmış ve ham veri ve fark verisi için Şekil 4.40'ta yer alan sıralamalar elde edilmiştir. Buna göre, 16 özellikli modelde ham veri için 2. özellik, fark

verisi için ise 4. özellik çıkarılarak veri kümeleri oluşturulmuştur. Bu süreç her adımda Şekil 4.40'ta verilen sıralamaya bağlı olarak bir özelliğin elenmesiyle devam ettirilmiş ve tek bir özellik kalana kadar sürdürülmüştür.



Şekil 4.40. Ham veri ile uygulanan RFE yöntem sonucuna göre mobil ses trafik hacmi tahminindeki özelliklerin elenme sırası

4.6.3. Yöntem

Mobil ses trafik hacminin tahmini için Holt-Winters, SARIMA ve YSA yöntemleri kullanılmıştır.

Holt-Winters

Mobil ses trafik hacminin incelenen dönemde artış eğilimli ve mevsimsel özellikli zaman serisi yapısı nedeniyle tercih edilen tahmin yöntemlerinden biri Holt-Winters yöntemidir. İlgili yöntemde gerçekleştirilen hesaplamalar, raporun “3.2.1 Zaman serileri analizi”

bölümünde ayrıntılı olarak açıklanan yöntem kapsamında, Eş. 3.5-3.8’de verilen formüller kullanılarak yapılmıştır. Hesaplamalarda mevsimsel uzunluk (N) değeri 4 çeyrek dönem olarak alınmıştır. α , β ve γ değerleri $[0,1, 1)$ aralığında 0,1’lik artışlarla denenerek MAE, MAPE ve MSE hata metrikleri hesaplanmıştır. Çalışma kapsamındaki ilgili yönteme ait adımları özetleyen sözde kod ise Çizelge 4.37’de verilmiştir.

Çizelge 4.37. Holt-Winters yöntemi sözde kodu

Veri kümesini yükle.
Başlangıç değerlerini ilk 8 gözleme göre hesapla.
 $0,1 \leq \beta < 1$ için 0,1’lik artışla:
 $0,1 \leq \alpha < 1$ için 0,1’lik artışla:
 $0,1 \leq \gamma < 1$ için 0,1’lik artışla:
 Her $t \in \{9,10, \dots, n\}$ için:
 S_t değerini Eş. (3.5) ile hesapla.
 G_t değerini Eş. (3.6) ile hesapla.
 c_t değerini Eş. (3.7) ile hesapla.
 $F_{t,t+\tau}$ değerini Eş. (3.8) ile hesapla.
Her (α, β, γ) denemesi için MAE, MAPE ve MSE performans metriklerini hesapla.
En iyi MAE, MAPE ve MSE performans metrikleri ile üretilen tahminleri yaz.

İlgili yönteme ait analiz sonuçları her α değeri için en iyi hata metriklerinin elde edildiği β , γ değerleri için; her β değeri için en iyi hata metriklerinin elde edildiği α , γ değerleri için; her γ değeri için en iyi hata metriklerinin elde edildiği α ve β değerleri için özet hâlinde Çizelge 4.38’de verilmiştir. Buna göre; en iyi sonuçlar tüm hata metriklerinde $\alpha = 0,2$, $\beta = 0,6$ ve $\gamma = 0,9$ değerleriyle elde edilmiştir.

Çizelge 4.38. Mobil ses trafik hacmi tahmini için α , β ve γ değerlerine göre en iyi Holt-Winters yöntemi sonuçları

α	β	γ	MAE	MAPE	MSE
Her α değeri için en iyi β ve γ değerleri					
0,1	0,9	0,9	1,735519	0,031063	7,225212
0,2	0,6	0,9	1,232470	0,019372	3,186562
0,3	0,6	0,8	1,358867	0,023114	3,387072

Çizelge 4.38. (devam) Mobil ses trafik hacmi tahmini için α , β ve γ değerlerine göre en iyi Holt-Winters yöntemi sonuçları

0,3	0,6	0,7	1,362640	0,023130	3,367673
0,4	0,3	0,6	1,676523	0,033022	7,203602
0,4	0,5	0,3	1,842799	0,035345	5,864709
0,5	0,2	0,6	1,928598	0,039191	8,952077
0,5	0,4	0,1	2,306990	0,041846	7,157253
0,6	0,1	0,6	2,139409	0,043225	10,213113
0,6	0,3	0,1	2,422124	0,043363	8,101646
0,7	0,1	0,1	2,477981	0,044955	9,284024
0,7	0,3	0,1	2,521820	0,043933	8,983999
0,7	0,2	0,1	2,509432	0,044475	8,829260
0,8	0,1	0,1	2,489972	0,044041	9,141399
0,8	0,2	0,1	2,529655	0,043743	9,053550
0,9	0,1	0,1	2,399711	0,041764	8,577398
0,9	0,2	0,1	2,435657	0,041488	8,643039
Her β değeri için en iyi α ve γ değerleri					
0,4	0,1	0,9	1.924902	0,038107	8.444139
0,3	0,1	0,9	2.121594	0,041849	8.434510
0,4	0,2	0,8	1.776549	0,035338	8.173827
0,3	0,2	0,9	1.806473	0,035405	7.609897
0,3	0,3	0,9	1.567756	0,029609	6.115721
0,3	0,4	0,9	1.461895	0,026537	4.711235
0,3	0,5	0,9	1,407235	0,024552	3,783414
0,2	0,6	0,9	1,23247	0,019372	3,186562
0,2	0,7	0,9	1,270479	0,020268	3,324644
0,2	0,7	0,8	1,272501	0,020069	3,207699
0,2	0,8	0,7	1,476071	0,025259	4,321226
0,1	0,9	0,9	1,735519	0,031063	7,225212
Her γ değeri için en iyi α ve β değerleri					
0,3	0,8	0,1	1,911284	0,035972	7,958271
0,4	0,5	0,1	2,070569	0,037771	6,240409
0,3	0,7	0,2	1,736308	0,032348	5,829518
0,3	0,7	0,3	1,584617	0,028651	5,025964

Çizelge 4.38. (devam) Mobil ses trafik hacmi tahmini için α , β ve γ değerlerine göre en iyi Holt-Winters yöntemi sonuçları

0,3	0,6	0,4	1,530626	0,027685	4,374854
0,3	0,6	0,5	1,461520	0,025899	3,860675
0,3	0,6	0,6	1,425852	0,024817	3,530471
0,3	0,6	0,7	1,362640	0,023130	3,367673
0,2	0,7	0,8	1,272501	0,020069	3,207699
0,2	0,6	0,9	1,232470	0,019372	3,186562


SARIMA

Mobil ses trafik hacminin incelenen dönemde, artış eğilimli ve mevsimsel özellikli zaman serisi yapısına sahip olması nedeniyle tercih edilen yöntemlerden bir diğeri de SARIMA'dır. Çalışmada uygulanan SARIMA yönteminin sözde kodu Çizelge 4.39'da verilmiştir.

Çizelge 4.39. SARIMA yöntemine ait sözde kod


Veri setini yükle.
 Serinin mevsimsel trend ayrıştırmasını (STL) yap.
 ACF ve PACF grafiklerini oluştur.
 ADF testi ile serinin durağanlığını kontrol et.
 $p < 0,05$ sağlanana kadar $i = 1$ 'den d 'ye ve $j = 1$ 'den D 'ye kadar:
 i. dereceden fark al.
 ADF testini uygula.
 j. dereceden fark al.
 ADF testini uygula.
 i = d ve *j = D* birleşik farkını al.
 ADF testini uygula.
d ve *D* değerlerini belirle.
 ACF ve PACF grafiklerini çiz.
 Farklı p , q ve P , Q hiper parametreleri için alternatif denemeler yap.
 AIC ve BIC ile p , q ve P , Q hiper parametre değerlerini belirle.
 Veriyi 0,25:0,75; 0,50:0,50 ve 0,75:0,25 olmak üzere üç farklı eğitim-test oranında ayır.
 Üç farklı oran için modelleri çalıştır.
 MAE, MAPE ve MSE değerlerini hesapla.

Söz konusu yöntem için ilk adım olarak STL yöntemi (Bkz. Şekil 4.41) uygulanmış ve söz konusu metodun kullanılmasına bu doğrultuda karar verilmiştir.




Şekil 4.41. Mobil ses trafik hacmi zaman serisinin mevsimsel trend ayrıştırması

SARIMA metodu uygulanmadan önce, ham veri için ACF ve PACF grafikleri (Bkz. Şekil 4.42) çizilerek serinin sergilediği yapı analiz edilmiştir. Buna göre, ACF grafiğinden değerlerin yavaş bir şekilde azaldığı, PACF grafiğinden ise ilk gecikmede anlamlı değerlerin bulunduğu ancak sonrasında değerlerin sıfırın etrafında dalgalandığı görülmektedir.



Şekil 4.42. Mobil ses trafik hacminin tahmininde ham verinin otokorelasyon ve kısmi otokorelasyon grafikleri

Hem STL grafiğinden hem de ACF ve PACF grafiklerinden elde edilen bulgular, serinin durağan olmadığını ve durağanlaştırma yöntemlerinin uygulanması gerekliliğini göstermiştir. Bu bulgunun istatistiksel olarak teyidi ADF testi ile gerçekleştirilmiştir. İlk testin sonucunda elde edilen p -değeri 0,0019'dur. Seriyeye birinci dereceden fark alma işlemi ($d=1$) uygulanarak test işlemi tekrar edilmiştir. İkinci yapılan test sonucunda p -değeri 0,8928 olarak hesaplanmıştır. Sadece mevsimsel farkın alındığı durum ($D=1$) için elde edilen p -değeri 0,8723'tür. Birleşik farkın ($d=1, D=1$) alındığı durum için ise p -değeri 0,0000 olarak hesaplanmıştır. Bu sebeple, SARIMA için oluşturulacak modelde $d=1, D=1$ olarak tercih edilmiştir. Seriyeye birleşik farkın ($d=1, D=1$) uygulanması sonucunda elde edilen ACF ve PACF grafikleri ise Şekil 4.43'te verilmiştir.



Şekil 4.43. Mobil ses trafik hacminin tahmini için alınan birleşik farkın sonucunda oluşan otokorelasyon ve kısmi otokorelasyon grafikleri

SARIMA yöntemindeki son adım, trend bileşeni için (p, q) ; mevsimsel bileşen için ise (P, Q) parametre değerlerinin belirlenmesidir. Söz konusu değerlerin belirlenmesi için çeşitli denemeler gerçekleştirilmiş olup en iyi model AIC ve BIC bilgi kriterlerine dayalı olarak seçilmiştir. Çizelge 4.40'ta verilen deneme sonuçlarına göre AIC bilgi kriteri için SARIMA $(2,1,0) \times (2,1,0)_4$ modeli, BIC bilgi kriteri için ise SARIMA $(1,1,0) \times (2,1,0)_4$ modeli eğitim-test oranı denemelerinde kullanılmıştır.

Çizelge 4.40. Mobil ses trafik hacminin tahmini için yapılan farklı SARIMA model denemelerine ait sonuçlar

Model	AIC	BIC
$(2,1,0) \times (2,1,0)_4$	150,090133	160,930108
$(0,1,2) \times (2,1,2)_4$	150,506413	164,779930
$(1,1,0) \times (2,1,0)_4$	151,057043	160,200250
$(1,1,1) \times (2,1,2)_4$	151,231768	165,685068

Çizelge 4.40. (devam) Mobil ses trafik hacminin tahmini için yapılan farklı SARIMA model denemelerine ait sonuçlar

$(2,1,2) \times (2,1,0)_4$	151,247719	165,701019
$(2,1,0) \times (2,1,1)_4$	151,790582	164,437220
$(0,1,1) \times (2,1,2)_4$	151,914912	164,561550
$(2,1,1) \times (2,1,0)_4$	152,064305	164,710942
$(1,1,1) \times (2,1,0)_4$	152,729010	163,700859
$(1,1,0) \times (2,1,1)_4$	153,011787	163,983635
$(2,1,0) \times (2,1,2)_4$	153,096758	167,550058
$(2,1,2) \times (2,1,1)_4$	153,214898	169,474861
$(0,1,1) \times (2,1,0)_4$	153,387139	162,637877
$(2,1,1) \times (2,1,1)_4$	153,708829	168,162128
$(2,1,2) \times (0,1,2)_4$	153,974594	168,248111
$(2,1,2) \times (2,1,2)_4$	154,218901	172,060797
$(1,1,0) \times (2,1,2)_4$	154,636390	167,436880
$(1,1,1) \times (2,1,1)_4$	154,728406	167,528896
$(0,1,2) \times (0,1,2)_4$	154,787605	165,492743
$(0,1,2) \times (2,1,0)_4$	154,921817	166,022702
$(2,1,1) \times (2,1,2)_4$	154,995724	171,255686
$(0,1,1) \times (2,1,1)_4$	155,385467	166,486353
$(1,1,1) \times (0,1,2)_4$	155,629129	166,469104
$(0,1,2) \times (2,1,1)_4$	156,875042	169,826075
$(0,1,1) \times (0,1,2)_4$	157,630719	166,664031
$(2,1,1) \times (0,1,2)_4$	158,964105	171,610742
$(1,1,0) \times (0,1,2)_4$	160,823930	169,967137
$(2,1,0) \times (0,1,2)_4$	161,812561	172,784409
$(2,1,2) \times (0,1,1)_4$	167,966565	181,064972
$(0,1,2) \times (0,1,1)_4$	169,119482	178,475487
$(1,1,1) \times (0,1,1)_4$	169,358609	178,817711
$(0,1,1) \times (0,1,1)_4$	170,574057	178,141338
$(0,1,2) \times (1,1,1)_4$	171,119357	182,346563
$(0,1,1) \times (1,1,1)_4$	173,341752	182,800854
$(2,1,0) \times (1,1,1)_4$	173,604138	184,955059

Çizelge 4.40. (devam) Mobil ses trafik hacminin tahmini için yapılan farklı SARIMA model denemelerine ait sonuçlar

$(2,1,1) \times (0,1,1)_4$	173,826945	185,177866
$(2,1,2) \times (1,1,1)_4$	174,043239	189,012847
$(1,1,0) \times (0,1,1)_4$	174,216529	181,864621
$(1,1,1) \times (1,1,1)_4$	174,523829	185,874751
$(2,1,0) \times (0,1,1)_4$	175,281565	184,841680
$(2,1,1) \times (1,1,1)_4$	175,597844	188,840586
$(1,1,0) \times (1,1,1)_4$	176,216514	185,776629
$(2,1,2) \times (1,1,0)_4$	178,563474	191,806216
$(2,1,1) \times (1,1,0)_4$	179,305230	190,656151
$(2,1,0) \times (1,1,0)_4$	181,788830	191,247932
$(1,1,0) \times (1,1,0)_4$	183,426907	191,074999
$(1,1,1) \times (1,1,0)_4$	185,280320	194,840435
$(0,1,1) \times (1,1,0)_4$	186,084986	193,812288
$(0,1,2) \times (1,1,0)_4$	174,216529	197,676273

Üç farklı eğitim-test oranı kullanılarak SARIMA $(2,1,0) \times (2,1,0)_4$ ve SARIMA $(1,1,0) \times (2,1,0)_4$ modelleriyle gerçekleştirilen denemelere ait sonuçlar Çizelge 4.41’de yer almaktadır. Buna göre, tüm performans metrikleri için en iyi değerler 0,50:0,50 eğitim-test oranına sahip veri seti özelinde SARIMA $(2,1,0) \times (2,1,0)_4$ modeli ile elde edilmiştir.

Çizelge 4.41. SARIMA $(2,1,0) \times (2,1,0)_4$ ve SARIMA $(1,1,0) \times (2,1,0)_4$ modellerinin farklı eğitim-test oranındaki deneme sonuçları

Model	Eğitim-test oranı	MAE	MAPE	MSE
SARIMA $(2,1,0) \times (2,1,0)_4$	0,25:0,75	25,178161	0,348828	1001,108371
	0,50:0,50	2,349728	0,030807	9,768275
	0,75:0,25	7,040059	0,089300	53,120476
SARIMA $(1,1,0) \times (2,1,0)_4$	0,25:0,75	18,163128	0,252551	515,315441
	0,50:0,50	4,672869	0,060397	38,453202
	0,75:0,25	6,306339	0,080023	42,462226

Yapay sinir ağıları


Mobil ses trafik hacminin YSA kullanılarak tahmin edilmesine yönelik süreç, raporun “4.1.3 Yöntem” bölümünde detaylandırılan YSA yönteminin temel yapısı esas alınarak birinci aşama denemeleriyle başlatılmıştır. Buna göre, ham veri için en iyi performanslar MAE ve MAPE hata metriklerine göre 0,75:0,25 eğitim-test oranıyla, 16 girdi özelliğine ve 35 nörona sahip model ile, MSE hata metriğine göre ise 0,75:0,25 eğitim-test oranıyla, 17 girdi özelliğine ve 32 nörona sahip model ile elde edilmiştir. Birinci dereceden fark alınmış veri setiyle yapılan özellik seçim sıralamasına göre yürütülen denemelerde, MAE ve MAPE hata metriklerine göre en iyi performans 0,75:0,25 eğitim-test oranına, 12 girdi özelliğine ve 40 nörona sahip model ile elde edilmiştir. Öte yandan, MSE hata metriği açısından en başarılı sonuç yine 0,75:0,25 eğitim-test oranıyla ancak 16 girdi ve 38 nöron içeren modelde gözlemlenmiştir. Söz konusu denemeye ait sonuçlar, her bir eğitim-test oranı için en iyi hata metriklerini sağlayan model hiper parametreleri dikkate alınarak Çizelge 4.42’de verilmiştir.

Çizelge 4.42. Mobil ses trafik hacmi tahmininde YSA yöntemine ait birinci aşamanın en iyi sonuçları

Veri tipi	Eğitim-test oranı	Özellik sayısı	Nöron sayısı	MAE	MAPE	MSE
Ham veri	0,25:0,75	9	29	2,566384	0,051137	10,478494
	0,50:0,50	15	37	2,454434	0,049144	8,524991
	0,75:0,25	16	35	2,222013	0,044367	8,575213
	0,75:0,25	17	32	2,261430	0,046231	8,441102
Fark alınmış veri	0,25:0,75	16	38	3,169551	0,060480	15,113251
	0,50:0,50	16	39	2,554105	0,051557	9,214061
	0,50:0,50	15	39	2,546181	0,051158	9,765487
	0,75:0,25	12	40	2,271082	0,044245	9,448774
	0,75:0,25	16	38	2,278333	0,046238	8,616628

Birinci aşama sonuçlarına göre, hem ham veri hem de fark verisi için ikişer farklı modelle (0,75:0,25 eğitim-test oranı ve 32 nöron, 0,75:0,25 eğitim-test oranı ve 35 nöron; 0,75:0,25 eğitim-test oranı ve 38 nöron, 0,75:0,25 eğitim-test oranı ve 40 nöron) elde edilmiştir. Bu modellerin ilgili hiper parametreleri sabit tutularak, mobil ses trafik hacmi için yapılan

özellik seçiminin model performansı üzerindeki etkisi Şekil 4.44'te incelenmiştir. Şekillerden elde edilen bulgulara göre, modele eklenen özellik sayısı artışının genel olarak performans değerlerinde iyileşme sağladığı, ancak, özellikle girdi olarak 7 özelliğin kullanıldığı modelden sonra, performans artışlarının sınırlı düzeyde kaldığı ve belirgin bir iyileşmenin olmadığı görülmektedir.



Şekil 4.44. Mobil ses trafik hacmi tahmininde RFE özellik kümelerine göre tüm hata metriklerindeki değişim

Birinci aşamada elde edilen 0,75:0,25 eğitim-test oranı, ham veri özelinde 16 ve 17 adet özellik içeren veri kümeleri, fark verisi özelinde 12 ve 16 adet özellik içeren veri kümeleri sabitlenerek toplamda dört farklı veri kümesi ile ikinci aşama denemelerine geçilmiştir. Bu aşamaya ait sonuçlar, kullanılan veri kümesi için her bir gizli katman ve epok sayısı

denemesinde en iyi performansı sağlayan nöron sayısı dikkate alınarak Çizelge 4.43'te özet hâlinde verilmiştir. Buna göre, en iyi sonuçlar MAE ve MAPE hata metrikleri açısından birinci dereceden farkı alınmış veri, 12 özellik, 4 gizli katman ile elde edilmiştir. Spesifik olarak ise en iyi sonuçlar, MAE hata metriğine göre 200 epok ve 27 nörona sahip model, MAPE hata metriğine göre 300 epok ve 40 nörona sahip model ile üretilmiştir. MSE hata metriği açısından ise en iyi performans ham veri, 17 özellik, 5 gizli katman, 300 epok ve 33 nörona sahip modelde gözlemlenmiştir.

Çizelge 4.43. Mobil ses trafik hacmi tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Veri tipi, eğitim-test oranı, özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAE	MAPE	MSE
Ham veri, 0,75:0,25, 16	1	27	300	2,250801	0,045637	8,273291
	1	38	300	2,252170	0,045399	8,181898
	2	38	200	2,106133	0,043731	7,422492
	2	40	300	2,095299	0,042170	6,996767
	3	16	200	2,203501	0,044840	7,896232
	3	34	200	2,177933	0,045063	7,897306
	3	40	200	2,217625	0,045667	7,710655
	3	29	300	2,088151	0,043068	7,004574
	3	36	300	2,103818	0,043048	6,876498
	3	38	300	2,120500	0,043549	6,811580
	4	30	200	2,101296	0,043985	6,965713
	4	39	200	2,079149	0,043680	7,102542
	4	25	300	2,110222	0,043588	7,023564
	4	38	300	2,114049	0,043437	6,802989
	5	29	200	2,118919	0,043601	7,088439
	5	39	200	2,124917	0,043130	6,953792
	5	19	300	2,068094	0,043273	6,668978
	5	30	300	2,112713	0,043167	6,707049
Ham veri, 0,75:0,25, 17	1	21	300	2,210031	0,045062	8,272445
	1	36	300	2,221417	0,045834	8,098448
	2	26	200	2,222649	0,045083	8,089870
	2	32	200	2,211273	0,045115	7,680005
	2	37	200	2,195533	0,045805	7,833513


Çizelge 4.43. (devam) Mobil ses trafik hacmi tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Ham veri, 0,75:0,25, 17	2	31	300	2,127068	0,044104	7,428409
	3	38	200	2,136011	0,043486	7,228637
	3	40	300	2,076289	0,042922	6,713641
	4	38	200	2,126758	0,043357	6,914926
	4	39	300	2,045814	0,042426	6,367521
	5	31	200	2,110725	0,043920	6,928772
	5	33	200	2,095538	0,042401	7,215407
	5	33	300	2,036094	0,041500	6,012287
Fark alınmış veri, 0,75:0,25, 12	1	39	300	2,136200	0,042691	8,057692
	2	17	200	2,229486	0,043482	8,843945
	2	39	200	2,201479	0,043696	8,348580
	2	40	200	2,205055	0,043997	8,207766
	2	24	300	2,130295	0,042660	7,561706
	2	36	300	2,100285	0,041425	7,721581
	3	30	200	2,081556	0,041135	7,459701
	3	31	300	2,033341	0,039179	7,075596
	3	37	300	2,030571	0,039319	6,684783
	4	27	200	1,984531	0,038722	7,106543
	4	40	200	2,024294	0,039462	6,854485
	4	40	300	1,995295	0,037792	6,404767
	5	37	200	1,999574	0,039032	6,88524
	5	26	300	2,01272	0,038924	6,508773
	5	40	300	2,049428	0,038414	6,766447
Fark alınmış veri, 0,75:0,25, 16	1	30	300	2,246404	0,045925	8,430942
	1	35	300	2,262558	0,046522	8,377228
	2	40	200	2,212823	0,045147	7,991136
	2	36	300	2,158196	0,044252	7,456512
	3	31	200	2,176301	0,044542	7,795725
	3	40	200	2,204538	0,045167	7,489638
	3	39	300	2,060776	0,042248	6,997661
	4	38	200	2,135276	0,043243	7,124943
	4	33	300	2,142842	0,043339	7,025031

Çizelge 4.43. (devam) Mobil ses trafik hacmi tahmininde YSA yöntemine ait ikinci aşamanın en iyi sonuçları

Fark alınmış veri, 0,75:0,25, 16	5	28	200	2,129289	0,044243	7,135660
	5	31	200	2,115989	0,044600	7,241926
	5	40	300	2,07736	0,042138	6,260201

Gizli katman sayısı ile epok sayısının model performansına etkileri, ikinci aşama denemelerindeki en iyi sonuçların elde edildiği üç farklı model hiper parametreleri (ham veri, 0,75:0,25 eğitim-test oranı, 17 özellik, 33 nöron; fark verisi, 0,75:0,25 eğitim-test oranı, 12 özellik, 27 ve 40 nöron) sabit tutularak incelenmiştir. Analize ait grafikler Şekil 4.45'te yer almakta olup ilgili grafiklerden genel olarak en başarılı sonuçların 300 epok, 4 veya 5 gizli katmana sahip modeller ile elde edildiği görülmektedir. Ayrıca, ikinci aşamadaki üç performans metriği özelinde de en iyi değerlere sahip sonuçların, epok ve nöron sayılarına göre değişimleri ise Ek-11-13'te yer almaktadır.



Şekil 4.45. Farklı gizli katman ve epok sayısına denemelerine göre mobil ses trafik hacminin tahmin performansındaki değişimi


İkinci aşamada en iyi sonuçların iki farklı veri kümesi ile elde edilmesi dolayısıyla, üçüncü aşama denemeleri de ilgili veri kümeleriyle sürdürülmüştür. Spesifik olarak, 17 özelliğe sahip veri kümesi için 5 gizli katman, 300 epok; 12 özelliğe sahip veri kümesi için ise 4 gizli katman ve 200 ile 300 epok kullanılan modellerle üçüncü aşama denemeleri gerçekleştirilmiştir. Buna göre, üçüncü aşama denemelerinden elde edilen en iyi sonuçlar Çizelge 4.44'te görülmektedir. En iyi sonuçlar, tüm hata metrikleri açısından ReLU aktivasyon fonksiyonu ile elde edilmiştir. Tüm performans metriklerinin en iyi değerlerine 12 adet özellik içeren veri kümesi kullanılarak ulaşılmış olup ayrıca modeller, 4 gizli

katman, 300 epok ve 20 nöron hiper parametre değerlerine sahiptir.

Çizelge 4.44. Mobil ses trafik hacmi tahmininde YSA yöntemine ait üçüncü aşamanın sonuçları

Aktivasyon fonksiyonu	Özellik sayısı	Gizli katman sayısı	Nöron sayısı	Epok sayısı	MAE	MAPE	MSE
Doğrusal	17	5	25	300	2,022166	0,038181	6,046508
Doğrusal	12	4	33	200	1,961699	0,034726	6,085543
Doğrusal	12	4	39	200	1,950754	0,034954	6,040888
Doğrusal	12	4	32	300	1,911263	0,034533	5,748580
ReLu	17	5	40	300	1,951674	0,037575	6,027413
ReLu	12	4	31	200	2,093310	0,036294	6,935381
ReLU	12	4	39	200	2,134538	0,037389	6,685768
ReLU	12	4	20	300	1,838591	0,032870	5,454916
Tanh	17	5	32	300	1,900816	0,037067	6,225587
Tanh	17	5	35	300	1,933882	0,038332	6,079165
Tanh	12	4	38	200	2,013801	0,034868	7,820550
Tanh	12	4	34	200	2,004444	0,035865	7,973103
Tanh	12	4	40	200	2,025379	0,036850	7,045126
Tanh	12	4	31	300	1,909761	0,033271	6,682679


Üçüncü aşama denemelerinden elde edilen hata metriklerinin en iyi değerlerine ait parametreler (tüm hata metrikleri için, fark verisi, 0,75:0,25 eğitim-test oranı, 12 özellik, 4 gizli katman, 300 epok) sabit tutularak, aktivasyon fonksiyonlarının model performansına etkisinin incelendiği grafikler Şekil 4.46'da yer almaktadır. İlgili grafiklerden, her üç performans metriğinde de doğrusal, sigmoid, tanh aktivasyon fonksiyonlarının birbirine yakın sonuçlar ürettiği, ReLU aktivasyon fonksiyonunun ise genellikle daha dalgalı bir yapı sergilediği, diğer aktivasyon fonksiyonlarından daha farklı değerler ortaya koyduğu, ancak, en yüksek başarı değerinin ReLU aktivasyon fonksiyonuyla elde edildiği görülebilir. Ayrıca genel olarak, nöron sayısı artışının bir önceki nöronlardan elde edilen değerlere göre iyileşme sağladığı görülse de özellikle 16 nöronlardan sonra performanslardaki iyileşme daha sınırlıdır.



Şekil 4.46. Aktivasyon fonksiyonlarının mobil ses trafik hacmi tahmin performansına etkisi

Modellerin karşılaştırılması

Mobil ses trafik hacmi tahmini için kurulan SARIMA, Holt-Winters ve YSA modellerinin MAE, MAPE ve MSE hata ölçüt metriklerindeki en iyi performanslarına ait karşılaştırmalara Şekil 4.47’de yer verilmektedir. Sonuçlar, Holt-Winters yönteminin tüm hata metriklerinde en iyi performansı sunduğunu, YSA modelinin ise SARIMA’ya kıyasla MAE ve MSE hata metrikleri açısından daha başarılı olduğunu göstermektedir.



Şekil 4.47. Mobil ses trafik hacmi tahmin modellerinin karşılaştırılması


Her hata metriği için ayrı olacak şekilde, üç yöntemin en iyi model performanslarına uygulanan Kruskal-Wallis testine ait sonuçlar Çizelge 4.45’te görülmektedir. Elde edilen bulgular H_0 hipotezinin reddedilmesine yol açmıştır. Buna göre, MAE, MAPE, MSE performans metrikleri açısından SARIMA, Holt-Winters ve YSA modellerinin olasılık dağılımlarından en az ikisi konum açısından farklılık göstermektedir. Bu farklılıkların hangi gruplar arasında olduğunun belirlenebilmesi için ise ikili karşılaştırmalar yapılarak sürece devam edilmiştir. Yapılan testler sonucunda, her üç performans metriği açısından Holt-Winters metodunun SARIMA modeline kıyasla anlamlı düzeyde farklı sonuçlar ürettiği; YSA modelinin ise SARIMA ve Holt-Winters modellerine göre anlamlı düzeyde farklı

sonuçlar ürettiğine dair yeterli kanıtın bulunmadığı görülmüştür. Bu bulgular, mobil ses trafik hacmi tahmininde Holt-Winters model performansının sadece SARIMA modeline göre belirgin şekilde farklı olduğunu, SARIMA ve YSA'nın ise benzer performansa sahip olduğunu ortaya koymaktadır.

Çizelge 4.45. Mobil ses trafik hacmi tahmini için yapılan Kruskal-Wallis testine ait sonuçlar

Performans metriği	Karşılaştırılan modeller	Test istatistiği	<i>p</i> -değeri
MAE-MAPE-MSE	Holt-Winters-SARIMA-YSA	6,3540	0,0417
	Holt-Winters-SARIMA	5,5177	0,0188
	Holt-Winters -YSA	2,1729	0,1405
	SARIMA-YSA	0,4226	0,5156

En iyi performans metriklerinin elde edildiği modellerle üretilen tahminlere ait karşılaştırmalar Şekil 4.48'de sunulmuştur. İlgili grafiklerden, YSA ve Holt-Winters yöntemlerinin tüm hata metrikleri açısından trend tahmininde başarılı olduğu, ancak, SARIMA yöntemin biraz zayıf kaldığı görülmektedir. Kısa vadeli dalgalanmalar dikkate alındığında ise, Holt-Winters yönteminin diğer yöntemlere kıyasla daha başarılı olduğu sonucuna ulaşılabilir.



Şekil 4.48. Tüm hata metrikleri için en iyi sonucun elde edildiği hiper parametrelerle üretilen mobil ses trafik hacmi tahminlerinin karşılaştırılması



5. SONUÇ VE ÖNERİLER

Bu çalışmada, Türkiye'nin elektronik haberleşme sektörüne yönelik göstergelerinden genişbant abone sayısı, mobil abone sayısı, SMS ve MMS miktarı ile mobil ses trafik hacmi tahmini için yöntemler önerilmiş ve karşılaştırılmıştır. Tahmin çalışmasında YSA yönteminden faydalanılmış, ayrıca tahmin edilen göstergenin yapısal özelliğine göre ARIMA, SARIMA, çift üstel düzeltme ve Holt-Winters gibi geleneksel yöntemlerle karşılaştırmalar yapılmıştır. YSA özelinde RFE yönteminin uygulandığı bir özellik seçim süreci yürütülmüş, modele eklenen her özelliğin model performansına etkisi izlenmiştir.

Bununla birlikte, MAE, MAPE ve MSE hata metrikleri kullanılarak çift üstel düzeltme, Holt-Winters ve YSA modellerinin hiper parametreleri belirlenmiş, AIC ve BIC bilgi kriteri kullanılarak ise SARIMA modelinin en uygun hiper parametreleri seçilmiştir. Oluşturulan modellerin farklı eğitim-test oranlarındaki performansları incelenmiş, seçim sürecinde yine MAE, MAPE ve MSE hata metriklerinden yararlanılmıştır. Bu sürecin ardından ise, elde edilen tahminlerin performansları kıyaslanmıştır. Genel olarak elde edilen sonuçların birbirine yakın olması dolayısıyla Kruskal-Wallis testi uygulanmış, model performanslarının arasında istatistiksel olarak anlamlı bir fark olup olmadığı araştırılmıştır. Bu kapsamda, çalışmada tahmin edilen elektronik haberleşme sektörüne ait göstergelerin en iyi model yapıları Çizelge 5.1'de verilmiştir.

Çizelge 5.1. Tahmin edilen göstergelerin en iyi model yapıları

Yöntem	MAE	MAPE	MSE
Genişbant internet abone sayısı	Çift üstel düzeltme (0,9; 0,2)	Çift üstel düzeltme (0,9; 0,2)	YSA (4 gizli katman, 300 epok, 14 nöron)
Mobil abone sayısı	YSA (5 gizli katman, 300 epok, 37 nöron)	YSA (5 gizli katman, 300 epok, 26 nöron)	YSA (5 gizli katman, 300 epok, 34 nöron)
MMS miktarı	ARIMA (2,1,1)	YSA (5 gizli katman, 300 epok, 35 nöron)	ARIMA (2,1,1)
SMS miktarı	Çift üstel düzeltme (0,8; 0,2)	YSA (3 gizli katman, 300 epok, 27 nöron)	YSA (3 gizli katman, 300 epok, 40 nöron)
Mobil ses trafik hacmi	Holt-Winters (0,2; 0,6; 0,9)	Holt-Winters (0,2; 0,6; 0,9)	Holt-Winters (0,2; 0,6; 0,9)

Çizelge 5.1'e göre, trend içeren serilerin tahmininde ARIMA metodunun diğer yöntemlere göre zayıf bir performans sergilediği söylenebilir. YSA modeli genellikle iyi sonuçlar üretse de karşılaştırıldığı tüm modellerle arasında istatistiksel olarak anlamlı bir fark gözlemlenmemiştir. Bu bakımdan, çift üstel düzeltme metodunun YSA'ya göre hem basit hem de kolay uygulanabilmesi trend içeren seriler için önemli bir alternatif olmasına neden olmaktadır. Mevsimsellik içeren serilerde ise YSA mevsimsel yapıyı tahmin etmede trend tahmininde olduğu kadar başarılı bir performans göstermemiştir. Ancak, SARIMA yöntemine kıyasla daha iyi performans sergilediği de bir gerçektir. Holt-Winters yöntemi hem mevsimsel yapıları hem de trend bileşenini tahmin etmede YSA yönteminden daha başarılı performans sergilemiştir. Bu bakımdan, Holt-Winters yöntemi bu tür zaman serilerinde YSA'ya kıyasla tercih edilebilir.

Çalışmanın bir diğer bulgusu, eğitim-test oranı kıyaslamalarında 0,75:0,25 oranı kullanılarak daha iyi sonuçlar elde edildiği yönündedir. Bu bakımdan, eğitim oranındaki artışın modelin performansında da artış sağladığı söylenebilir. Çalışma kapsamında ele alınan bir diğer konu ise hiper parametre seçimidir. YSA özelinde, katman, nöron ve epok sayılarındaki artış modelin performansında genellikle iyileşme sağlamaktadır (Bkz. Ek-1-13). Bununla birlikte, çıktı katmanında kullanılan aktivasyon fonksiyonlarından, ReLU aktivasyon fonksiyonunun daha farklı ve düzensiz sonuçlar ürettiği; doğrusal, sigmoid ve tanh aktivasyon fonksiyonlarıyla ise daha tutarlı ve benzer sonuçlar üretildiği söylenebilir.

Öte yandan literatürde, çok değişkenli yöntemlerin aşırı öğrenme eğilimi göstermesi, modelleme sürecindeki temel endişelerden birini oluşturmaktadır [85]. Bu bulguyla tutarlı olarak, M3 Competition sonuçları, model karmaşıklığının test verisi üzerindeki genelleme performansını garanti etmediğini ve daha basit yöntemlerin birçok durumda daha istikrarlı sonuçlar verdiğini ortaya koymuştur [86].

Bu çerçevede, yapay sinir ağlarının da yüksek model kapasitesi nedeniyle aşırı öğrenmeye yatkın bir yapıya sahip olduğu dikkate alınarak, bu çalışmada modelin genelleme performansını artırmaya yönelik çeşitli önlemler alınmıştır. İlk olarak, sınırlı veri koşullarında anlamlı olmayan değişkenlerin model karmaşıklığını artırabileceği göz önünde bulundurularak, regresyon analizi için α parametresi 0,01 olarak belirlenmiştir. Bunu takiben, RFE özellik seçimi yöntemi kullanılarak farklı özellik sayılarıyla oluşturulan modellerin performansları karşılaştırılmıştır.

Bununla birlikte, literatürde yapay sinir ağlarının eğitiminde kullanılan epok sayılarının ağ mimarisi, veri büyüklüğü ve optimizasyon yöntemine bağlı olarak geniş bir aralıkta [87-89] değişebildiği göz önünde bulundurularak, bu çalışmada 200 ve 300 epok değerleri karşılaştırmalı olarak ele alınmıştır. Optimize edici algoritma kullanımında ise, modelin yakınsama sürecini hızlandırmak ve dışsal tahmin kararlılığına katkı sağlamak amacıyla, optimal parametrelerin gradyanlarını etkin biçimde güncellemeye olanak tanıyan Adam algoritması tercih edilmiştir [90].

Literatürde ayrıca, yeterli büyüklüğe sahip veri kümeleri kullanıldığında aşırı öğrenmenin azaltılmasına yardımcı olan örnekleme yığınlama (bagging) gibi yeniden örnekleme (bootstrap yöntemi) tabanlı çalışmalar bulunmaktadır [91-93]. Ne var ki, bu çalışmada kullanılan veri kümesinin sınırlı boyutu, söz konusu yöntemlerin uygulanmasını kısıtlamıştır. Buna karşın, yapay sinir ağlarının rastgele başlangıç ağırlıklarına duyarlı yapısı dikkate alınarak, her ağ yapısı farklı başlangıç koşulları altında 10 kez eğitilmiş ve elde edilen sonuçların ortalaması alınarak model varyansının azaltılması hedeflenmiştir. Bunun yanı sıra, eğitim veri oranının artırılmasıyla birlikte test hata metriklerinde çoğunlukla gözlenen iyileşme, modelin daha fazla örüntü öğrenme fırsatı bulduğunu ve genelleme yeteneğinin güçlendiğini göstermektedir.

Sonuç olarak, bu çalışma, genişbant internet abone sayısı, mobil abone sayısı, SMS ve MMS miktarları ile mobil ses trafik hacmi gibi temel elektronik haberleşme sektörü göstergelerinin tahmininde YSA kullanımının etkisini incelemekte ve ilgili göstergelerin en başarılı şekilde tahmin edilmesini sağlayan yöntemin belirlenmesine odaklanmaktadır. Söz konusu göstergelerin geleceğe yönelik doğru tahminleri, işletmecilerin altyapı planlamalarını daha etkin biçimde yapmalarına, hizmet kalitesini sürdürmelerine ve müşteri memnuniyetini artırmalarına katkı sağlayacaktır. Ayrıca, bu çalışmanın, elektronik haberleşme sektöründeki ilgili göstergelerin tahmininde; YSA model performansının geleneksel yöntemlerle kıyaslanması, istatistiksel anlamlılık testlerinden faydalanılarak çalışma bulgularının güvenilirliğinin artırılması, farklı eğitim-test oranı denemelerinin gerçekleştirilmesi, hem ham hem de birinci dereceden fark alınmış veri kümesi kullanılarak özellik seçiminin uygulanması gibi çeşitli süreçleri barındırması bakımından literatüre önemli katkılar sunması beklenmektedir.

Çalışmanın sınırlılıkları arasında, çalışmada nispeten az sayıda veri kullanılması, kullanılan bazı verilerin yıllık olarak yayımlanması ve deneyler için uzun zaman harcanması gösterilebilir. Gelecek çalışmalar için, LSTM gibi derin öğrenme yöntemleriyle klasik istatistiksel modellerin güçlü yönlerini birleştiren hibrit yaklaşımların, Türkiye’deki mobil ve genişbant abone sayıları, mobil veri trafiği, mobil ses trafiği gibi göstergeler üzerinde uygulanması ve performanslarının karşılaştırmalı olarak incelenmesi faydalı olabilir. Bu çalışmada ele alınan elektronik haberleşme sektörü göstergeleri için, farklı özellik seçim yöntemleri kullanılarak özellik seçim sürecinin model performansı üzerindeki etkisi gözlemlenebilir. Ayrıca, elektronik haberleşme sektörü dışındaki işletmeler de mobil hizmet talebi tahminlerinden yararlanarak satış, kampanya ve etkinlik planlamalarını optimize edebilir; servis sağlayıcılarla yapacakları iş birliklerinde daha bilinçli stratejik kararlar geliştirebilirler. Bununla birlikte, tahmin yöntemlerinin elektronik haberleşme sektöründeki iş zekâsı sistemlerine entegrasyonu kapsamında bulut tabanlı çözümlerin değerlendirilmesi ve karar destek sistemlerinin geliştirilmesi, kurumların operasyonel verimliliğini artıracak önemli katkılar sağlayabilir [94-95].

KAYNAKLAR

1. Bilgi Teknolojileri ve İletişim Kurumu (2025). 2025-2. Çeyrek Türkiye Elektronik Haberleşme Sektörü Pazar Verileri Raporu. *BTK*. Ankara, 45-82.
2. Csikor, L., Pezaros, D. P. (2017, 4-8 Aralık). *End-host driven troubleshooting architecture for software-defined networking*. In 2017 IEEE Global Communications Conference (GLOBECOM), Singapur, 1-7.
3. Luo, C., Zeng J., Yuan, M., Dai, W., Yang, Q. (2016). Telco user activity level prediction with massive mobile broadband data. *ACM Transactions on Intelligent Systems and Technology*, 7(4), 1-30.
4. Huang, C. W., Chiang, C. T., Li, Q. (2017, 8-13 Ekim). *A study of deep learning networks on mobile traffic forecasting*. In 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC), Montreal, 1-6.
5. Feng, J., Chen, X., Gao, R., Zeng, M., Li, Y. (2018). DeepTP: An end-to-end neural network for mobile cellular traffic prediction. *IEEE Network*, 32(6), 108-115.
6. Yamada, Y., Shinkuma, R., Sato, T., Oki, E. (2018, 9-13 Aralık). *Feature-selection based data prioritization in mobile traffic prediction using machine learning*. In 2018 IEEE Global Communications Conference (GLOBECOM), Abu Dhabi, 1-6.
7. Mejia, J., Ochoa-Zezzati, A., Cruz-Mejia, O. (2020). Traffic forecasting on mobile networks using 3D convolutional layers. *Mobile Networks and Applications*, 25, 2134-2140.
8. Kirmaz, A., Michalopoulos, D. S., Balan, I., Gerstacker, W. (2020, 17-19 Kasım). *Mobile network traffic forecasting using artificial neural networks*. In 2020 28th International Symposium on Modeling, Analysis, and Simulation of Computer and Telecommunication Systems (MASCOTS), Nice, 1-7.
9. Prajam, S., Wechtaisong, C., Khan, A. A. (2022). Applying machine learning approaches for network traffic forecasting. *Indian Journal of Computer Science and Engineering*, 13(2), 324-335.
10. Batool, I., Fouda, M. M., Fadlullah, Z. M. (2024, 28-30 Mayıs). *Deep learning-based throughput prediction in 5G cellular networks*. In 2024 International Conference on Smart Applications, Communications and Networking (SmartNets), Harrisonburg, 1-6.
11. Xie, R., Guan, X., Cao, J., Wang, X., Wu, H. (2024). HSeq2Seq: Hierarchical graph neural network for accurate mobile traffic forecasting. *Information Sciences*, 679, 1-18.
12. Zeng, L., Zhang, C., Qin, P., Zhou, Y., Cai, Y. (2024). One method for predicting satellite communication terminal service demands based on artificial intelligence algorithms. *Applied Sciences*, 14(14), 6019.

13. Bastos, J. A. (2019). Forecasting the capacity of mobile networks. *Telecommunication Systems*, 72, 231–242.
14. Wang, L. N., Zang, C. R., Cheng, Y. Y. (2020). The short-term prediction of the mobile communication traffic based on the product seasonal model. *SN Applied Sciences*, 2, 399.
15. Jiang, W., Zhang, Y., Han, H., Huang, Z., Li, Q., Mu, J. (2024, Şubat). Mobile traffic prediction in consumer applications: A multimodal deep learning approach. *IEEE Transactions on Consumer Electronics*, 70(1), 3425–3435.
16. Hong, W. C., Dong, Y., Chen, L. Y., Lai, C. Y. (2010). Taiwanese 3G mobile phone demand forecasting by SVR with hybrid evolutionary algorithms. *Expert Systems with Applications*, 37(6), 4452–4462.
17. Aziz, A. (2016). Forecasting broadband users in Indonesia. *Buletin Pos dan Telekomunikasi*, 14(1), 23–38.
18. Nikraves, A. Y., Ajila, S. A., Lung, C. H., Ding, W. (2016, 27 Haziran– 2 Temmuz). *Mobile network traffic prediction using MLP, MLPWD, and SVM*. In 2016 IEEE International Congress on Big Data (BigData Congress), San Francisco, 402–409.
19. Siluyele, I., Jere, S. (2016). Using Box-Jenkins models to forecast mobile cellular subscription. *Open Journal of Statistics*, 6, 303–309.
20. Fu, X., Zhang, P., Zhang, J. (2017, February). Forecasting and analyzing Internet users of China with Lotka–Volterra model. *Asia-Pacific Journal of Operational Research*, 34(1), 1740006.
21. Duan, Z., Liu, Y., Huang, K. (2019, Mayıs). Mobile phone sales forecast based on support vector machine. In *Journal of Physics: Conference Series*, 1229(1), 012061.
22. Alvarado, J. G., Alvarado, A. D., Lema, E. V. (2021). Time series analysis of telecommunications data using neural networks. *Turkish Journal of Computer and Mathematics Education*, 12(14), 2835–2841.
23. Pratondo, A., Utoro, R. K., Tambunan, T. D., Sugiarto, D., Sularsa, A., Budianto, A. (2023, 6-7 Temmuz). *Prediction of operating system preferences on mobile phones using machine learning*. In 2023 9th International Conference on Wireless and Telematics (ICWT), Solo, 1-5.
24. Hyndman, R. J., Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (İkinci Baskı). Australia:OTexts, 9.
25. Karahan, M. (2011). *İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması*. Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya.

26. Es, H.A., Kalender, F.Y., ve Hamzaçebi, C. (2014). Yapay sinir ağları ile Türkiye net enerji talep tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 29(3), 495-504.
27. Bilgin, E., ve Ulusoy, Y. (2021, Haziran). *Talep tahmini ve stok yönetimi üzerine bir uygulama*. 20. Uluslararası İşletmecilik Kongresi Bildirileri, Giresun, 1412-1433.
28. Koçkaya, A. (2016). *Otomotiv sanayisi için üretim yapan bir işletmede talep tahmin yöntemlerinin uygulanması*. Yüksek Lisans Tezi, Maltepe Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
29. Önsel Şahin, Ş., Ülengin, F., ve Ülengin, B. (2002). Senaryo analizi için dinamik bir yaklaşım önerisi. *İTÜ Dergisi/B: Sosyal Bilimler*, 1(1), 35–46.
30. Körpeoğlu, A. D., ve Ağaoğlu, O. (2019). Delphi tekniği ile BİLSEM öğretmenlerinin gözünden öğrencilerin sosyal medya kullanımlarının olumlu ve olumsuz yönlerinin incelenmesi. *Bilim Armonisi*, 2(1), 3–7.
31. Sarı, M. (2016). *Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması*. Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
32. Yazıcıoğlu, N. (2010). *Yapay zeka ile talep tahmini*. Yüksek Lisans Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.
33. Şeker, S. E. (2015). Zaman serisi analizi. *YBS Ansiklopedi*, 2(4), 23–31.
34. Nahmias, S., Olsen, T. V. (2015). *Production and operations analysis*. (7. Baskı). Long Grove: Waveland Press, Inc., 59.
35. Hansun, S. (2013, 27-28 Kasım). *A new approach of moving average method in time series analysis*. In 2013 Conference on New Media Studies (CoNMedia), Tangerang, 1–4.
36. Soysal, M., ve Ömürgönülşen, M. (2010). Türk turizm sektöründe talep tahmini üzerine bir uygulama. *Anatolia: Turizm Araştırmaları Dergisi*, 21(1), 128–136.
37. Louahem M'sabah, H., Bouzaouit, A., Mattallah, S. (2023). Forecast of the temperature variation of an elastohydrodynamic contact by the simple exponential smoothing model (SES). *Acta Mechanica Slovaca*, 27(3), 70–76.
38. Ostertagová, E., Ostertag, O. (2011, 20-22 Eylül). *The simple exponential smoothing model*. In Modelling of Mechanical and Mechatronic Systems 2011: Proceedings of the 4th International Conference, Košice, 380–384.
39. İnternet: Panda, M. (Temmuz, 2020). Application of ARIMA and Holt-Winters forecasting model to predict the spreading of COVID-19 for India and its states. *MedRxiv preprint*. URL1: <https://doi.org/10.1101/2020.07.14.20153908>, Son Erişim Tarihi: 10.09.2025.

40. Selçuk, İ. S. (2009). *Küresel ısınma, Türkiye'nin enerji güvenliği ve geleceğe yönelik enerji politikaları*. Yüksek Lisans Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.
41. Djakaria, I., Saleh, S. E. (2021). Covid-19 forecast using Holt-Winters exponential smoothing. *Journal of Physics: Conference Series*, 1882, 012033.
42. Vagropoulos, S. I., Chouliaras, G. I., Kardakos, E. G., Simoglou, C. K., Bakirtzis, A. G. (2016, 4-8 Nisan). *Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting*. In 2016 IEEE International Energy Conference (ENERGYCON), Leuven, 1-6.
43. Rizkya, I., Syahputri, K., Sari, R. M., Siregar, I. (2019). Autoregressive integrated moving average (ARIMA) model of forecast demand in distribution centre. *IOP Conference Series: Materials Science and Engineering*, 598(1), 012071.
44. Wirawan, I. M., Widiyaningtyas, T., Hasan, M. M. (2019, 21-22 Eylül). *Short term prediction on Bitcoin price using ARIMA method*. In Proceedings of the International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE), Semarang, 260–265.
45. Yanık, E. (2019). *İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması*. Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Kırıkkale.
46. Karaca, C., ve Karacan, H. (2016). Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 4(3), 182–195.
47. Surya, P., Aroquiaraj, I. L. (2018). Crop yield prediction in agriculture using data mining predictive analytic techniques. *International Journal of Research and Analytical Reviews (IJRAR)*, 5(4), 783–787.
48. Tabar, M. E., Başara, A. C., ve Şişman, Y. (2021). Çoklu regresyon ve yapay sinir ağları ile Tokat ilinde konut değerlendirme çalışması. *Türkiye Arazi Yönetimi Dergisi*, 3(1), 1–7.
49. Çemrek, F. (2012). Türkiye'deki illerin gelir ve refah düzeyi değişkenleri arasındaki ilişkinin kanonik korelasyon analizi ile incelenmesi. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 7(2), 197–215.
50. Er, B., ve Fidan, U. (2024). Koroner arter hastalığı sınıflandırılmasında destek vektör makinelerinin gri kurt optimizasyonuna dayalı özellik seçim yöntemi ile geliştirilmesi. *ESTUDAM Bilişim Dergisi*, 5(1), 37–44.
51. Sağbaş, E. A., Korukoğlu, S., ve Ballı, S. (2022). Mahalanobis uzaklığı tabanlı aykırı değer bulma ve ReliefF öznitelik seçimine dayalı bir makine öğrenmesi yaklaşımı ile akıllı telefon verileri üzerinden stres tespiti. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 28(2), 333–345.

52. Ghorbani, H. (2019). Mahalanobis distance and its application for detecting multivariate outliers. *Facta Universitatis Series: Mathematics and Informatics*, 34(3), 583–595.
53. Çelik, A. (2022). Predicting diagnosis of COVID-19 disease with AdaBoost and Naive Bayes machine learning algorithms. *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(4), 1212–1221.
54. Ayan, S., ve Bilgin, T. T. (2024). Uyku sağlığı ile yaşam tarzı arasındaki ilişkinin PCA, Naive Bayes ve rastgele orman ağaçları yöntemleri ile incelenmesi ve karşılaştırılması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 8(1), 41–56.
55. Keskenler, M. F., ve Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8–18.
56. Ersoy, E., ve Karal, Ö. (2012). Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188–205.
57. Tabar, M. E., Başara, A. C., ve Şişman, Y. (2021). Çoklu regresyon ve yapay sinir ağları ile Tokat ilinde konut değerlendirme çalışması. *Türkiye Arazi Yönetimi Dergisi*, 3(1), 1–7.
58. Öztemel, E. (2009). *Yapay sinir ağları*. (3. Baskı). İstanbul: Papatya Yayıncılık Eğitim, 48-53.
59. Kaytan, M., Aydılek, İ. B., Yeroğlu, C., ve Karcı, A. (2022). Sigmoid-Gumbel: Yeni bir hibrit aktivasyon fonksiyonu. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(1), 29–45.
60. Ertaylan, A., Aktaş, Ö., ve Doğan, Y. (2021). Yapay sinir ağları ile piyasa takas fiyatı tahminlemesi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi (DEUFMD)*, 23(67), 93–105.
61. Akkaya, A., ve Közkurt, C. (2025, 6 Şubat). *Doğrusal ve doğrusal olmayan aktivasyon fonksiyonlarının karşılaştırılması*. In Proceeding Book of the 2nd International Conference on Pioneer and Innovative Studies (ICPIS 2025), Konya, 228–246.
62. Khashei, M., Bijari, M. (2010). An artificial neural network (p, d, q) model for time series forecasting. *Expert Systems with Applications*, 37(1), 479–489.
63. Rhanoui, M., Mikram, M., Yousfi, S., Barzali, S. (2019). A CNN-BiLSTM model for document-level sentiment analysis. *Machine Learning and Knowledge Extraction*, 1(3), 832–847.
64. İnternet: Türkiye İstatistik Kurumu (TÜİK), Resmi İstatistik Portalı. URL2: <https://www.resmiistatistik.gov.tr/>, Son Erişim Tarihi: 30.10.2025.
65. İnternet: Bilgi Teknolojileri ve İletişim Kurumu (BTK), Elektronik Haberleşme Pazar Verileri. URL3: <https://www.btk.gov.tr/pazar-verileri>, Son Erişim Tarihi: 30.10.2025.

66. Eşidir, K. A. (2025). Türkiye'nin kimyasal madde ithalatının gelecek tahmini: Makine öğrenmesi ve topluluk öğrenme yöntemleri performans analizi. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 35(1), 261–278.
67. Chicco D, Warrens M. J., Jurman G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623.
68. Akaike, H. (1973). Information Theory and an Extension of the Maximum Likelihood Principle. B. N. Petrov and C. Csaki (Editörler), *Second International Symposium of Information Theory*, 267-281.
69. Schwarz, G. (1978). Estimating the dimension of a model. *Annals of Statistics*, 6(2), 461–464.
70. Otu, O. A., Osuji, G. A., Opara, J., Mbachu, H. I., Iheagwara, A. I. (2014). Application of SARIMA models in modelling and forecasting Nigeria's inflation rates. *American Journal of Applied Mathematics and Statistics*, 2(1), 16–28.
71. Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101–115.
72. Hastie, T., Tibshirani, R., Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2. Baskı). ABD: Springer Series in Statistics, 394-400.
73. Sinha, S., Singh, T. N., Singh, V. K., Verma, A. (2010). Epoch determination for neural network by self-organized map (SOM). *Computational Geosciences*, 14, 199–206.
74. Namdar, M., Güney, A., Bardak, F. K., ve Başgümüş, A. (2023). NOMA tabanlı bilişsel radyo sistemlerinde sinir ağı yöntemleri ile ergodik kapasite tahmini ve başarımlar analizi. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 28(1), 253–272.
75. Asilkan, Ö., ve Irmak, S. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(2), 375–391.
76. Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., ve Tokgöz, G. (2012). Yapay sinir ağları yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
77. Göktepe, A. B., Ağar, E., ve Lav, A. H. (2005). Esnek üstyapılarda mekanik özelliklerin yapay sinir ağları kullanılarak geri-hesaplanması. *İTÜ Dergisi/d – Mühendislik*, 4(2), 31–42.
78. Yılmazel, Ö., Afşar, A., ve Yılmazel, S. (2018). Konut fiyat tahmininde yapay sinir ağları yönteminin kullanılması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi (UIİİD/IJEAS)*, 20, 285–300.

79. Öz, A., Uzun-Per, M., ve Bal, M. (2023). Kullanıcı ve öge bazlı, geniş ve derin öğrenme tabanlı seyahat öneri sistemi. *Avrupa Bilim ve Teknoloji Dergisi*, 51, 334–351.
80. Jadon, A., Patil, A. (2024, 18-19 Ocak). *A comprehensive survey of evaluation techniques for recommendation systems*. In *Computation of Artificial Intelligence and Machine Learning (ICCAIML 2024)*, Jaipur, 281–304.
81. Yavuz, S., ve Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağının performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167–187.
82. Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. (1. Baskı). Cambridge: MIT Press, 174.
83. Kruskal, W. H., Wallis, W. A. (1952). Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association*, 47(260), 583–621.
84. Parlak, M. ve Yıldırım G. (2025). Çift üstel düzeltme, ARIMA ve yapay sinir ağları ile kısa mesaj miktarının tahmini. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 31(7), 1211-1224.
85. Guyon, I., Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3, 1157–1182.
86. Makridakis, S., Hibon, M. (2000). The M3-Competition: Results, conclusions and implications. *International Journal of Forecasting*, 16(4), 451–476.
87. Silaban, H., Zarlis, M., Sawaluddin. (2017). Analysis of accuracy and epoch on back-propagation BFGS quasi-Newton. *Journal of Physics: Conference Series*, 930, 012006.
88. Oğuz, H., Sarıtaş, I., Baydan, H. E. (2010). Prediction of diesel engine performance using biofuels with artificial neural network. *Expert Systems with Applications*, 37(9), 6579–6586.
89. Sudheer, K. P., Gosain, A. K., Rangan, D. M., Saheb, M. S. (2002). Modeling evaporation using an artificial neural network algorithm. *Hydrological Processes*, 16, 3189–3202.
90. Zheng, J., Liu, C., Huang, S., He, Y. (2023). A novel adaptive dynamic GA combined with AM to optimize ANN for multi-output prediction: Small samples enhanced in industrial processing. *Information Sciences*, 644, 119285.
91. Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24, 123–140.
92. Fakhruzi, I. (2018, 6-7 Mart). *An artificial neural network with bagging to address imbalance datasets on clinical prediction*. In *2018 International Conference on Information and Communications Technology (ICOIACT)*, Yogyakarta, 895-898.

93. Islam, M. M., Yao, X., Shahriar Nirjon S. M., Islam, M. A., Murase, K. (2008). Bagging and boosting negatively correlated neural networks. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 38(3), 771–784.
94. Torkul O, Kor E, Şişci M. (2024). Tedarik zincirinde hibrit talep tahmin modeli önerisi: Çelik sektörü uygulaması. *Journal of Intelligent Systems: Theory and Applications*, 7(2), 66-80.
95. Algorabi Ö, Namlı E. (2022). Banka telepazarlama başarısının tahmini için bir birleşik makine öğrenme tabanlı karar destek modeli. *Verimlilik Dergisi*, 1, 94-109.





EK-1. Geniřbant internet abone sayısı tahmininde epok ve nöron sayılarının MAE'ye etkileri

Nöron sayısı	Ham veri, 4 gizli katman, 200 epok	Ham veri, 4 gizli katman, 300 epok	Fark verisi, 4 gizli katman, 200 epok	Fark verisi, 4 gizli katman, 300 epok
5	6 089 320	8 689 628	6 646 179	4 849 329
6	5 171 310	3 322 878	6 764 905	6 929 307
7	3 599 945	3 707 629	6 147 533	5 602 830
8	3 008 426	2 379 844	4 773 711	2 920 098
9	3 558 122	3 510 848	3 596 464	2 183 638
10	3 168 167	1 884 454	4 091 292	2 535 157
11	2 409 819	2 623 847	2 177 353	1 953 978
12	2 098 599	1 717 658	2 278 065	1 820 829
13	2 127 238	1 916 393	2 345 601	1 789 538
14	2 242 807	1 876 923	2 461 107	1 904 150
15	2 133 832	1 828 661	2 157 907	1 581 052
16	2 159 993	2 051 937	2 015 630	1 646 154
17	1 915 928	1 561 736	2 054 344	1 537 464
18	1 664 361	1 459 034	1 638 718	1 637 558
19	1 774 973	1 761 453	1 814 451	1 568 624
20	1 823 168	1 495 094	1 698 261	1 518 929
21	1 919 939	1 688 253	1 788 682	1 548 756
22	1 698 678	1 674 304	1 802 382	1 710 423
23	1 869 428	1 744 450	2 037 500	1 623 588
24	1 595 901	1 681 135	1 687 109	1 575 030
25	1 660 967	1 641 983	1 591 471	1 794 823
26	1 761 991	1 705 712	1 378 439	1 561 769
27	1 749 082	1 704 292	1 674 117	1 573 187
28	1 656 847	1 649 139	1 580 809	1 610 767
29	1 841 668	1 445 295	1 631 483	1 351 349
30	1 318 494	1 766 768	1 693 241	1 285 534
31	1 689 142	1 617 489	1 640 151	1 481 820
32	1 675 751	1 671 419	1 581 401	1 484 241
33	1 595 030	1 674 248	1 443 666	1 582 410
34	1 679 773	1 642 722	1 468 367	1 428 672
35	1 604 775	1 652 684	1 518 129	1 732 736
36	1 741 367	1 764 246	1 459 907	1 555 008
37	1 560 052	1 610 671	1 656 376	1 350 762
38	1 696 611	1 599 888	1 738 972	1 530 862
39	1 701 851	1 776 391	1 771 555	1 529 854
40	1 973 126	1 489 652	1 468 329	1 530 982

EK-2. Geniřbant internet abone sayısı tahmininde epok ve nöron sayılarının MAPE'ye etkileri

Nöron sayısı	Ham veri, 4 gizli katman, 200 epok	Ham veri, 4 gizli katman, 300 epok	Fark verisi, 4 gizli katman, 200 epok	Fark verisi, 4 gizli katman, 300 epok
5	0,385665	0,624631	0,390727	0,285554
6	0,275485	0,190197	0,395475	0,480030
7	0,232777	0,105352	0,291777	0,323158
8	0,163843	0,104406	0,275893	0,172768
9	0,208868	0,235121	0,245402	0,102002
10	0,196492	0,079554	0,302193	0,082382
11	0,111231	0,075695	0,108369	0,089465
12	0,090160	0,071362	0,121946	0,074086
13	0,099374	0,066557	0,112565	0,080154
14	0,107278	0,069609	0,124602	0,081903
15	0,085669	0,062318	0,105793	0,072441
16	0,097019	0,069436	0,094842	0,061385
17	0,078869	0,053060	0,100402	0,058673
18	0,072977	0,051752	0,073251	0,063824
19	0,067475	0,053692	0,083826	0,055297
20	0,066259	0,050803	0,079431	0,055891
21	0,076773	0,054461	0,079324	0,059371
22	0,068902	0,052318	0,079153	0,061440
23	0,069453	0,054069	0,089886	0,057119
24	0,054514	0,050971	0,065641	0,052600
25	0,057220	0,048909	0,063493	0,063740
26	0,063470	0,052726	0,061359	0,057606
27	0,063713	0,050243	0,063875	0,053491
28	0,054933	0,047028	0,065847	0,053789
29	0,054450	0,044282	0,063911	0,048134
30	0,045421	0,056149	0,062288	0,048845
31	0,057254	0,052875	0,065064	0,051437
32	0,054920	0,050415	0,054873	0,055880
33	0,057176	0,045923	0,052592	0,051542
34	0,055172	0,048532	0,054757	0,049585
35	0,052292	0,048021	0,056998	0,059075
36	0,055852	0,052051	0,055180	0,051154
37	0,048646	0,047750	0,062017	0,048042
38	0,053187	0,043756	0,064972	0,052698
39	0,053014	0,050990	0,064100	0,050945
40	0,061444	0,043917	0,055995	0,051549

EK-3. Geniřbant internet abone sayısı tahmininde epok ve nöron sayılarının MSE'ye etkileri

Nöron sayısı	Ham veri, 4 gizli katman, 200 epok	Ham veri, 4 gizli katman, 300 epok	Fark verisi, 4 gizli katman, 200 epok	Fark verisi, 4 gizli katman, 300 epok
5	103 372 429 168 686	212 723 928 420 451	114 273 110 330 877	73 810 737 067 962
6	72 792 381 685 651	35 424 567 103 569	125 626 242 957 551	168 654 393 520 305
7	39 233 568 373 856	43 583 185 200 773	98 940 613 868 950	121 043 114 623 547
8	12 534 189 118 512	7 345 580 283 566	68 328 766 168 187	29 576 611 902 927
9	38 142 136 543 627	50 893 812 622 672	40 924 478 763 544	6 397 890 592 870
10	34 819 580 966 603	5 093 151 558 321	66 321 389 397 979	23 286 000 397 753
11	7 634 777 123 538	24 055 638 534 752	6 617 551 125 098	54 977 045 32 471
12	5 702 084 737 105	3 961 980 830 335	7 459 601 406 314	4 284 053 973 187
13	6 265 535 754 964	4 929 011 703 515	7 382 710 797 740	4 359 361 990 415
14	6 768 232 453 517	4 587 367 648 668	8 659 633 872 537	4 972 078 738 550
15	5 769 878 775 520	4 670 301 063 026	6 128 297 836 560	3 476 462 839 440
16	5 854 569 591 216	6 064 601 754 006	5 737 183 782 245	3 928 902 997 037
17	4 991 598 277 164	3 627 588 388 454	6 026 150 669 620	3 454 460 687 360
18	3 805 000 965 569	3 026 358 542 387	3 643 131 988 895	3 829 069 205 336
19	4 294 410 945 206	4 607 328 029 554	4 487 491 581 246	3 246 134 523 892
20	4 357 631 529 788	3 182 830 380 948	4 049 994 377 436	3 074 280 476 878
21	5 302 957 835 367	4 154 008 335 888	444 0941 979 419	3 094 863 102 763
22	3 969 700 387 700	3 935 274 527 409	4 511 460 451 015	3 986 122 041 333
23	5 128 272 713 144	4 392 423 151 151	5 620 318 354 414	3 626 292 706 037
24	3 608 941 299 102	3 941 987 086 565	4 011 435 497 120	3 502 883 680 753
25	3 670 924 616 600	4 077 394 678 194	3 557 742 600 310	4 651 945 483 333
26	4 221 678 244 710	4 275 064 184 480	2 596 560 497 868	3 437 282 358 778
27	4 344 733 612 440	4 249 784 439 881	3 728 836 685 192	3 310 055 217 241
28	3 772 221 163 177	3 867 577 433 940	3 716 446 487 840	3 573 052 087 892
29	5 015 380 503 846	2 984 849 220 696	3 716 024 857 201	2 529 129 009 873
30	2 523 015 047 472	4 502 919 926 548	4 069 164 131 094	2 189 121 139 608
31	3 905 674 388 535	3 654 466 796 212	3 550 045 200 508	3 177 729 154 407
32	3 856 390 038 458	3 949 286 324 834	3 343 624 164 621	3 098 794 031 179
33	3 561 866 277 252	4 195 321 770 503	2 965 900 134 664	3 688 785 861 196
34	3 993 817 961 084	3 891 103 960 209	2 952 399 070 488	2 805 819 575 411
35	3 738 544 405 885	3 976 596 181 844	3 213 971 422 095	4 023 006 678 835
36	4 271 732 943 575	4 480 788 427 399	3 095 318 116 116	3 302 183 737 496
37	3 553 009 340 392	3 700 803 334 056	3 720 197 190 652	2 517 732 118 132
38	3 947 139 346 650	3 731 953 233 667	4 186 927 954 717	3 245 830 295 745
39	4 167 467 438 371	4 600 248 227 954	4 254 889 548 064	3 178 313 611 162
40	5 251 882 732 333	3 276 964 185 661	2 954 081 587 634	3 229 407 007 672

EK-4. Mobil abone sayısı tahmininde epok ve nöron sayılarının MAE'ye etkileri

Nöron Sayısı	Ham veri, 14 özellik, 5 gizli katman, 200 epok	Ham veri, 14 özellik, 5 gizli katman, 300 epok	Ham veri, 15 özellik, 4 gizli katman, 200 epok	Ham veri, 15 özellik, 4 gizli katman, 300 epok	Fark verisi, 13 özellik, 5 gizli katman, 200 epok	Fark verisi, 13 özellik, 5 gizli katman, 300 epok
5	3 887 618	1 285 990	3 555 894	3 329 038	4 388 298	2 412 394
6	1 331 232	1 677 566	1 651 431	1 387 339	1 737 172	1 353 977
7	1 628 482	1 031 565	1 533 106	1 131 801	1 470 654	1 692 079
8	912 735	1 096 628	900 121	1 150 547	1 023 227	866 048
9	1 521 310	1 131 038	1 137 589	844 105	1 569 371	1 122 401
10	895 123	792 722	1 005 738	1 097 261	894 584	1 033 081
11	880 206	865 592	880 752	768 720	872 375	783 538
12	1 174 194	836 951	910 494	1 073 726	940 079	826 794
13	839 036	845 500	941 863	795 790	889 564	807 705
14	844 870	771 561	881 321	847 448	894 321	803 132
15	852 825	811 482	823 687	869 751	875 698	810 119
16	905 272	789 139	816 709	837 399	940 268	732 330
17	791 551	739 433	759 873	793 272	850 023	744 154
18	773 897	733 676	817 908	824 913	871 088	756 644
19	813 718	774 325	810 621	774 707	874 439	817 583
20	796 275	785 310	797 426	1 150 597	807 709	784 199
21	824 743	754 949	806 869	822 712	823 867	768 324
22	774 983	846 637	771 485	804 077	857 354	775 655
23	762 266	763 999	829 784	816 799	876 978	815 744
24	773 927	792 541	831 790	783 220	774 839	784 741
25	823 379	745 555	833 250	736 695	784 417	715 448
26	851 841	775 578	786 397	801 714	842 781	740 684
27	740 111	803 478	849 231	781 759	801 170	761 175
28	866 703	766 370	742 614	791 172	838 493	759 962
29	776 342	729 024	762 387	753 737	844 820	701 217
30	849 624	780 806	783 120	726 879	831 524	773 347
31	784 309	786 532	807 023	793 392	874 726	736 078
32	786 283	791 391	839 106	715 768	836 283	686 327
33	821 711	779 188	833 711	685 573	843 481	837 228
34	809 554	758 859	862 485	728 058	804 217	771 158
35	785 700	696 690	792 599	735 581	819 665	732 132
36	794 312	704 870	762 241	736 742	751 155	752 126
37	826 598	789 007	761 114	753 373	781 384	762 887
38	785 118	763 518	766 973	671 433	788 715	703 211
39	786 020	728 232	792 699	788 161	776 495	750 577
40	764 164	743 357	876 191	782 986	738 673	668 963

EK-5. Mobil abone sayısı tahmininde epok ve nöron sayılarının MAPE'ye etkileri

Nöron Sayısı	Ham veri, 14 özellik, 5 gizli katman, 200 epok	Ham veri, 14 özellik, 5 gizli katman, 300 epok	Ham veri, 15 özellik, 4 gizli katman, 200 epok	Ham veri, 15 özellik, 4 gizli katman, 300 epok	Fark verisi, 13 özellik, 5 gizli katman, 200 epok	Fark verisi, 13 özellik, 5 gizli katman, 300 epok
5	0,049969	0,016107	0,045662	0,041678	0,056307	0,031088
6	0,016620	0,022592	0,022732	0,019365	0,021813	0,016705
7	0,020059	0,012964	0,018962	0,015381	0,019674	0,021637
8	0,011806	0,013845	0,011555	0,015519	0,013062	0,011304
9	0,018583	0,014228	0,014359	0,010967	0,019351	0,014203
10	0,011478	0,010309	0,012810	0,013895	0,011622	0,012994
11	0,011424	0,011326	0,011450	0,010034	0,011276	0,010248
12	0,014726	0,010969	0,011772	0,013555	0,012154	0,010817
13	0,010944	0,011055	0,012250	0,010427	0,011565	0,010559
14	0,010949	0,010132	0,011443	0,011100	0,011588	0,010530
15	0,011194	0,010572	0,010617	0,011420	0,011389	0,010656
16	0,011786	0,010369	0,010585	0,010983	0,012165	0,009640
17	0,010394	0,009710	0,009947	0,010433	0,011008	0,009851
18	0,010111	0,009544	0,010640	0,010821	0,011384	0,009947
19	0,010641	0,010160	0,010546	0,010177	0,011466	0,010724
20	0,010454	0,010240	0,010388	0,014567	0,010659	0,010220
21	0,010792	0,009950	0,010584	0,010773	0,010797	0,010076
22	0,010171	0,011095	0,010104	0,010579	0,011179	0,010217
23	0,009966	0,010019	0,010923	0,010752	0,011430	0,010707
24	0,010135	0,010353	0,010821	0,010320	0,010123	0,010335
25	0,010825	0,009763	0,010974	0,009680	0,010305	0,009416
26	0,011144	0,010166	0,010284	0,010562	0,011110	0,009759
27	0,009696	0,010556	0,011097	0,010308	0,010548	0,009982
28	0,011407	0,010137	0,009775	0,010368	0,010974	0,009969
29	0,010157	0,009569	0,009990	0,009843	0,011100	0,009118
30	0,011116	0,010296	0,010296	0,009483	0,010943	0,010143
31	0,010356	0,010362	0,010595	0,010384	0,011453	0,009560
32	0,010359	0,010439	0,011023	0,009393	0,010975	0,008976
33	0,010788	0,010208	0,010932	0,008944	0,011014	0,010936
34	0,010674	0,009961	0,011280	0,009554	0,010597	0,010052
35	0,010345	0,009151	0,010445	0,009595	0,010693	0,009552
36	0,010406	0,009195	0,010013	0,009726	0,009839	0,009883
37	0,010914	0,010367	0,010022	0,009944	0,010296	0,010064
38	0,010397	0,009993	0,010056	0,008798	0,010369	0,009182
39	0,010351	0,009502	0,010390	0,010433	0,010173	0,009842
40	0,010011	0,009764	0,011440	0,010314	0,009647	0,008829

EK-6. Mobil abone sayısı tahmininde epok ve nöron sayılarının MSE'ye etkileri

Nöron sayısı	Ham veri, 14 özellik, 5 gizli katman, 200 epok	Ham veri, 14 özellik, 5 gizli katman, 300 epok	Ham veri, 15 özellik, 4 gizli katman, 200 epok	Ham veri, 15 özellik, 4 gizli katman, 300 epok
5	34 712 720 257 849	4 835 694 806 694	29 745 438 723 041	28 344 334 411 571
6	5 284 011 251 863	7 989 336 034 416	7 541 856 796 208	6 077 879 244 314
7	7 870 210 107 544	3 768 471 098 375	7 154 584 961 399	3 654 803 927 550
8	1 349 766 857 496	3 806 526 134 369	1 377 069 431 020	3 784 217 093 142
9	8 241 988 437 291	3 943 610 690 148	2 767 481 500 288	1 091 730 841 745
10	1 362 398 132 596	1 012 120 714 399	1 797 842 968 806	3 553 494 868 652
11	1 166 397 689 800	1 054 034 747 138	1 194 338 913 715	963 197 114 842
12	4 383 723 992 483	1 016 565 802 684	1 262 652 647 742	3 662 839 619 560
13	1 050 203 721 276	1 016 481 562 809	1 329 618 402 528	981 450 829 780
14	1 108 674 488 870	921 765 068 718	1 241 540 812 946	1 053 907 473 361
15	1 134 476 787 905	1 039 349 627 061	1 167 324 845 809	1 058 552 773 440
16	1 252 348 351 771	916 192 328 045	1 058 158 466 124	1 027 536 224 965
17	994 480 277 625	876 695 324 008	976 672 301 910	1 000 724 827 546
18	970 780 887 182	888 095 731 580	1 015 884 781 608	998 578 310 000
19	1 072 618 678 634	984 495 367 268	1 027 995 082 110	1 008 967 506 175
20	996 123 749 927	890 915 626 115	1 037 199 477 515	3 714 773 883 853
21	1 058 748 722 736	911 723 505 609	1 063 719 488 127	1 020 403 990 904
22	978 560 830 232	1 022 710 379 555	968 985 644 135	936 235 646 881
23	911 814 406 704	887 795 941 593	1 034 433 419 450	967 217 299 550
24	965 109 108 995	920 309 581 079	1 012 123 194 566	958 350 989 244
25	1 008 031 874 188	854 490 002 619	1 023 962 284 843	886 366 958 905
26	1 076 376 955 309	931 811 247 186	1 000 801 748 524	1 001 317 033 115
27	891 836 894 619	891 659 376 917	1 055 434 540 550	974 997 571 682
28	1 085 849 889 751	847 369 380 810	902 956 007 756	901 127 200 999
29	950 993 323 390	861 805 651 912	970 535 748 308	881 092 460 161
30	1 021 559 576 480	902 148 939 755	961 241 439 712	818 585 744 661
31	986 936 249 669	903 157 299 928	1 015 961 078 104	919 914 039 086
32	973 632 651 042	954 241 229 786	1 078 339 293 012	804 241 877 361
33	1 039 640 355 523	854 445 153 574	1 076 154 993 933	747 844 565 235
34	989 096 776 424	866 133 903 653	1 173 759 317 983	811 318 245 928
35	941 957 768 095	749 303 633 618	1 072 172 304 593	840 883 013 685
36	963 417 093 301	715 427 982 836	985 634 951 864	855 117 188 946
37	1 006 672 418 625	971 372 400 196	922 516 075 760	863 294 458 240
38	955 816 851 192	858 211 427 851	936 384 373 342	747 113 379 132
39	930 394 382 939	847 383 246 430	976 062 004 107	926 894 991 487
40	957 782 638 347	867 163 564 549	1 194 639 746 587	972 424 326 721

EK-6. (devam) Mobil abone sayısı tahmininde epok ve nöron sayılarının MSE'ye etkileri

Nöron sayısı	Fark verisi, 13 özellik, 5 gizli katman, 200 epok	Fark verisi, 13 özellik, 5 gizli katman, 300 epok
5	42 195 218 049 785	15 248 690 884 659
6	7 810 054 385 190	5 816 018 478 079
7	5 863 743 684 981	9 232 705 993 591
8	2 427 070 462 339	1 192 334 798 130
9	7 877 715 998 602	3 889 483 424 231
10	1 237 634 665 656	3 548 503 182 538
11	1 210 391 272 022	994 820 794 715
12	1 395 748 049 877	1 057 550 525 857
13	1 235 838 495 791	968 575 843 545
14	1 198 936 243 134	982 619 071 524
15	1 230 716 603 845	1 023 336 008 281
16	1 392 214 488 565	871 163 765 684
17	1 142 011 340 188	836 111 564 997
18	1 123 346 200 050	910 470 422 226
19	1 094 136 038 009	1 046 516 653 458
20	992 639 322 873	991 085 516 195
21	1 079 924 663 606	939 332 417 221
22	1 064 540 083 130	883 358 562 801
23	1 207 399 338 720	1 038 518 528 181
24	978 544 703 467	987 078 485 124
25	986 577 458 949	774 726 822 851
26	1 070 088 146 550	893 746 453 756
27	983 443 784 470	868 154 123 764
28	1 148 988 952 328	875 882 828 536
29	1 186 745 923 492	750 632 880 331
30	1 054 564 075 011	937 368 965 886
31	1 306 663 990 465	888 560 246 351
32	1 033 069 383 464	796 119 850 139
33	1 112 223 892 659	1 077 022 469 291
34	976 156 554 684	901 335 029 006
35	1 100 005 392 198	888 037 215 336
36	949 699 983 579	896 624 093 930
37	989 448 939 680	913 285 588 163
38	1 073 189 125 103	792 135 569 183
39	961 568 334 963	869 741 184 582
40	943 977 723 010	727 193 676 577

EK-7. MMS miktarı tahmininde epok ve nöron sayılarının MAE'ye etkileri

Nöron sayısı	Ham veri, 5 gizli katman, 200 epok	Ham veri, 5 gizli katman, 300 epok	Fark verisi, 5 gizli katman, 200 epok	Fark verisi, 5 gizli katman, 300 epok
5	5,864767	5,336403	7,733129	8,519683
6	10,174407	9,581591	5,534097	5,117701
7	5,352156	5,493016	6,095413	5,319801
8	4,321184	4,110767	4,666658	3,303178
9	4,177080	3,327170	4,283484	3,374297
10	4,408808	2,606836	4,914479	3,301384
11	3,180719	2,457900	3,961477	4,051097
12	3,240631	2,283620	3,671009	2,430859
13	3,294391	2,422620	3,704767	2,259866
14	3,121772	2,600277	3,270543	2,337961
15	3,378298	2,640187	2,873554	2,389782
16	3,047291	2,813515	2,794187	2,517647
17	2,829005	2,196124	2,638234	2,611662
18	2,731267	2,119439	2,739000	2,084359
19	2,709700	2,077021	2,642823	2,295615
20	2,313994	2,066549	2,512660	2,044056
21	2,563762	2,130268	2,765535	2,122620
22	2,635820	2,044076	2,690987	2,179685
23	2,464432	2,036066	2,254051	2,442144
24	2,352836	2,026439	2,276985	2,087093
25	2,552919	1,967413	2,398519	2,051957
26	2,487590	1,975564	2,292315	2,030185
27	2,288778	1,989267	2,628498	2,051476
28	2,204634	2,052514	2,282422	1,942348
29	2,354296	2,093212	2,178334	2,024490
30	2,216095	1,982065	2,256644	2,007492
31	2,161310	1,927671	2,289014	1,933793
32	2,089263	1,996393	2,140278	2,037171
33	2,118905	1,986904	2,216532	1,931809
34	2,069673	1,899164	2,046864	1,948717
35	2,220112	2,100409	2,221029	1,869677
36	2,338988	2,008265	2,417854	1,889364
37	2,198080	2,019586	2,404631	2,118929
38	2,076893	1,940428	2,088668	1,997502
39	2,006736	1,880050	2,182735	2,013556
40	2,165990	1,803905	2,078842	2,020922

EK-8. MMS miktarı tahmininde epok ve nöron sayılarının MAPE'ye etkileri

Nöron sayısı	Ham veri, 5 gizli katman, 200 epok	Ham veri, 5 gizli katman, 300 epok	Fark verisi, 5 gizli katman, 200 epok	Fark verisi, 5 gizli katman, 300 epok
5	0,229346	0,170634	0,366638	0,430900
6	0,637767	0,515001	0,182371	0,212355
7	0,181488	0,282480	0,243354	0,267598
8	0,177939	0,156080	0,167405	0,132066
9	0,163206	0,143649	0,170761	0,140828
10	0,174022	0,125715	0,168395	0,137636
11	0,133691	0,123375	0,149805	0,249653
12	0,140489	0,117779	0,147579	0,122990
13	0,137221	0,121821	0,145220	0,124789
14	0,135567	0,126040	0,129916	0,122180
15	0,141576	0,129380	0,132329	0,125918
16	0,135454	0,128465	0,125016	0,126010
17	0,129525	0,121181	0,123093	0,132203
18	0,125896	0,117321	0,125770	0,114730
19	0,125585	0,116075	0,125263	0,118506
20	0,120159	0,118086	0,118742	0,120055
21	0,124536	0,124408	0,128205	0,119283
22	0,124190	0,121007	0,124367	0,124376
23	0,127078	0,118551	0,119940	0,122927
24	0,120503	0,120080	0,119012	0,121405
25	0,122532	0,116274	0,125330	0,125271
26	0,119056	0,114824	0,123392	0,120680
27	0,122593	0,116750	0,128892	0,123815
28	0,117221	0,122589	0,118816	0,117707
29	0,124032	0,125658	0,117772	0,121979
30	0,118018	0,118377	0,127170	0,121205
31	0,121221	0,116627	0,122755	0,119647
32	0,115594	0,117328	0,119305	0,126135
33	0,119382	0,120243	0,129212	0,116353
34	0,119726	0,115849	0,119615	0,115833
35	0,121740	0,118873	0,117081	0,112305
36	0,127477	0,120763	0,125881	0,116689
37	0,124592	0,119794	0,123933	0,128351
38	0,119828	0,117710	0,120772	0,122976
39	0,114905	0,113766	0,120173	0,118520
40	0,121296	0,113685	0,116610	0,122746

EK-9. MMS miktarı tahmininde epok ve nöron sayılarının MSE'ye etkileri

Nöron sayısı	Ham veri, 5 gizli katman, 200 epok	Ham veri, 5 gizli katman, 300 epok	Fark verisi, 5 gizli katman, 200 epok	Fark verisi, 5 gizli katman, 300 epok
5	97,460593	95,568209	159,765271	185,419063
6	203,023558	218,193581	102,776627	82,037874
7	92,057046	85,204320	109,443560	79,709091
8	49,783191	54,965086	70,334153	25,401338
9	50,307199	34,918353	52,114706	27,620099
10	54,875231	14,611373	77,724657	39,994823
11	24,660155	13,313318	42,608184	48,653977
12	25,903273	10,735383	34,380563	11,521396
13	26,063982	11,547104	39,144718	8,589977
14	22,534875	15,148496	29,844279	9,735785
15	32,478059	16,398494	16,680302	11,199288
16	23,376169	28,293458	16,098223	12,450642
17	17,451619	8,222685	14,004324	13,102647
18	15,871238	7,681782	20,001590	7,756427
19	15,707634	7,653679	12,764577	13,085444
20	9,564623	7,507966	13,142996	7,290882
21	12,271824	7,702497	15,520019	7,876029
22	13,196860	6,987671	15,318251	8,442725
23	11,150304	6,858263	9,766708	13,813226
24	10,717015	7,052143	10,531385	7,713505
25	13,060650	7,208182	9,762346	7,343531
26	13,419356	6,743473	8,741912	7,049087
27	9,242338	6,541463	17,529029	7,407867
28	8,906663	7,265350	9,063236	6,392087
29	9,860862	7,681026	8,333569	7,020302
30	8,791520	6,646824	8,516060	6,793798
31	7,864333	6,436373	9,308688	6,215233
32	7,498210	6,893629	7,881277	6,781321
33	7,597740	6,433102	8,090570	6,514438
34	7,230515	6,263127	7,376567	7,016189
35	8,816461	8,552796	10,262535	6,139140
36	10,645907	6,649289	11,572847	6,439946
37	8,402618	6,858554	11,581283	7,719884
38	8,109848	6,593012	7,338971	6,832806
39	6,795845	6,239262	8,557630	7,088583
40	8,018965	5,735837	7,678714	6,746813

EK-10. SMS miktarı tahmininde epok ve nöron sayılarının MAE'ye etkileri

Nöron Sayısı	Fark verisi, 13 özellik, 3 gizli katman, 200 epok	Fark verisi, 13 özellik, 3 gizli katman, 300 epok	Fark verisi, 14 özellik, 3 gizli katman, 200 epok	Fark verisi, 14 özellik, 3 gizli katman, 300 epok	Fark verisi, 14 özellik, 5 gizli katman, 200 epok	Fark verisi, 14 özellik, 5 gizli katman, 300 epok
5	5400	4021	4376	4116	5884	4410
6	4769	2827	3081	3055	5153	2961
7	5001	4256	3312	3291	3293	2187
8	3471	2723	3085	2955	2782	2946
9	2833	2809	3408	2459	2317	2191
10	2553	2401	2441	2380	3244	1923
11	2614	1935	2246	1924	2502	1960
12	2474	2003	2342	1964	2366	1947
13	2270	2085	2203	1901	2135	1831
14	2206	1889	2121	1947	2053	1838
15	2216	2027	2130	1903	1938	1862
16	2065	2006	1914	1843	1968	1921
17	2123	1941	2122	1822	2053	1868
18	1967	1832	2180	1848	2014	1813
19	1982	1931	2038	1928	1924	1934
20	2001	1916	2125	1895	1929	1875
21	2109	1919	1987	1797	1896	1881
22	1915	1888	1920	1917	1830	1870
23	1958	1856	1913	1832	1817	1815
24	1933	1732	1915	1843	1968	1764
25	1897	1916	2022	1798	1836	1853
26	1937	1801	1967	1857	1907	1778
27	1795	1888	1947	1861	1812	1840
28	1920	1945	1887	1866	1886	1844
29	1878	1833	1902	1761	1802	1772
30	1920	1819	1919	1867	1851	1922
31	1838	1806	1872	1830	1862	1831
32	1902	1836	1893	1815	1865	1801
33	1812	1869	1917	1891	1893	1808
34	1938	1882	1803	1835	1834	1762
35	1950	1802	1844	1863	1815	1836
36	1936	1923	1898	1832	1804	1905
37	1879	1843	1863	1774	1803	1759
38	1846	1848	1858	1755	1794	1886
39	1749	1756	1871	1804	1886	1879
40	1883	1938	1898	1850	1838	1744

EK-11. Mobil ses trafik hacmi tahmininde epok ve nöron sayılarının MAE'ye etkileri

Nöron sayısı	Ham veri, 5 gizli katman, 200 epok	Ham veri, 5 gizli katman, 300 epok	Fark verisi, 4 gizli katman, 200 epok	Fark verisi, 4 gizli katman, 300 epok
5	3,983880	4,927824	7,001384	4,426772
6	4,612072	3,099025	5,301214	2,473569
7	5,316033	2,341297	3,351620	3,849881
8	2,491418	3,115376	2,837903	3,025977
9	2,512957	2,372895	3,309186	2,300520
10	2,243940	2,214265	2,300030	2,531918
11	2,413724	2,398434	2,272080	2,331474
12	2,280294	2,317463	2,263852	2,244225
13	2,238957	2,240845	2,330807	2,239614
14	2,267329	2,236929	2,363185	2,095728
15	2,181535	2,235548	2,380204	2,239721
16	2,265877	2,304451	2,333581	2,144834
17	2,327985	2,203309	2,224472	2,231176
18	2,214598	2,260347	3,127853	2,198613
19	2,163296	2,217603	2,227943	2,081611
20	2,258168	2,347884	2,251649	2,255549
21	2,347696	2,137177	2,096313	2,042108
22	2,406192	2,248051	2,083750	2,196327
23	2,280165	2,253028	2,360296	2,081224
24	2,322837	2,203839	2,236223	2,107716
25	2,211552	2,257750	2,325838	2,199157
26	2,372169	2,089860	2,208935	2,001198
27	2,260903	2,610702	1,984531	2,199764
28	2,188347	2,282631	2,199609	2,175762
29	2,286861	2,305314	2,158304	2,067601
30	2,251052	2,423600	2,287739	2,060642
31	2,110725	2,216876	2,176047	2,099017
32	2,555361	2,239574	2,284393	2,091684
33	2,095538	2,036094	1,999483	2,173557
34	2,318033	2,162573	2,213794	2,119780
35	2,160784	2,177917	2,105759	2,134653
36	2,323485	2,189255	2,169774	2,133424
37	2,151832	2,385512	2,255913	2,092708
38	2,286201	2,254084	2,115530	2,397992
39	2,230921	2,334449	2,140398	2,082977
40	2,255954	2,121140	2,024294	1,995295

EK-12. Mobil ses trafik hacmi tahmininde epok ve nöron sayılarının MAPE'ye etkileri

Nöron sayısı	Ham veri, 5 gizli katman, 200 epok	Ham veri, 5 gizli katman, 300 epok	Fark verisi, 4 gizli katman, 200 epok	Fark verisi, 4 gizli katman, 300 epok
5	0,103678	0,106106	0,138989	0,082058
6	0,094313	0,056164	0,104921	0,047329
7	0,100199	0,048094	0,084240	0,088460
8	0,054419	0,058953	0,062246	0,063076
9	0,050472	0,048036	0,058385	0,046180
10	0,046370	0,045004	0,046535	0,055932
11	0,049051	0,048457	0,044330	0,046159
12	0,046889	0,047262	0,044474	0,043985
13	0,045493	0,046417	0,046688	0,044012
14	0,045673	0,045822	0,046923	0,042798
15	0,045600	0,045536	0,046619	0,044187
16	0,046202	0,046715	0,045496	0,041738
17	0,047502	0,045902	0,044023	0,043250
18	0,045657	0,046354	0,055915	0,043530
19	0,043996	0,045162	0,043967	0,041314
20	0,045922	0,048555	0,043756	0,043069
21	0,047757	0,043596	0,041315	0,039518
22	0,048972	0,045576	0,041380	0,043078
23	0,046843	0,045737	0,047202	0,040237
24	0,047318	0,044850	0,044610	0,040883
25	0,045276	0,046056	0,046077	0,042007
26	0,048295	0,042757	0,043047	0,039179
27	0,047216	0,052805	0,038722	0,042558
28	0,044506	0,045847	0,042573	0,041793
29	0,046454	0,047050	0,043892	0,039325
30	0,046989	0,047980	0,044536	0,040341
31	0,043920	0,044504	0,042613	0,040520
32	0,051253	0,045008	0,043717	0,040452
33	0,042401	0,041500	0,039345	0,041743
34	0,046958	0,043864	0,043645	0,039861
35	0,044467	0,043625	0,040496	0,040842
36	0,046511	0,043996	0,042255	0,041654
37	0,044182	0,047559	0,043688	0,040264
38	0,046194	0,044284	0,040355	0,045934
39	0,045422	0,046198	0,040678	0,040494
40	0,046239	0,043250	0,039462	0,037792

EK-13. Mobil ses trafik hacmi tahmininde epok ve nöron sayılarının MSE'ye etkileri

Nöron sayısı	Ham veri, 5 gizli katman, 200 epok	Ham veri, 5 gizli katman, 300 epok	Fark verisi, 4 gizli katman, 200 epok	Fark verisi, 4 gizli katman, 300 epok
5	42,942735	55,049741	109,954547	49,413982
6	58,332410	24,063995	66,710948	10,704238
7	74,388671	8,750704	28,302456	33,229559
8	11,552350	23,852558	18,316000	18,822107
9	9,953175	8,695763	28,349838	8,540061
10	8,022603	8,070737	9,552252	14,558656
11	9,261498	9,098127	8,840135	9,126185
12	8,404666	8,352895	8,717965	8,617738
13	7,866158	7,927309	9,156470	8,450196
14	8,303984	7,881198	9,050139	7,465840
15	7,584748	7,999206	9,534739	8,453606
16	8,285195	8,226878	8,927928	7,778388
17	8,721542	7,235967	8,627464	8,100475
18	7,748002	8,082579	27,488910	8,122128
19	7,571474	7,570317	8,509360	7,411404
20	8,252160	8,173455	8,862260	8,282956
21	8,654872	7,113292	7,750253	7,291717
22	8,983693	7,653580	7,453815	7,689667
23	7,957299	7,723892	8,909574	7,246564
24	8,423509	7,301011	8,313330	7,253096
25	7,597023	7,651148	8,778672	7,775909
26	8,666052	6,601523	8,079753	6,749653
27	7,955935	9,985188	7,106543	7,857200
28	7,758161	7,566433	8,008433	7,557882
29	8,093191	7,826632	7,646892	6,896967
30	7,988396	9,437698	8,232566	7,030831
31	6,928772	6,999116	7,759936	7,046829
32	9,771151	7,336475	8,332163	7,235651
33	7,215407	6,012287	6,925037	7,384033
34	8,539080	6,926437	8,002564	7,103492
35	7,455912	7,250941	7,551059	7,325866
36	8,070729	7,200586	7,825813	7,306929
37	7,256829	8,201153	8,312712	7,236239
38	8,151757	7,666072	7,021636	8,977863
39	7,548189	7,912493	7,761616	6,865014
40	7,676703	6,720107	6,854485	6,404767



Gazili olmak ayrıcalıktır