



T.C.
MUŞ ALPARSLAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MUŞ DEVLET HASTANESİ HASTA
RADYOLOJİK GÖRÜNTÜ SAYILARININ,
BİR ZAMAN SERİSİ OLARAK DERİN
ÖĞRENME YÖNTEMLERİ KULLANILARAK
GELECEK TAHMİNLERİNİN YAPILMASI**

Erkan YALDIZ

YÜKSEK LİSANS TEZİ

**Nükleer Enerji ve Enerji Sistemleri
Anabilim Dalı**

Ağustos-2021
MUŞ
Her Hakkı Saklıdır



T.C.
MUŞ ALPARSLAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MUŞ DEVLET HASTANESİ HASTA
RADYOLOJİK GÖRÜNTÜ SAYILARININ,
BİR ZAMAN SERİSİ OLARAK DERİN
ÖĞRENME YÖNTEMLERİ KULLANILARAK
GELECEK TAHMİNLERİNİN YAPILMASI**

Erkan YALDIZ

YÜKSEK LİSANS TEZİ

**Nükleer Enerji ve Enerji Sistemleri
Anabilim Dalı**

Danışman: Doç. Dr. Zeydin PALA

Ağustos-2021
MUŞ
Her Hakkı Saklıdır

TEZ KABUL ve ONAYI

Erkan YALDIZ tarafından hazırlanan “Muş Devlet Hastanesi Hasta Radyolojik Görüntü Sayılarının, Bir Zaman Serisi Olarak Derin Öğrenme Yöntemleri Kullanılarak Gelecek Tahminlerinin Yapılması” adlı tez çalışması 14/07/2021 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Muş Alparslan Üniversitesi Fen Bilimleri Enstitüsü Nükleer Enerji ve Enerji Sistemleri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak oybirliği ile kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Yaşar DAŞDEMİR
Erzurum Teknik Üniversitesi,
Mühendislik-Mimarlık Fakültesi,
Bilgisayar Mühendisliği Bölümü

.....

Danışman

Doç. Dr. Zeydin PALA
Muş Alparslan Üniversitesi,
Mühendislik-Mimarlık Fakültesi,
Yazılım Mühendisliği Bölümü

.....

Üye

Dr. Öğr. Üyesi İhsan TUĞAL
Muş Alparslan Üniversitesi,
Mühendislik-Mimarlık Fakültesi,
Yazılım Mühendisliği Bölümü

.....

Yukarıdaki sonuç;
Enstitü Yönetim Kurulu/...../..... Tarih ve/..... nolu kararı ile onaylanmıştır.

Doç. Dr. Sedat BOZARI
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Erkan YALDIZ

Tarih:14/07/2021

ÖZET

YÜKSEK LİSANS TEZİ

MUŞ DEVLET HASTANESİ HASTA RADYOLOJİK GÖRÜNTÜ SAYILARININ, BİR ZAMAN SERİSİ OLARAK DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK GELECEK TAHMİNLERİNİN YAPILMASI

Erkan YALDIZ

Muş Alparslan Üniversitesi
Fen Bilimleri Enstitüsü
Nükleer Enerji ve Enerji Sistemleri
Anabilim Dalı

Danışman: Doç. Dr. Zeydin PALA

Zaman serileri tahmin işlemleri başta bilim, sağlık ve mühendislik olmak üzere ticaretin birçok alanında kullanılmakta ve hayati derece öneme sahip bulunmaktadır. Zaman serileri tahmin sürecinde iki farklı yaklaşım kullanılmaktadır. Bunlardan birisi istatistik tabanlı yaklaşım, ikincisi ise makine öğrenmesi modelleri kullanılarak yapılan yaklaşımdır. Tahmin işleminde makine öğrenmesinin bir alt dalı olan derin öğrenme tabanlı yaklaşım oldukça yaygın olarak kullanılmaktadır. Her iki yaklaşımın da kendine has güçlü yanları olduğu gibi zayıf yanları da bulunmaktadır. Özellikle ARIMA ve Holt-Winters gibi istatistiksel tabanlı yaklaşımlar sağlamlık ve esnekliklerinden dolayı uzun yıllardan beri kullanılmaktadır. İstatistiksel tabanlı yaklaşım için R ortamında kullanılan ARIMA, ETS, TBATS, THETAF ve SES metodları ile eldeki verinin kısıtlı olması durumunda bile vasat neticeler elde edilebilmektedir. Oysa derin öğrenme yaklaşımları için verinin yetersiz olması ya algoritmanın hiç çalışmamasına yâda oldukça zayıf tahmin sonuçlarına neden olmaktadır. Ancak literatürde derin öğrenme ve istatistiksel tabanlı yaklaşımların birlikte hibrid olarak kullanılması daha iyi sonuçların elde edilmesine neden olduğu ifade edilmektedir.

Bu çalışmada Muş Devlet Hastanesi Radyoloji biriminden alınan 2010-2020 yılları arasındaki 11 yıllık, diğer bir ifadeyle 132 aylık radyolojik görüntü sayıları kullanılarak farklı gelecek tahminleri yapılmıştır. Tahminler için MLP, NNTAR, ELM gibi derin öğrenme algoritmaları yanında ARIMA, TBATS, HOLT-WINTERS, ETS, STL, THETAF ve SES gibi istatistiksel tabanlı algoritmalar da kullanılmıştır. Modellerin performanslarını değerlendirmek için de RMSE, MAE, MAPE ve MASE metrikleri kullanılmıştır.

Bu çalışmada kullanılan veriler bir zaman serisi olarak açıklama, modelleme ve tahmin sürecine uygun olarak ele alınmıştır. Bunun için verilerin tedarik edildiği hastanenin farklı birimlerindeki radyolojik görüntü sayıları dikkate alınarak aylık hasta akışını tahmin etmek için çok modellenmiş bir yaklaşım kullanılarak literatüre katkı sağlama amaçlanmıştır. Tahmin işlemlerinde zaman serisi çapraz doğrulama ve ileriye dönük tahmin olmak üzere iki farklı genel yaklaşım kullanılmış ve elde edilen sonuçlar değerlendirilmiştir.

Daha açık bir ifadeyle bu tezde araştırılan araştırma sorusu, radyoloji biriminin aylık geçmiş verilerine bağlı olarak gelecekteki hasta potansiyeli için hem istatistiksel hem de derin öğrenme tahmin modelleri yardımıyla planlamanın hangi oranda başarılı olacağını açığa çıkararak ilgili birimi geleceğe hazırlıklı hale getirmektir. Elde edilen bulguların, hastaneye gelen ve radyoloji birimine sevk edilen hasta akışını daha verimli yönetmede hastane yöneticilerine kolaylık sağlayarak hem hizmet kalitesini hem de hasta memnuniyetini artırarak hastanenin gelecek planlamasında önemli katkılar sunacağına inanılmaktadır.

2021, 50 Sayfa

Anahtar Kelimeler: Radyoloji birimi, radyolojik veriler, aylık radyoloji hasta akışı, zaman serileri, derin öğrenme modelleri, istatistik tabanlı modeller

ABSTRACT

MS THESIS

MAKING FUTURE PREDICTIONS OF MUŞ STATE HOSPITAL PATIENT RADIOLOGICAL IMAGE NUMBERS AS A TIME SERIES BY USING DEEP LEARNING METHODS

Erkan YALDIZ

**Muş Alparslan University
Natural and Applied Science
Department of Nuclear Energy and Energy Systems**

Advisor: Assoc. Prof. Dr. Zeydin PALA

Time series forecasting processes are used in many areas of commerce, especially in science, health and engineering, and have a vital importance. Two different approaches are used in the time series estimation process. One of them is the statistics-based approach, and the second is the approach using machine learning models. Deep learning-based approach, which is a sub-branch of machine learning, is widely used in forecasting. Both approaches have their own strengths as well as weaknesses. Statistical based approaches such as ARIMA and Holt-Winters have been used for many years due to their robustness and flexibility. For the statistical-based approach, mediocre results can be obtained with the ARIMA, ETS, TBATS, THETAF and SES methods used in the R environment, even when the available data is limited. However, for deep learning approaches, insufficient data causes either the algorithm not working at all or very poor prediction results. However, it is stated in the literature that using deep learning and statistical-based approaches together as a hybrid leads to better results.

In this study, different future predictions were made using the radiological image numbers of 11 years, in other words, 132 months, between the years 2010-2020, obtained from the Radiology unit of Muş State Hospital. In addition to deep learning algorithms such as MLP, NNTAR, ELM, statistical-based algorithms such as ARIMA, TBATS, HOLT-WINTERS, ETS, STL, THETAF and SES were also used for predictions. RMSE, MAE, MAPE and MASE metrics were used to evaluate the performance of the models.

The data used in this study were handled as a time series in accordance with the explanation, modeling and estimation process. For this purpose, it is aimed to contribute to the literature by using a multi-model approach to estimate the monthly patient flow, taking into account the number of radiological images in different units of the hospital where the data are supplied. Two different general approaches, time series cross validation and forward estimation, were used in estimation processes and the results were evaluated.

To put it more clearly, the research question investigated in this thesis is to prepare the relevant unit for the future by revealing to what extent the planning will be successful with the help of both statistical and deep learning prediction models for the future patient potential depending on the monthly historical data of the radiology unit. It is believed that the findings obtained will make important contributions to the future planning of the hospital by increasing both the service quality and patient satisfaction by facilitating the hospital managers in managing the patient flow to the hospital and referred to the radiology unit more efficiently.

2021, 50 Pages

Keywords: Radiology unit, radiological data, monthly radiology patient flow, time series, deep learning models, statistics-based models

TEŐEKKÖR

Bu alıőmada ncelikle benden vazgeemeyen cesaretlendiren ve tez boyunca yardımını esirgemeyen deęerli danıőman hocam Do. Dr. Zeydin PALA' ya, hayatımın her anında olan ve desteęini hibir zaman eksik etmeyen aileme teőekkör ederim.

Erkan YALDIZ
MUŐ-2021



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
SİMGELER ve KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ	1
2. TEMEL BİLGİLER	4
2.1 R Programlama Dili	4
2.2 Radyoloji.....	5
2.3 Tahmin	6
2.4 Zaman Serisi Yöntemleri	8
2.4.1 Zaman serisi bileşenleri	10
2.4.1.1 Trend.....	10
2.4.1.2 Mevsimsel dalgalanmalar	10
2.4.1.3 Konjonktürel dalgalanmalar	10
2.4.1.4 Düzensiz hareketler.....	10
2.4.2 Derin öğrenme modelleri	11
2.4.2.1 Neural network autoregression (NNAR)	12
2.4.2.2 Multiplayer perceptrons (MLP)	14
2.4.2.3 Extreme learning machine (ELM)	15
2.4.3 İstatistiksel modeller	17
2.4.3.1 Simple exponential smoting (SES).....	17
2.4.3.2 Holt-Winter modeli.....	18
2.4.3.3 Exponential Smoting (ETS).....	18
2.4.3.4 Auto-arima	19
2.4.3.5 Tbats.....	20
2.4.3.6 Seasonal and trend decomposing time losess (STL)	20
2.5 Performans ölçümleri.....	21
2.5.1 MAPE	21
2.5.2 MAE.....	21
2.5.3 MASE	22
2.5.4 RMSE.....	22
3. BULGULAR.....	23
3.1 Veri Bilgileri	23
3.2 Tahmin Analizleri	23

3.2.1 12-Aylık tahmin analizleri: zaman serisinin 120-aylık eğitim/12-aylık test için ayrılması	24
3.2.2 24-Aylık tahmin analizleri: zaman serisinin 108-aylık eğitim/24-aylık test için ayrılması	25
3.2.3 30-Aylık tahmin analizleri: zaman serisinin 102-aylık eğitim/30-aylık test için ayrılması	26
3.2.4 36-Aylık tahmin analizleri: zaman serisinin 96-aylık eğitim/36-aylık test için ayrılması	27
3.2.5 42-Aylık tahmin analizleri: zaman serisinin 90-aylık eğitim/42-aylık test için ayrılması	28
3.2.6 48-aylık tahmin analizleri: zaman serisinin 84-aylık eğitim/48-aylık test için ayrılması	29
3.2.7 54-Aylık tahmin analizleri: zaman serisinin 78-aylık eğitim/54-aylık test için ayrılması	30
3.2.8 60-Aylık tahmin analizleri: Zaman serisinin 72-aylık eğitim/60-aylık test için ayrılması	31
4. MODEL KARŞILAŞTIRMALARI	33
4.1 İstatistiksel ve Derin Öğrenme Tabanlı Model Karşılaştırmaları	33
4.1.1 12-Aylık tahminler için model karşılaştırmaları	33
4.1.2 24-Aylık tahminler için model karşılaştırmaları	33
4.1.3 30-Aylık tahminler için model karşılaştırmaları	34
4.1.4 36-Aylık tahminler için model karşılaştırmaları	34
4.1.5 42-Aylık tahminler için model karşılaştırmaları	35
4.1.6 48-aylık tahminler için model karşılaştırmaları	36
4.1.7 54-aylık tahminler için model karşılaştırmaları	36
4.1.8 60-aylık tahminler için model karşılaştırmaları	37
4.2 Zaman Serileri için Çapraz-Doğrulama	37
4.3 Mape hata metriğine göre hata değerlerinin grafiksel incelenmesi	39
5. SONUÇLAR ve ÖNERİLER	44
5.1 Sonuçlar	44
5.2 Öneriler	45
KAYNAKLAR	46
ÖZGEÇMİŞ	50

SİMGELELER ve KISALTMALAR

Kısaltmalar

AUTO ARIMA	:Auto Regressive Integrated Moving Average
ELM	:Extreme learning machine
ETS	:Exponential Smoting
MAE	:Mean Absolute Error
MAPE	:Mean Absolute Percentage Error
MASE	:Mean Absolute Scaled Error
MLP	:Multiplayer Perceptrons
NNAR	:Neural network Autoregression
RIS	:Radiology Information System
RMSE	:Root Mean Squared Error
STL	:Seasonal and Trend Decomposing Time Losess
SES	:Simple Exponential Smoting
TBATS	:Exponential smoothing state space model with Box-Cox transformation, ARMA errors, Trend and Seasonal components
THETAF	:Theta Method Forecast
VAE	:Variational Autoencoder
WCH	:West China Hospital

ŞEKİLLER DİZİNİ

Şekil 2. 1 Elektromanyetik dalga örnekleri (Gökhan, y.y.).....	5
Şekil 2. 2 Yapay Sinir Ağı (YSA) ve Derin Öğrenme Sinir Ağı Karşılaştırması (Çarkacı ve ark., 2018; Kın ve ark., 2019).	11
Şekil 2. 3 Derin Öğrenmelerde Performans Grafiği (Brownlee ve ark., 2016).....	12
Şekil 2. 4 Sinir Ağları mimarisi dört giriş düğümü, iki gizli katman ve bir düğüm çıkış katmanından oluşur (Sena ve Nagwani, 2016).	13
Şekil 2. 5 Çok katmanlı yapay sinir ağı örneği (Neural Network, 2016).	15
Şekil 2. 6 ELM Yapay sinir ağı katmanları(Cai ve ark., 2020).....	16
Şekil 3. 1 2010-2020 yıllarına ait 132-aylık veri setinin ayrıştırma grafiği	24
Şekil 3. 2 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 12-aylık tahmin grafikleri	25
Şekil 3. 3 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 24-aylık tahmin grafikleri	26
Şekil 3. 4 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 30-aylık tahmin grafikleri	27
Şekil 3. 5 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 36-aylık tahmin grafikleri	28
Şekil 3. 6 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 42-aylık tahmin grafikleri	29
Şekil 3. 7 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 48-aylık tahmin grafikleri	30
Şekil 3. 8 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 54-aylık tahmin grafikleri	31
Şekil 3. 9 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 60-aylık tahmin grafikleri	32
Şekil 4. 1 Test verisi sabit olarak uygulanan Zaman serilerinde Çapraz-Doğrulama	38
Şekil 4. 2 Zaman serilerinde AUTO.ARIMA algoritması için uygulanan 8 tahmin analizi.....	39
Şekil 4. 3 Zaman serilerinde ETS algoritması için uygulanan 8 tahmin analizi	39
Şekil 4. 4 Zaman serilerinde ELM algoritması için uygulanan 8 tahmin analizi	40
Şekil 4. 5 Zaman serilerinde HOLT-WINTERS algoritması için uygulanan 8 tahmin analizi.....	40
Şekil 4. 6 Zaman serilerinde NNAR algoritması için uygulanan 8 tahmin analizi	41
Şekil 4. 7 Zaman serilerinde MLP algoritması için uygulanan 8 tahmin analizi	41
Şekil 4. 8 Zaman serilerinde STL algoritması için uygulanan 8 tahmin analizi	42
Şekil 4. 9 Zaman serilerinde SES algoritması için uygulanan 8 tahmin analizi.....	42
Şekil 4. 10 Zaman serilerinde THETAF algoritması için uygulanan 8 tahmin analizi ..	43
Şekil 4. 11 Zaman serilerinde TBATS algoritması için uygulanan 8 tahmin analizi.....	43

ÇİZELGELER DİZİNİ

Çizelge 3. 1	Çalışmada kullanılan 11 yıllık, 12-aylık veri seti.....	23
Çizelge 3. 2	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 12-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	24
Çizelge 3. 3	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 24-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	26
Çizelge 3. 4	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 30-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	27
Çizelge 3. 5	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 36-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	28
Çizelge 3. 6	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 42-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	29
Çizelge 3. 7	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 48-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	30
Çizelge 3. 8	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 54-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	31
Çizelge 3. 9	İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 60-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri.....	32
Çizelge 4. 1	12-aylık MAPE tahmin ortalaması.....	38
Çizelge 5. 1	Tez kapsamında yapılan 8 adet tahmin analizi ve mape ortalamaları.....	44

1. GİRİŞ

Yarınlara daha donanımlı olarak hazırlanmak için mutlak suretle geçmiş tecrübelerden faydalanmak ve geçmiş süzgecinden geçmek gerekmektedir. Geçmiş bilinmeden geleceğe hazırlanmak istenilen neticeyi vermeyecektir. Dolayısıyla hayatın her alanında geçmişe bakarak geçmişten ders çıkarma ve daha emin adımlarla geleceğe hazırlıklı olarak yürüme oldukça büyük önem arz etmektedir.

Zaman serileri tahmin analizi eldeki verilerden hareketle gelecek verileri tahmin etme sürecine dayanmaktadır. Son zamanlarda yapay zekâ alanındaki gelişmeler (Pala ve Özkan, 2020) ve bu alanın birer alt dalı olan makine öğrenmesi ve derin öğrenme alanlardaki derinlemesine çalışmalar (Pala ve ark., 2017; Pala ve Şana, 2020) birçok uygulamada olduğu gibi tahmin uygulamalarında da önemli mesafeler kat etmiştir. Zaman serileri ekonomik büyüme tahminlerinde, fiyat/satış tahminlerinde, sağlıkta (Yaldız ve Pala, 2018), güneş lekeleri tahmininde (Pala ve Atıcı, 2019) ve radyasyon tahmini (Pala, 2021; Pala ve ark., 2019; Pala ve ark., 2017) gibi birçok alanda kullanılmaktadır.

Literatürde zaman serilerinin tahmin işlemi için istatistiksel ve makine öğrenmesi (Ünlük ve Pala 2019; Pala, 2019) metotları olmak üzere iki farklı temel yaklaşım kullanılmaktadır (Pala ve Pala, 2020). Birbirlerinden tamamen farklı olan bu iki yaklaşım aynı amaç için kullanılmaktadırlar. Bu iki yöntemin kullanıldığı hibrid uygulamalar da mevcuttur (Pala, 2019). Zaman serisi tahmin işlemlerinde kullanılan bu iki yaklaşımın kuvvetli yanları olduğu gibi zayıf yanları da bulunmaktadır. Dolayısıyla her iki yaklaşımından da tahmin işlemlerinden mükemmel performans beklemek olası değildir.

Literatürde tahmin işlemleri için kullanılan veri seti için doğru metodu seçmenin zorluğuna da işaret edilmektedir (Brockwell ve Davis, 2016). Bundan dolayı her veri seti için süper tahmin yapabilecek bir metot bulunmamaktadır (Wolpert ve Macready, 1997).

Sağlıklı bir geleceğin kurulması şüphesiz sağlıklı bireylerin yetiştirilmesi ile mümkün olmaktadır. Geçmişten gelen araştırmalara günümüzde yenileri eklenerek devam etmektedir. Hastaneler ve hastane birimlerinin sağlıklı işlemesi için de çok sayıda araştırma yürütülmektedir. Hastane birimlerinin performansları ve hasta odaklı çalışmaları oldukça önemlidir. Hastane ortamında tanı amaçlı olarak çok sayıda cihaz kullanılmaktadır. Teknolojik yeniliklerin hızla gelişmesi ile birlikte sağlık çalışanlarının en büyük yardımcıları olan görüntüleme cihazlarına son yıllarda talep oldukça artmıştır.

Görüntüleme cihazlarının çeşitliliği ve sayısı hasta potansiyelini etkilemektedir. Ancak görüntüleme cihazlarına olan talebin geçmiş dönemlere bakılarak hasta potansiyeline göre belirlenmesi, planlanması ve geleceğe hazır olması oldukça büyük önem arz etmektedir. Nasıl ki bir işletmede yetkili kişi belli dönem aralıklar ile müşteri potansiyelini ve müşteri profili noktasında tahmin süreçlerine başvurma gereği duyuyorsa hasta birimleri için de aynı şeyleri söylemek mümkündür.

Literatürde, acil biriminin hasta akışının tahminiyle ilgili çalışmalar yeterli sayıda olmasına rağmen özellikle radyolojideki görüntü sayılarının tahminiyle ilgili sınırlı sayıda çalışma bulunmaktadır.

Yazarlar yaptıkları çalışmada (Jones ve ark., 2008) üç ayrı hastanenin 2005-2007 yılları arasındaki verilerini kullanarak acil departmanının günlük hasta yoğunluğunu ARIMA, ANN gibi modeller ile 30 günlük tahminler yapmışlardır. Regresyon tabanlı modellerin günlük tahmin işleminde daha başarılı olduklarını ifade etmişlerdir.

Başka bir çalışmada (Jilani ve ark., 2019) UK’de dört hastaneden tedarik ettikleri Ocak-2011-Aralık-2015 arasındaki günlük zaman serisi verilerini kullanarak acil polikliniğine gelen hasta tahmini yapmak için sezgisel tabanlı bulanık mantık modelini tanımlamışlardır. Tahmin işleminde ARIMA ve neural networks modellerini kullanmışlardır. Tahmin performanslarını değerlendirmek için mean absolute percentage errors (MAPE) ve root mean square errors (RMSE) metriklerini kullanmışlardır. Özellikle kısa süreli tahminler için model performansının kabul edilebilir aralıkta olduğunu ifade etmişlerdir.

Harrou ve arkadaşları (2020) çalışmalarında variational autoencoder (VAE) algoritmasını kullanarak acil durum servisindeki günlük ve saatlik ziyaretleri zaman serilerini kullanarak derin öğrenme frameworkları yardımıyla tahmin etmeye çalışmışlardır. Yazarlar sonuçlarında, VAE modelinin diğer derin öğrenme algoritmalarından daha iyi bir performans sergilediğini ifade etmişlerdir.

Yazarlar kendi çalışmalarında (Xu ve ark., 2016) ARIMA ve LR'yi ardışık bir şekilde birleştiren hibrit bir otoregresif entegre hareketli ortalama doğrusal regresyon (ARIMA-LR) yaklaşımı önermişlerdir. Hibrit yaklaşımın tahmin performansını elde ettikleri gerçek verisetlerini kullanarak karşılaştırmışlardır. Önerilen hibrit ARIMA-LR modeli ile tahmin doğruluğu açısından mevcut modellerden daha iyi performans gösterdiğini göstermişlerdir.

Golmohammadi ve arkadaşları (Golmohammadi ve ark., 2016) çalışmalarında yerel bir hastanenin acil servisinden alınan ikincil verileri kullanarak logistic Regression

ve neural networks yardımıyla, karar destek aracı olarak kullanılabilir ve acil servislere yatkınlığı azaltmaya yardımcı olacak bir tahmin modeli geliştirmişlerdir. Sonuçta, çalışmalarının hasta kabul olasılığını doğru bir şekilde tahmin edebildiğini ve böylece hastane operasyonlarında önemli sorunlar olan acil servise biniş ve tıkanıklığı azalttığını ifade etmişlerdir.

Shahid ve arkadaşları (2016) yaptıkları çalışmada, radyoloji birimine ultrason için gelen hastaların 2001-2015 yılları arasındaki dataları aylık zaman seri olarak tedarik etmişler ve ARIMA modelini kullanarak Haziran 2015-Mayıs 2017 aralığında aylık tahmin yapmışlardır. Sonuç olarak uzun ve kısa vadeli tahminlerde ARIMA modelinin oldukça iyi performans sergilediğini ifade etmişlerdir.

Diğer bir çalışmada (Zhang ve ark., 2020) 2013-2016 arasındaki dört yıllık veriyi Radiology Information System (RIS) of West China Hospital (WCH) temin etmişlerdir. Günlük tahmin işlemi için ARIMA, lasso, linear-SVR, radial-SVR, random forest ve adabost modellerini kullanmışlardır. Model performanslarını değerlendirmek için MAPE metriğini tercih etmişlerdir. Kullanılan modeller içinde ARIMA modelinin daha başarılı olduğunu ifade etmişlerdir.

Mevcut çalışmalardan farklı olarak hastanenin tüm noktalarından radyoloji birimine sevk edilen hastaların aylık radyolojik vaka tahminini çoklu zaman serisi modelleriyle yapmak ve bunun gelecekteki etkilerini araştırmak bu çalışmanın literatüre katkısı olmaktadır.

Literatürdeki tahmin işlemleri ile alakalı darboğazlar dikkate alınarak bu çalışmada radyolojik görüntü sayılarına dayalı verisetinin tahmin işlemi gerçekleştirilecektir. Mevcut çalışmada tanı araçlarının başından gelen radyolojik görüntüleme taleplerinin aylık olarak hangi oranlarda arttığını ve gelecekte hastanenin bu talebe karşı hazırlıklı olması için hangi adımları atması gerektiğini bir problem olarak kabul ettik. Söz konusu problemin çözümü için geçmiş verileri kullanarak teknoloji harikası algoritmalarla tahminler yapmaya çalıştık.

Daha anlaşılır bir ifadeyle verilerin elde edildiği hastanenin bir sonraki hasta potansiyellerini görmelerini ve bu sayede hastalara daha iyi hizmet vermelerini hem istatistiksel hem de derin öğrenme tahmin modellerinden yapılan çalışmaların hangisinin daha fazla katkı sağlayacağı tespit etmektir.

2. TEMEL BİLGİLER

Bu bölümde analizleri gerçekleştirmek için kullanılan R programlama dili, radyoloji alanı ile alakalı bilgiler, tahmin, zaman serisi yöntem ve bileşenleri ile alakalı bilgiler verilmektedir.

2.1 R Programlama Dili

Bu çalışmada yapılan analizlerin tamamı açık kaynak kodlu, istatistiksel hesaplama ve grafikler için bir dil ve ortam olan R versiyon 4.1.0 (2021-05-18) kullanılmıştır.

R programlama dili, 1993 yılında Ross Ihaka ve Robert Gentleman tarafından geliştirilen açık kaynak kodlu bir yazılım dilidir. İstatistiksel ve grafiksel yöntemlerin kapsamlı bir kütüphaneye sahiptir. Script olarak çalışan fonksiyonlardan oluşan bir istatistik tabanlı yazılım geliştirme kütüphanesidir (“The Comprehensive R Archive Network”, y.y.). Yeni Zelanda Aucland Üniversitesi İstatistik bölümünde geliştirilmiş bu dil zamanla yaygın bir kullanıma sahip olmuştur (Ihaka ve Gentleman, 1996). R kütüphanelerinin çoğu R dilinde yazılmıştır, ancak hesaplama işlemlerinin ağır olduğu işler için C, C ++ ve Fortran kodları tercih edilmektedir. Diğer dillerden farklı olarak R programlama dili verilere doğrudan erişim sağlamak yerine özel veri yapıları sayesinde verilere referanslar ile erişim sağlar (Özdemir ve ark., 2018). Açık kaynak kodlu olduğu için birbirinden farklı alanlarda birçok geliştirici tarafından geliştirilmiş fonksiyon kütüphanelerine sahiptir. R programlama dili betik olarak çalışması sebebiyle bütün işletim sistemleri ile uyumlu olarak çalışır. R programlama dili, sadece akademik araştırmalar veya çalışmalarda değil aynı zamanda birden fazla büyük şirket tarafından da kullanılmaktadır; Uber, Google, Airbnb, Facebook’un da içinde bulunduğu şirketlerde de R programlama dilini kullanmaktadır.

R ile veri analizi; Yapılan analizlerin çıktıları belirli aşamalardan geçmektedir bunlar, programlama, dönüştürme, keşfetme, modelleme ve iletme gibi adımlardan oluşmaktadır;

Program: R programlama dili açık kaynak kodlu ve erişilebilir bir programlama aracıdır.

Dönüşüm: R programlama dili, özellikle veri bilimi için tasarlanmış kütüphanelerden oluşur.


Keşfet: Verileri araştırıp hipotezini geliştirir ve analiz eder.

Model: R programlama dili, verileriniz için doğru modeli yakalamak için çok çeşitli araçları bir arada sunar.

İletişim: Kodları, grafikleri ve çıktıları R Markdown ile bir rapora entegre edip kullanıcıya ve dünya ile paylaşmak için Shiny uygulamaları oluşturmalarına yardımcı olur.

2.2 Radyoloji

Milyonlarca yıldır insanlar uzaydan gelen kozmik ışınlarla maruz kalmaktadırlar. Ayrıca insan sürekli olarak çeşitli radyoaktif kaynaklara maruz kalmakta ve bunlar hem vücudunda hem de çevresinde bulunmaktadır (Atakan, 2006). Radyasyon kaynakları var olduğu sürece bu kaynaklara maruz kalma devam edecektir ve tamamen önlenmesi mümkün değildir. 1985 yılında W. Conrad Roentgen tarafından X ışınlarının keşfi ve 20. yüzyılın başlarında Marie Curie' nin radyoaktiviteyi keşfetmesi ile birlikte radyasyon kullanımı tıp ve endüstriyel alanlarda giderek yaygınlaşmış ve hayatımızın kaçınılmaz bir parçası haline gelmiştir (TAEK, 2014). Şekil 2.1' de hayatımızda yer alana elektromanyetik dalgalar yayma örnekleri ve aralıkları verilmiştir.



Şekil 2. 1 Elektromanyetik dalg örnekleri (Gökhan, 2017)

Sağlık çalışanlarının hastalığa tanı konma aşamasında en büyük yardımcıları olan radyoloji cihazları sağlık kuruluşları için önemlidir. Son zamanlarda, yapay radyasyon kaynakları arasında tıbbi ışınlama en büyük paya sahip olup, tanısal radyolojik incelemeler en çok kullanılanlardır (Türkiye Cumhuriyeti Sağlık Bakanlığı, Sağlık İstatistikleri Yıllığı, 2019). Çizelge 2.1 ve Çizelge 2.2’ de paylaşılan veriler her ne kadar ülkemiz istatistikleri olsa da tüm ülkeler için genellenebilir bir durum olduğunu göstermektedir.

Çizelge 2.1 Sektörlere Göre Hastanelerde Görüntüleme Sayısı, 2019 (T.C. Sağlık Bakanlığı, 2020)

	MR	BT	Ultrason	Doppler Ultrason	EKO	Mamografi
Sağlık Bakanlığı	10.930.353	14.107.645	16.579.909	18.952.089	6.855.133	1.559.142
Üniversite	2.176.295	2.996.732	2.636.428	1.213.426	982.550	296.278
Özel	3.089.036	2.295.910	6.328.809	2.352.643	2.022.627	397.395
Toplam	16.195.684	19.400.287	25.545.146	22.518.158	9.860.310	2.252.815

Çizelge 2.2 Sektörlere Göre Hastanelerde Görüntüleme Sayısı, 2018 (T.C. Sağlık Bakanlığı, 2019)

	MR	BT	Ultrason	Doppler Ultrason	EKO	Mamografi
Sağlık Bakanlığı	10.180.784	13.255.939	17.998.067	14.526.373	6.535.140	1.452.964
Üniversite	1.967.369	2.632.116	2.409.065	983.610	937.498	306.181
Özel	3.135.503	2.433.929	5.629.537	1.983.226	1.678.765	380.668
Toplam	15.283.656	18.321.984	26.036.669	17.493.209	9.151.403	2.139.813

Bir hastalığın sağlık kuruluşlarındaki ilk amacı doğru tanı konulması gerekir. Bu açıdan sağlık personellerinin doğru tanı konusunda görüntüleme cihazlarının yerinin ayrı bir önemi vardır.

2.3 Tahmin

Tahmin yani diğer adıyla öngörü süreci, daha önceden bahsettiğimiz gibi, geçmiş ve şimdiki zaman verileri kullanılarak gelecek verilerini değerlendirmek için kullanılır. Son zamanlarda hastanelere giden hastaların tahmini üzerine birçok çalışma yapılmıştır. Bu tür çalışmaların birisi Milner tarafından yapıldı ve acil servise gelen hastaların toplamı için bir ARIMA modeli tahmini sunuldu (Milner, 1988; Kadri ve ark., 2014; Sun ve ark., 2009; Jones ve ark., 2002; Shi ve ark., 2011).

Ayrıca, kısa vadeli tahmin modelleri de birçok çalışmada incelenmiş, ARIMA, doğrusal regresyon, üstel yumuşatma ve Monte Carlo benzetim tabanlı modeller gibi

teknikler kullanılmıştır (Abraham ve ark., 2013; Ekström ve ark., 2013; Bergs ve ark., 2013; Mielzarek, 2013; Bouleux ve ark., 2014).

Bu arada hastanede bulunan servislerin hasta yoğunluklarında karşılaşılan zorlukların önüne geçmek için birden fazla makale var ve bu makaleler çıktıkları dönemin favori makaleleri olarak kabul edilirler. Çünkü bu makaleler önemli ve öngörülemeyen insan ihtiyaçlarını tahmin etmişlerdir. Kategorik olarak, sinir ağının radyal temel işlevini kullanarak kısa vadeli acil durum hükümlerini tahmin etmeye ilgi gösteren araştırmalar vardır (Mohammadi ve ark., 2014; Afilal ve ark., 2016).

Son olarak, belirli bir zaman diliminde hastane randevularının sayısını tahmin etmek, üstlenilmesi oldukça zor bir iştir. Bu nedenle, personel ile uyumsuz hastalar hastanenin belirli bazı servislerinin kalabalık olmasına neden olabilir ayrıca hastanenin düşük performansına ve hasta memnuniyetsizliğinin artmasına neden olabilir. Bu durum hali hazırda yatan durumda olan hastaları da etkileyebilir.

Matematiksel modeller normalde hastaneyi ziyaret eden hastaların sayısını tahmin etmek için kullanılır ve yaygın olarak kullanılan diğer modellerin geliştirilmesine yardımcı olmuştur. Bu tahmin modelleri günlük, haftalık, aylık, yıllık ve mevsimsel zaman dilimlerine bölünen lineer regresyona sahip zaman serisi modelleri oluşturulur. Bazı çalışmalar haftalık veya günlük verilerin hastane hasta girişleri için en güçlü belirleyici olduğunu gösterse de aylık veriler ile hastaneye giriş yapan ve radyolojik görüntüleme çekilen hasta hacmini tahmin etmek için kullanılıyor (Ekström ve ark., 2015).

Hastanenin hasta ziyaretlerini tahmin etmek aynı zamanda sağlık personelleri ve servis hasta ziyaretlerinin daha iyi planlanmasını sağlamak için bir model ve ayrıca hasta akışını önlemek için verimi artırır. Bu, uzun vadede, bu alandaki daha önceki araştırmacıların güvendiği bağımsız değişkenleri kullanarak hastaların güvenliğini güçlendirmeye yardımcı olabilir. Hareketli ortalamalar gibi çeşitli tahmin yöntemleri, Üstel yumuşatma, Winters yöntemi, sezgisel yöntemler vb. hastaneye gelip radyolojik görüntü istenen hasta hacmini tahmin etmek için farklı literatürlerdeki farklı araştırmacılar tarafından farklı algoritmalar kullanılmıştır.

R ortamında tahmin işlemleri için istatistik tabanlı modeller arasında auto-arima, holt-winters, simple exponential smoothing (ses), Seasonal and Trend decomposition using Loess(stl), tbats ve ets gibi modeller kullanılırken neural network autoregression (NNAR), multilayer perceptrons (MLP) ve extreme learning machine (ELM) gibi derin

öğrenme algoritmaları da yaygın olarak kullanılmaktadır (Zun, 2009; Ekström ve ark., 2015; Bergs ve ark., 2014; Jones ve ark., 2008).

2.4 Zaman Serisi Yöntemleri

Zaman serileri analizi, diğer bir ifadeyle zaman serilerinin tanımı ve araştırılması, hipotez testi ve tahmin olarak alt bölümlere ayrılabilir (Brockwell ve Davis, 2016). Tahmin işlemi aynı zamanda bu tezin de konusunu oluşturmaktadır. Zaman serisi tahmini alanı, söz konusu gözlem dizisinin gelecekte nasıl devam edeceğini tahmin etmeyi amaçlamaktadır. Analiz, gözlemlenen veri noktalarının altında yatan fenomeni anlamak için yapılır ve geçmiş verileri dikkate alır.

Zaman serileri, farklı zaman dilimlerinde ardışık ve karakteristik olarak düzenli gözlemlerin ve olguların bir derlemesidir. Gerçekte zaman serisi analizinin benzersiz niteliği, gözlemler genellikle özerk olmadığından analistin zaman dizisini göz önünde bulundurması gerektiğidir. Diğer istatistiksel kavramlar ise otonom araştırmaların rastgele modelleri ile ilgilidir. Zaman serilerini değerlendirme yöntemleri önemli bir istatistik alanı olarak görülebilir. Ayrıca, zaman serileri genellikle sistematik ve periyodik aralıklarla tahmin edilen, veri kümelerinin sıralı bir taslağıdır. Zaman serisi analizi, verilerin ilgili özniteliklerini tahmin edilen değerleri ayırmak ve zaman serisi verilerini değerlendirmek için stratejiler içerir (Box ve ark., 1994, Green., 2011).

Zaman serisi bileşenleri; trend, döngüsel değişimler, mevsimsel değişimler ve tutarsız koşullardır (Pociovălișteanu, 2008).

Ancak bir zaman serisinin değerlendirilmesi sırasında, zaman serilerinden farklı olarak incelemelerin çizilmesinde önemli bir adım atılması gerekmektedir. Çizgi bölümleri sadece abartmak için değil, grafikte bulunan sürekli zaman ölçeğini desteklemek içindir. Çizilen zaman serileri normalde serinin temel özelliklerinin ve temel gösterimlerini elde etmek için kullanılır. Bu durum çizimlerde kullanılan verilerde bulunabilecek eğilimler, mevsimsel değişimler, kesintiler ve düzensizlikler gibi özelliklerini anında ortaya çıkarabilir (Hanke ve Wichern, 2014).

Daha önce de belirtildiği gibi, zaman serilerinin temel önemi, geleceğe yönelik tahminler yapmaktır. Birbirine bağlı ve sonraki görüşler söz konusu olduğunda yakın değerler genellikle tarihsel araştırmalar ile tahmin edilir.

Zaman serilerinin yakın değerleri kesin olarak tahmin edilebilirse, zaman serileri deterministik olarak sınıflandırılabilir ve bu tahmin edilen değerlerin sadece kısmen

tarihsel bulgulardan elde edilebileceği sıklıkla kayıt altına alınır (Hanke ve Wichern, 2014; Green, 2011).

Bir zaman serisi aynı zamanda zaman içinde sırayla alınan gözlemlerin bir ilerlemesidir. Veri kümeleri seriler olarak görülmektedir; örneğin bir sektörden sevk edilen aylık ürün sayısı serileri, haftalık otoyolda yaşanan trajedisi sayısı serileri, günlük kar fırtınası miktarı vb. ekonomi, işletme, mühendislik, doğa bilimleri ve hatta sosyal bilimlerde olduğu gibi zaman serileri gibi eğitim alanlarında yaygın olarak kullanılmaktadır (Box ve ark., 1988).

Zaman serisi analizi belirli bir süre boyunca sayıların varyasyonlarını tahmin etmek için yararlı bir çalışmadır. Örneğin hastaneye gelen hasta hacmi gibi.

Zaman serileri tarafından istatistik tabanlı modellerde auto-arima, holt-winters, simple exponential smoothing(ses), Seasonal and Trend decomposition using Loess(stl), tbats ve ets gibi derin öğrenme algoritmalarında ise neural network autoregression (NNAR), multilayer perceptrons (MLP) ve extreme learning machine (ELM) gibi zaman serisi yöntemleri arasında en yaygın kullanılan modeller gibi görünmektedir (Zun, 2009; Ekström ve ark., 2015; Bergs ve ark., 2014; Jones ve ark., 2008).

Zaman serisi analizi ve tahmin, işletmelerde stratejik planlama ve yönetim için yaygın olarak kullanılmaktadır. Her ne kadar zaman serisi analizi dünya çapındaki hastanelerde kullanılsa da sınırlıdır, örneğin Wargon ve diğerleri bazı bilimsel değerlendirmelerde acil servis tahmini üzerine bazı çalışmalar yapmışlardır. Bu çalışmaların birkaçı zaman serisi analizinde kullanırken geri kalanı genelleştirilmiş doğrusal regresyon modellerini kullanır (Sarfo ve ark., 2015).

Zaman serilerinin analizi serilerinin bölünmesini belirlemek, yani eğilimi mevsimsel veya döngüsel gelişimi tespit etmek için benzersizdir. Ekonomideki performansını ve dünyanın veriler üzerindeki etkisini gözlemlerken trend, mevsimsel veya döngüsel hareket modelinde açıkça kullanılır. Seriler için bir model üretmenin kolay olması için tahmincinin her şeyden önce modellemede kullanılan birçok yöntemin olduğunu ve her durum için belirli bir yöntemin olmadığını bilmesi gerekir. Tahmincinin her işlem için var olan farklı modellere aşina olması gerekir, ancak aynı zamanda her bir prosedür tahminde kullanılırken de dikkatli olmalıdır. İstatistik tabanlı modellerde auto-arima, holt-winters, simple exponential smoothing(ses), Seasonal and Trend decomposition using Loess (stl), tbats ve ets gibi derin öğrenme algoritmalarında ise neural network autoregression (NNAR), multilayer perceptrons (MLP) ve extreme

learning machine (ELM) tümü durağan ve durağan olmayan zaman serisi verilerini gösteren ve zaman serisi modelleri sınıfına aittir (Box ve ark., 1994).

Bu nedenle, zaman serileri analizinin önceki araştırmacılar tarafından yaygın olarak kullanılan kabul edilebilir bir performans sağladığı görülmektedir.

Muş Devlet Hastanesi Radyoloji birimine ait 2010-2020 yılları arasında 11 yıllık veya 132 aylık verilerin kullanılarak gelecekteki radyolojik görüntülerin çekilmesini tahmin etmek, tahminleri değerlendirmek ve geleceği ona göre planlamak oldukça büyük önem arz etmektedir. Eldeki özgün veriler ışığında böyle bir çalışmanın ilk yapıyor olması literatüre de önemli katkıları olacaktır.

2.4.1 Zaman serisi bileşenleri

2.4.1.1 Trend

Bir zaman serisinin belirli bir zaman aralığındaki genel eğilimi artış ya da azalış yönünde olabilir. Zaman serilerinde bu harekete trend adı verilir.

2.4.1.2 Mevsimsel dalgalanmalar

Mevsimsel dalgalanmadaki hareketlenmeler periyodik biçimde gerçekleşir, sık rastlanan ve kolaylıkla tespit edilebilen bir etkidir. Bir yıl içerisinde ya da bir yıldan az olan bir süre içinde gerçekleşen süreçte mevsim hareketlerinin veriler ile olan etkisini ifade eder. Mevsimsel dalgalanmalardaki veriler daha çok fiyat karşılaştırmaları, sıcaklık değerleri, turizmdeki istatistik verileri gibi değişkenlerden oluşan kısımlarda görülebilir.

2.4.1.3 Konjonktürel dalgalanmalar

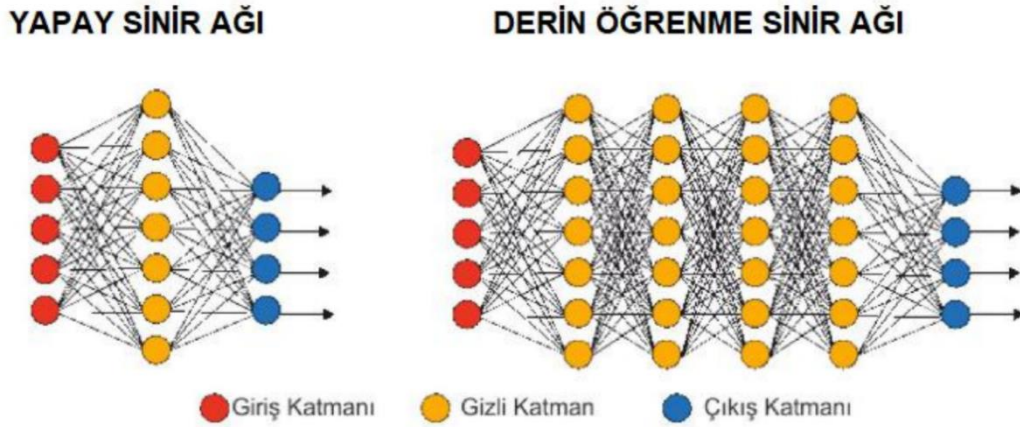
Zaman serilerindeki uzun süreçli dairesel hareketlerin genel trend düzeyinde gösterilmesine konjonktürel dalgalanma denir. Örnek olarak hava sıcaklıklarının günlük değişimlerini verebiliriz.

2.4.1.4 Düzensiz hareketler

Serilerdeki hareketlerin düzensiz bir yapıya sahip olması ve bu düzensiz yapı ile bir modelleme yapılamıyorsa bu tür hareketlere düzensiz hareketler denir. Düzensiz yapılardaki seriler üzerinde tahmin işlemi yapılamaz.


2.4.2 Derin öğrenme modelleri

Derin öğrenme, birden fazla işlem katmanından oluşan hesaplama modellerinin, birden fazla soyutlama seviyesine sahip veri temsillerini öğrenmesini sağlar. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi gibi diğer birbirinden farklı alanlarda en son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenmeler, çok katmanlı modeller ile yapılan yapay öğrenmelerdir. Şekil 2.2’de görüldüğü gibi derin öğrenme, bir makinenin her katmandaki gösterimi önceki katmandaki gösterimden hesaplamak için kullanılan iç parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılma algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder.



Şekil 2. 2 Yapay Sinir Ağı (YSA) ve Derin Öğrenme Sinir Ağı Karşılaştırması (Çarkacı ve ark., 2018; Kın ve ark., 2019).


Derin öğrenmede veri büyüklüğü ile başarı pozitif yönlü etkileşim içindedir. Ancak diğer algoritmalar için aynı durum geçerli değildir veri büyüklüğünün artması performansın sabit hale gelmesini sağlayabilir. Bu durum Şekil 2.3’te gösterilmiştir.



Şekil 2. 3 Derin Öğrenmelerde Performans Grafiği (Brownlee ve ark., 2016).

2.4.2.1 Neural network autoregression (NNAR)

Sinir ağları, makine öğreniminde yaygın olarak kullanılan bir tür istatistiksel modeldir. Yapay Sinir Ağı kavramı, merkezi sinir sisteminin biyolojik sinir ağından esinlenmiştir. Bunlar, büyük hacimli eğitim setlerine dayalı fonksiyonları tahmin etmek için daha iyi kullanılır ve Şekil 2.4'te gösterildiği gibi paralel olarak çalışan çoklu düğümlerin ağıdır. Sinir ağları, altta yatan ilişkinin önceden varsayımı olmaksızın karmaşık doğrusal olmayan ilişkiyi modelleyebilir. Her düğüm, düğümün girdisini, sonraki katmandaki düğümler için bir girdi görevi gören bir çıktıya dönüştüren bir etkinleştirme işleviyle ilişkilendirilir. Her düğüm, giriş sinyalini bir ağırlıkla çarpar w_{ij} , bağlantının karakteristiği bitişik katmanların i ve j düğümleri arasındaki bağlantıdır ve ardından ağırlıklı girdiyi toplar. Her gizli katman düğümü, girişinin tek bir 'sigmoid' dönüşümünü gerçekleştirir (Hamra ve ark.,2003).



Şekil 2. 4 Sinir Ağları mimarisi dört giriş düğümü, iki gizli katman ve bir düğüm çıkış katmanından oluşur (Sena ve Nagwani, 2016).

$$z_j = g(\sum_i y_i w_{ij} - \beta_j) \quad (2.1)$$

Formül sonucunda girdiler ve çıktılar şu şekildedir; z_j , j. düğümünün çıktısı, y_i ise i. düğümün girdisi β_j , j. düğümün standart sapması ve $g()$ ise sigmoidal fonksiyonudur.

$$g(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$

Bir sinir ağlarının başarılı bir şekilde uygulanması, büyük hacimli eğitim setleri ile ağına uygun şekilde eğitilmesine bağlıdır. Eğitim sürecinde sinir ağlarının, bir öğrenme algoritması yardımıyla her bağlantıyla ilişkili ağırlıklarını ayarlamayı öğrenir. Geri yayılma algoritması en bilinen ve yaygın olanıdır tüm sinir ağı paradigmalarının öğrenme algoritması kullanılır. Bu algoritma, alınan her girdi için elde edilen cevaba dayanarak ağı eğitir. Daha sonra, elde edilen yanıtı hedef çıktı ile karşılaştırarak ağırlıklarını ayarlar, böylece ağına toplam Kare hatasını (SSE) en aza indirir.

$$SSE = \frac{1}{2} \sum_p \sum_k (Z_k^{\wedge} - Z_k)^2 \quad (2.3)$$

Burada Z_k^{\wedge} ve Z_k , kth çıktı düğümünün hedef çıktısı ve yanıt vektörüdür. p alt simgesi, kullanılan belirli giriş vektörü desenini ifade eder. Eğitim aşamasından sonra elde edilen ağırlıklar, çıktı katmanında en iyi çıktıyı üretmek için en uygun olanlardır.

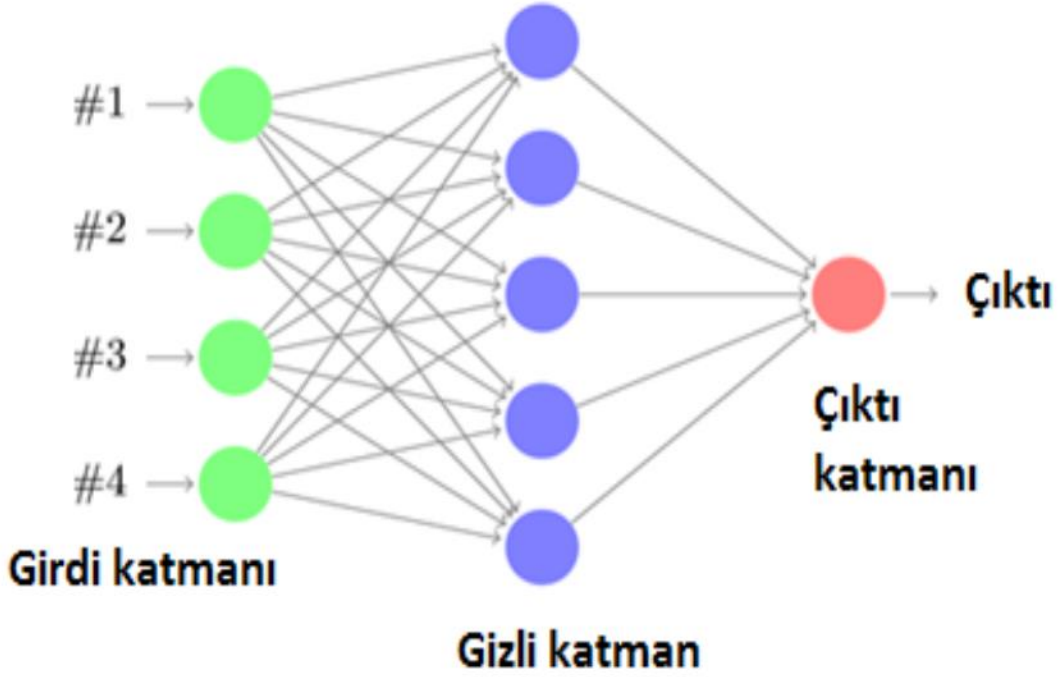
NNAR modeli, parametrik doğrusal olmayan bir tahmin modelidir. Bu modeldeki tahmin iki adımda gerçekleştirilir. İlk adımda, verilen zaman serileri için otoregresyon

sırası belirlenir. Otoregresyon sırası, zaman serilerinin geçerli değerinin bağlı olduğu önceki değerlerin sayısını gösterir. İkinci aşamada sinir ağları otoregresyon sırası dikkate alınarak hazırlanan bir eğitim seti ile eğitilir. Girdi düğümlerinin sayısı, otomatik regresyon sırasından belirlenir ve sinir ağlarına yapılan girdiler, tek değişkenli zaman serisi tahmininde önceki, gecikmeli gözlemlerdir. Tahmin edilen değerler sinir ağları modelinin çıktılarıdır. Gizli düğümlerinin sayısı, seçim için herhangi bir teorik temelin olmaması nedeniyle genellikle deneme yanılma yoluyla veya deney yoluyla belirlenir (Zhang ve ark.,2001). Aşırı hatalı çıktı problemini önlemek için yineleme sayısı doğru seçilmelidir.

2.4.2.2 Multiplayer perceptrons (MLP)

Yapay sinir ağlarında karmaşık işlemlerin gerçekleştirilebilmesi için tek nöronun yeterli olmadığı durumlarda birden fazla nörondan oluşan nöron yığınları kullanılmaktadır. MLP sinir ağları, katmanlar halinde düzenlenmiş birimlerden oluşur. Şekil 5'te görüldüğü gibi her MLP, bir giriş katmanı, bir veya daha fazla gizli katmanlar ve bir çıkış katmanından oluşan en az üç katmandan oluşur (Kaynar ve Taştan, 2009).

- **Girdi katmanı:** Dışardan girdi bilgileri alır. Girdi katmanında herhangi bir bilgi işleme olmaz.
- **Ara katmanlar:** Girdi katmanından gelen bilgileri işlerler. Katman sayısı arttıkça problem çözme sayısı da artmaktadır. Ağda öğrenilmesi istenilen problemin girdi/çıkı arasındaki ilişkisi doğrusal olmaz ve karmaşıklık sayısına göre ara katman sayısı da artırılabilir.
- **Çıktı katmanı:** Çıktı katmanı bir önceki ara katmandan gelen bilgileri işleyerek ağa girdi katmanından sunulan girdi için ağın ürettiği çıktıyı bulur. Çıktı katmanında üretilen bilgi dışarı aktarılır (Öztemel, 2012).




Şekil 2. 5 Çok katmanlı yapay sinir ağı örneği (Neural Network, 2016).

Yapay sinir ağlarının genel anlamda çalışma mantığı yani temel görevi verilen örnek veri setindeki girdi bilgilerini öğrenerek istenilen işlemi yapabilecek duruma gelmesi yani genelleştirme yapmasıdır. Bu işlemi yapabilmesi için girdi bilgileri ile eğitilerek genelleme yapabilme yeteneğine kavuşmasıdır. Girdi bilgileri ile eğitilen sinir ağı ara katmanlarda kullanılan nöron sayılarına göre problem çözme becerisi de artmaktadır. MLP ağları geri yayılım (backpropagation) algoritmasını kullanır. Geri yayılım algoritması ismi gibi çıkıştan girişe hataların azaltılması yolu ile öğrenme gerçekleştirdiği için bu ismi almıştır. Geri yayılım algoritmaları danışmanlı öğrenme yapısına sahiptirler bu nedenle birçok uygulamada kullanılmış en yaygın öğrenme algoritmasıdır (Kaynar ve Taştan, 2009).

2.4.2.3 Extreme learning machine (ELM)

Eğitim sürecinde, geleneksel ileri besleme sinir ağı, ağırlık ve eşik gibi model parametrelerini sürekli olarak gözden geçirmek için hatayı gradyan iniş algoritması aracılığıyla geri yayar (M. Q. Raza ve A. Khosravi, 2015). Bu şekilde kare hataların toplamı giderek belirli bir seviyeyi azaltır ve sinir ağının çıktısı yavaş yavaş potansiyel çıktıya yaklaşır. Geleneksel ileri beslemeli sinir ağından farklı olarak, aşırı öğrenme makinesi, tek katmanlı ileri beslemeli sinir ağı için bir makine öğrenme algoritmasıdır; burada, gizli katmanın parametrelerine göre yalnızca çıktı ağırlığının hesaplanması

gerekir ve gizli katman rastgele ayarlanır (Figueiredo ve Ludermer, 2012). Bu algoritma, geleneksel gradyan tabanlı öğrenme sürümlerinden yalnızca daha yüksek genelleme performansına ve daha hızlı öğrenme hızına sahip olmakla kalmaz, aynı zamanda güçlü uyum yeteneğine ve daha düşük hesaplama karmaşıklığına sahiptir. Şekil-6'da üç katmanlı bir ELM gösterilmektedir.



Şekil 2. 6 ELM Yapay sinir ağı katmanları(Cai ve ark., 2020).

Aşırı öğrenme makinesi. İleri beslemeli sinir ağı, parametreleri girdi ağırlıklarını α , çıktı ağırlıklarını β ve gizli katman önyargılarını b içeren yalnızca bir gizli katmana sahiptir.

Aşırı öğrenme makinesinin prensibi aşağıdaki gibidir. N eğitim örneği olduğunu varsayalım ve $\{(x_i, t_i)\}_{i=1}^N$, öyle ki $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n, t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$. Bir aktivasyon fonksiyonuna sahip sinir ağı $G(x)$ ve k gizli düğümleri matematiksel olarak şu şekilde gösterilmiştir.

$$H\beta = T \quad (2.4)$$

Burada $H = \{h_{ij}\}_{i=1, \dots, N, j=1, \dots, k}$ çıktı matrisini temsil eder yani gizli katman. $h_{ij} = g(a_j^T x_i + b_j)$ ve $x_i \cdot a_j = [a_{j1}, a_{j2}, \dots, a_{jn}]^T$ göre j ninci gizli düğümü ve gizli nörona bağlayan ağırlık vektörüdür. b_j ise j ninci gizli nöronun önyargı ifadesidir. Çıkış ağırlıklarının matrisi $\beta = [\beta_1, \beta_2, \dots, \beta_k]^T$ olarak temsil edilir burada $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jk}]^T, j=1, 2, \dots, k$ çıkış düğümlerini j inci gizli nörona bağlayan ağırlık vektörüdür. $T = [t_1, t_2, \dots, t_k]^T$, hedeflerin matrisini temsil eder.

ELM fikri, ilk girdi ağırlıklarını ve gizli önyargıları rastgele oluşturmaktır. Daha sonra H matrisi aktivasyon fonksiyonu $g(x)$ 'e göre belirlenir. Bu şekilde ileri beslemeli sinir ağının eğitimi, (2.4) de verilen doğrusal sisteme en küçük kareler çözümünü çözme problemine dönüştürülebilir ve sonucu (2.5) gibi gösterilebilir.

$$\hat{\beta} = H^{\dagger}T \quad (2.5)$$

H^{\dagger} , Moore-Penrose (MP) ye göre genelleştirilmiş anlamına gelir ve H matrisinin tersidir.

2.4.3 İstatistiksel modeller

İstatistiğin temel amaçlarından birisi değişkenler ve gözlem sonuçlarından elde edilen veriler ile oluşan anlamlı sonuçlar çıkarmaktır. Gözlem sonuçlarından elde edilen verilerin belirli özelliklerine bakılarak sıralanmasına seri adı verilir. Bu verilerin zaman içinde değişim göstermesi halinde bu olaya da zaman serisi adı verilmektedir.

2.4.3.1 Simple exponential smoting (SES)

Bu tahmin yöntemi, tüm tahmin tekniklerinde arasında yaygın olarak kullanılan bir modeldir. Çok az hesaplama gerektirir. Bu yöntem, veri deseni yaklaşık olarak yatay olduğunda kullanılır (yani tarihsel verilerde ne döngüsel varyasyon ne de belirgin bir eğilim yoktur). Basit üstel yumuşatma modeli, mevsimsellik veya eğilimin olmadığı zaman serileri için uygundur. Bu yöntem, 0 otoregresyon sırası, yöntem farkı, yöntemin hareketli ortalaması ve sıfır sabiti ile ARIMA modeline benzer özellikler taşır (Orhunbilge, 1999).

Gözlemlenen bir zaman serisi $y_1, y_2, y_3 \dots, y_n$ olsun. Resmi olarak basit üstel yumuşatma (SES) denklemi şu şekildedir;

$$\hat{y}_{i+1} = ay_i + (1 - a)y_i^{\wedge} \quad (2.6)$$

y_i bilinen zaman periyodu için i gerçek seri değeri, y_i^{\wedge} ise tahmin değeri ve \hat{y}_{i+1} , $i+1$ zaman periyodu için tahmin değeridir ve a yumuşatma değeridir (Brown ve Meyer, 1961). Genel formdaki tahmin denklemi ise şu şekildedir;

$$\hat{y}_{i+1} = ay_i + a(1 - a)y_{y-1} + a(1 - a)^2y_{i-2} + \dots + a(1 - a)^{i-2}y_2 + a(1 - a)^{i-1}y_1 = a \sum_{k=0}^{i-1} (1 - a)^k y_{i-k} \quad (2.7)$$

2.4.3.2 Holt-Winter modeli

Holt-Winters yöntemi zaman serisi analizlerinde sıklıkla kullanılan tahmin modellerinden biridir. Bu model Holt yönteminin bir uzantısı olarak görülen trend ve mevsimsellik için geliştirilmiş diğer adıyla üstel yumuşatma olan Winters yöntemi olsa da, Holt yönteminin gelişmiş versiyonu olduğu için modele Holt-Winters modeli denmektedir. Holt yönteminde sadece trendden yararlanırken Winters yönteminde ise hem trend hem de mevsimsellikten yararlanır. Ayrıca zaman serisi tahminlerinde üç yumuşatma sabiti kullanılır. Bunlardan birinci seviye için ℓ_t trend için b_t ve mevsimsellik için ise s_t ye karşılık gelen yumuşatma parametreleri ile birlikte α , β ve γ sabitleri kullanılır. Burada kullanılan m parametresi ise mevsimselliğin sıklığını ifade etmektedir yani mevsim sayını belirlemek için kullanılır. Örnek vermek gerekirse dört aylık veriler için $m = 3$ ya da aylık veriler için $m = 12$ seçilir.

Holt-Winters yönteminin mevsimsellik durumuna göre farklılık gösteren iki çeşidi vardır. Bunlar katkı yöntemi ve çarpımsal yöntemlerdir. Katkı yöntemi mevsimsel değişimlerin seriler boyunca değişmediği yani sabit olduğu durumlarda tercih edilirken mevsimsel değişimler seriler orantılı olarak değiştiğinde çarpımsal yöntem tercih edilir.

Katkı yöntemi için kullanılan bileşen formları;

$$\hat{y}_{t+h|t} = \ell_t + hb_t + s_{t+h-m(k+1)} \quad (2.8)$$

$$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1}) \quad (2.9)$$

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1} \quad (2.10)$$

$$s_t = \gamma(y_t - \ell_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad (2.11)$$

Çarpımsal yöntem için kullanılan bileşen formları;

$$\hat{y}_{t+h|t} = (\ell_t + hb_t)s_{t+h-m(k+1)} \quad (2.12)$$

$$\ell_t = \alpha\left(\frac{y_t}{s_{t-m}}\right) + (1 - \alpha)(\ell_{t-1} + b_{t-1}) \quad (2.13)$$

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1} \quad (2.14)$$

$$s_t = \gamma\left(\frac{y_t}{\ell_{t-1} + b_{t-1}}\right) + (1 - \gamma)s_{t-m} \quad (2.15)$$

2.4.3.3 Exponential Smoting (ETS)

Başlangıçta Pagels (1969) tarafından tanımlanmış 1985 te Gardner, 2002 yılında ise Rob Hyndman ve arkadaşları tarafından geliştirilip değiştirilmiştir.

Genel denklem şu şekildedir;

$$\hat{y}_{t|t-1} = \ell_{t-1}$$

$$l_t = ay_{t-1} + (1 - a)l_{t-1} \quad (2.16)$$

Burada $y_{t|t-1}^{\wedge}$ önceki adımlar göz önüne alındığında y_t nin tahmin beklentisidir.

Basit üstel yumuşatma modelinde, tahmin önceki seviyeye karşılık gelir. İkinci denklem (yumuşatma denklemi), bir sonraki seviyeyi önceki seviyenin ve önceki gözlemin ağırlıklı ortalaması olarak hesaplar.

2.4.3.4 Auto-arima

ARIMA zaman serileri analizinde ve gelecek değerlerin tahminlerinde sıkça kullanılan bir yöntemdir. Temel özellikleri geçmiş dönemde atılmışsa da 1971 yılında George E.P. Box ve Gwilym Jenkins tarafından yayınlanan kitap ile popüler hale gelmiştir. ARIMA modeli, otomatik gerileyen (AR), entegre (I), hareketli ortalamanın (MA) kısaltmalarının bir araya gelmeleri ile oluşur. Popüler bir model olmasının temel sebebi, kısa ve orta dönem tahminlerinde başarılı sonuçlar vermesidir. Birden fazla modelin arasından en uygun modeli seçme şansı verir. Model seçimlerinde dikkat edilmesi gereken iki husus vardır. Bunlar durağanlığın incelenmesi ve mevsimselliğin olup olmadığının araştırılmasıdır. ARIMA modelleri durağan olmadığı halde fark alma işlemi ile birlikte durağan hale dönüştürülmüş serilere uygulanan modellerdir. Bu modellere “durağan olmayan doğrusal skolastik modeller” denir. Modellerin genel gösterimi ARIMA (p, d, q) şeklindedir. Burada p ve q parametreleri otoregresif (AR) modelini ve hareketli ortalama (MA) modelinin derecesidir, d ise fark alma işleminin derecesidir.

Genel ARIMA (p, d, q) modeli aşağıdaki gibi formüle edilir.

$$y_t = \sum_{i=1}^p \Phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (2.17)$$

Φ_i =Otoregresif parametresi

θ_j =Hareketli ortalama parametresi

ε_t =Rastsal terimi

ARIMA modellerinde geleceğe yönelik tahminlerde uygulanması gereken adımlar şu şekildedir;

- Modelin Belirlenmesi
- Parametrelerin Tahin Edilmesi
- Modelin Uygunluğunun Test Edilmesi

- Tahmin Yapılması

2.4.3.5 Tbats

Yaygın olarak kullanılan diğer birçok modelden farklı olarak, Box Cox dönüşümü, ARMA hataları, Trend ve mevsimsel Bileşenler (TBATS) ile trigonometrik üstel yumuşatma durumu uzay modeli, zaman serilerinde çoklu, karmaşık ve dinamik mevsimselliklere izin veren bir tahmin modelidir.

TBATS, günden güne mevsimsellik gibi çok sık mevsimsellik tahminlere izin veren mevsimsellikleri ayırtmak için trigonometrik yaklaşım kullanır. Model ayrıca en küçük kareler yöntemiyle maksimum olabilirlik tahminini kullanır, bu nedenle geçici başlangıç parametrelerine olan ihtiyaç azdır. Ek olarak, yöntem hesaplama yükünü azaltır (Livera ve ark., 2010; Hyndman ve ark., 2017). Modeli kullanan bir varsayım, hata dağılımının, veri seviyesi orijinden yeterince uzak olduğunda geçerli olan Gauss dağılımına uymasındır (Wang ve ark., 2015). TBATS modelinin bir dezavantajı, harici regresörlerle herhangi bir kullanıma izin vermemesidir.

2.4.3.6 Seasonal and trend decomposing time losess (STL)

STL, zaman serisi verilerini ayırtmayı amaçlayan bir zaman serisi ayırma yöntemidir. Trend (T_t), mevsimsel (S_t) ve kalan bileşenler ($\$t$) olarak ifade edilir. Stl algoritması $Y_t = T_t + S_t + \$t$ bir iç bir de dış döngüden oluşur. Dış döngüde, her bir veri noktasına geri kalanına göre sağlamlık ağırlıkları atanır ve aykırı değerlerin etkisini azaltır. İç döngüde, trend ve mevsimsel bileşenler güncellenir ve süreç aşağıdaki gibi ilerler.

STL' nin çeşitli avantajları vardır. İlk olarak, STL yöntemi, ARIMA zaman serileri (SEAT) (Hyndman, 2018) ve X11(Dagum ve ark., 2016) yöntemlerinde mevsimsel ekstraksiyonun aksine, her türlü mevsimselliği ele alma avantajına sahiptir. İkincisi, mevsimsel bileşen zamanla değişse de, kullanıcı değişim oranını kontrol edebilir. Üçüncüsü ise aykırı değerler ayrılmış trendi ve mevsimsel bileşenleri büyük ölçüde etkilemediğinden, aykırı değerler olduğunda kullanılması güvenlidir. Üçüncüsü ise aykırı değerler ayrılmış trendi ve mevsimsel bileşenleri büyük ölçüde etkilemediğinden, aykırı değerler olduğunda kullanılması güvenlidir.

2.5 Performans ölçümleri

Tahminlerin değerlendirilmesi aşamasında en büyük yardımcılarımız performans ölçümlerinde kullanılan hata metriklerimizdir. Bu ölçümler yapılan tahminlerin doğruluğunu değerlendirirler. Performans ölçümlerinde kullanılan metriklerin farklı hesaplama yöntemleri olsalar da tümü zaman serilerindeki gerçek değer ile tahmin edilen değerlerin farklarından çıkan sonuç ile performansları değerlendirilir. $\Delta_t = y_t - F_t$.

2.5.1 MAPE

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|e_i|}{|A_i|} \quad (2.18)$$

Ortalama mutlak yüzde hata zaman serisi modellerinde tahminlerin doğruluğunu ölçmek ve değerlendirmek için ortalama mutlak yüzde hata sıkça kullanılmaktadır. Toplanan gerçek değerler arasında sıfır değeri varsa, sıfır ile bölünme olacağı ve belirsizlik içerdiği için MAPE hesaplanamaz. Verilerin eksik, yanlış ya da düşük olmasından kaynaklanan hata oranı %100 olamaz, ancak tahmin oranının üst bir limiti yoktur. MAPE, kullanılan algoritmaların doğruluğunu karşılaştırmak için kullanıldığında, tahminleri çok düşük olan bir yöntemi sistematik olarak seçmesi nedeniyle önyargılıdır. Bu önyargı sonucu oluşan problemin elde edilen gerçek değerlerine oranını bulan bir doğruluk ölçütü ile giderilebilir.

2.5.2 MAE

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (2.19)$$

MAE yani ortalama mutlak hata iki sürekli değişken değerler yani tahmin edilen ve gerçek değerler arasındaki farkın ölçüsüdür. Ortalama mutlak hata her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. Ortalama mutlak hata aynı zamanda gerçek veriler ile oluşturulan her veri noktası ile tahmin edilen ve en iyi uyan çizgi arasındaki ortalama yatay mesafedir. Ortalama mutlak hata değeri diğer metriklere göre daha kolay yorumlanabilir olduğu için regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır. Ortalama mutlak hata yönlerini yani pozitiflik ya da negatiflik durumunu dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçen, tüm tekil hataların ortalama eşit olarak dağıtan doğrusal bir sonuçtur. Ortalama mutlak hata değeri 0'dan ∞ 'a kadar değişebilir. Elde edilen değerler arasında aykırı değerler var ve bunları görmezden gelmek istiyorsak MAE diğer metriklere

göre daha iyi bir seçenektir. Negatif yönelimli puanlar yani daha düşük değerlere sahip makine öğrenmesi modelleri daha iyi performans gösterir.

2.5.3 MASE

$$MASE = \frac{\sum_{t=1}^n |e_t|}{\frac{n}{n-1} \sum_{t=2}^n |Y_t - Y_{t-1}|} \quad (2.20)$$

İstatistiksel değerlendirmelerde, ortalama mutlak ölçekli hata (MASE) yapılan tahminlerin doğruluğunun bir ölçüsüdür. 2006 yılında Rob J. Hyndman ve Anne B. Koehler tarafından “diğer hata metriklerinde görülen ve sorunsuz tahminlerin doğruluğunu genel olarak uygulanabilir bir ölçüm” olarak nitelendirmesi önerildi. Ortalama mutlak ölçekli hata diğer hata metriklerinin yaptığı tahmin hatalarını hesaplamak için kullanılan diğer yöntemlerle karşılaştırıldığında pozitif özelliğe sahiptir ve dolayısıyla tahminler karşılaştırılabilir olduklarından doğruluklarını belirlemek için önerilen bir ölçüttür.

2.5.4 RMSE

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad (2.21)$$

$$RMSE = \sqrt{MSE} \quad (2.22)$$

Zaman serisi analizlerinde kullanılan bir makine öğrenmesi modelinin, algoritmaların tahmin ettiği değerler ile elde edilen gerçek değerlerin arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen ikincil dereceden bir metriktir. RMSE tahmin hatalarının standart sapması olarak tanımlanır. RMSE, verilere en iyi uyan gerçek verilere en yakın değerler etrafında o verilerin ne kadar yoğun olduğunu söyler. RMSE değeri 0 ile ∞ arasında her türlü değeri alabilir. Sonuçların negatif yönelimli yani daha düşük değerlere sahip algoritmaları daha iyi performans gösterdiği anlamına gelir. Yani RMSE hata metrik değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir. RMSE, tahminleyici algoritmaların yapmış oldukları büyük hatalarda diğer metriklerle oranla daha avantajlı olduğu söylenebilir, bu yüzden bazı durumlara daha uygun olabilir.

3. BULGULAR

Bu bölümde 2010-2020 yılları arasında Muş Devlet Hastanesine başvuran ve radyolojik görüntüleme istenen hasta istatistikleri yer almaktadır. Elde edilen veriler Muş Devlet Hastanesi Bilgi İşlem Servisinden temin edilmiştir.

3.1 Veri Bilgileri

Muş Devlet Hastanesi Bilgi İşlem Servisinden elde edilen 2010-2020 yılları arasında 132 aylık veriler Çizelge 3.1’ de gösterilmiştir. Veriler aylık olarak radyoloji biriminde çekilen bilgisayarlı tomografi, röntgen, ultrason, manyetik rezonans ve mamografi adetlerinden oluşmaktadır. Kullanılan 11 yıllık, 132 aylık verilerin istatistiksel dağılımı en küçük, en büyük, medyan ve ortalama sırasıyla 36, 47608, 6480 ve 1704 dir.

Elde edilen aylık veri seti kullanılarak tahmin işlemleri için farklı oranlarda eğitim ve test verisi ayrılmak kaydıyla dört farklı analiz yapılmıştır.

Çizelge 3. 1 Çalışmada kullanılan 11 yıllık, 12-aylık veri seti

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
2010	77	79	92	114	143	132	159	60	38	89	86	104
2011	140	124	59	54	49	152	309	249	102	36	52	54
2012	264	220	411	367	288	233	179	354	359	86	127	773
2013	523	885	861	950	1115	1195	1098	1392	585	2135	2234	2263
2014	1801	1525	3067	4790	5729	6653	5946	6510	6502	6789	6458	6209
2015	4832	4581	5209	5629	6631	6106	6163	6195	5950	6040	6176	8196
2016	23234	29896	32182	27434	27841	26933	24059	31950	22590	27610	28876	27127
2017	34016	31509	38088	32529	32723	27676	35786	32611	31816	33939	32767	32483
2018	39272	38523	40833	37888	39298	32236	39422	34717	37793	35617	36369	43061
2019	42609	40440	42165	40557	38071	36434	45751	38113	41932	45534	43160	47608
2020	45406	42973	36200	14654	17985	35698	38530	37209	36311	37210	37213	38855


3.2 Tahmin Analizleri

Tahmin analizleri için kullanılan 132-aylık veri seti öncelikle ayrıştırma modeli yardımıyla dört bileşene ayrılmıştır.

$$\hat{X}_t = T_t + S_t + R_t + \epsilon_t \quad (2.23)$$

Burada \hat{X}_t , t zamanında modellenen veya tahmin edilen değeri, T_t , t zamanındaki trend bileşenini, S_t , t zamanındaki mevsimsel bileşeni, R_t , t zamanındaki kalan bileşeni ve ϵ_t terimini ise t zamanındaki hatayı temsil etmektedir.

Söz konusu bileşenler veri (observed), trend (trend), mevsimsellik (seasonal) ve düzensiz bileşenler (random) olarak Şekil 7’ deki gibi görülmektedir.



Şekil 3. 1 2010-2020 yıllarına ait 132-aylık veri setinin ayrıştırma grafiği

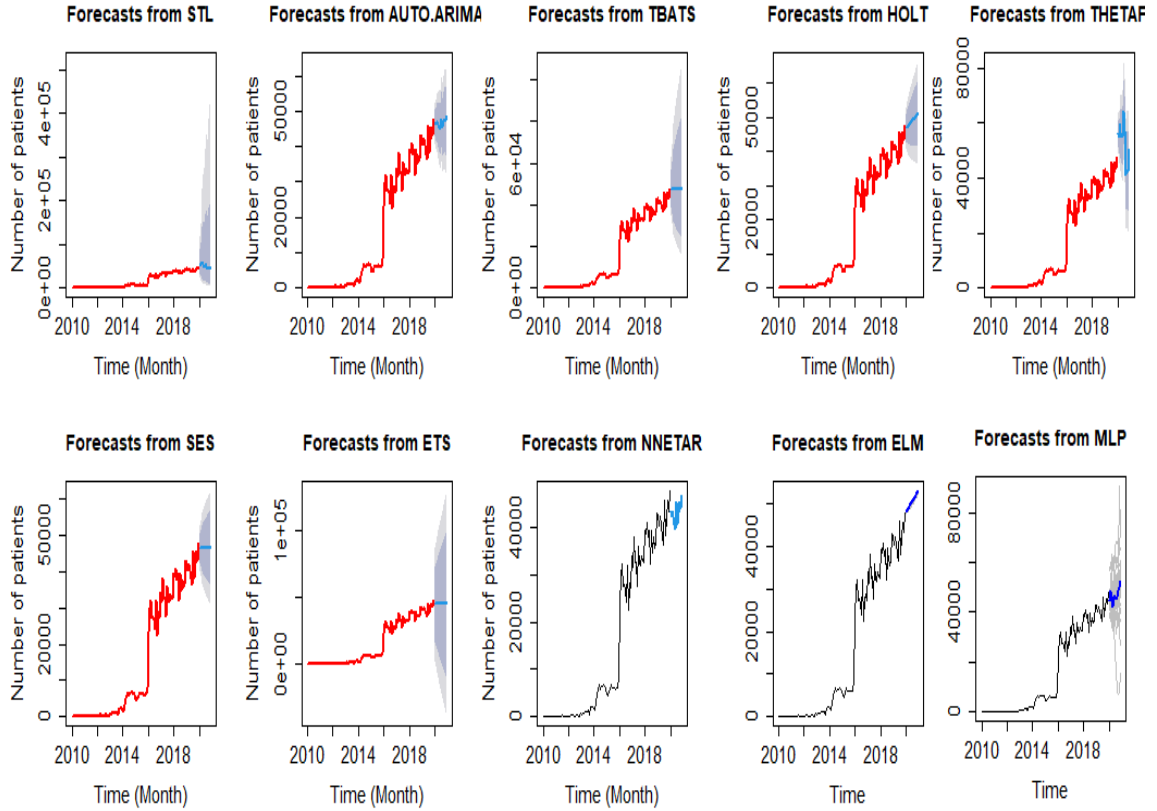
Devam eden kısımda iki farklı yaklaşımla tahminler yapılmıştır. Birinci yaklaşımda her defasında test/eğitim oranı değiştirilmek suretiyle sekiz farklı analiz yapılmış ve elde edilen sonuçlar değerlendirilmiştir. İkinci yaklaşımda ise zaman serisi çapraz doğrulama modeli kullanılarak yapılan analizlerin ortalaması alınmıştır.

3.2.1 12-Aylık tahmin analizleri: zaman serisinin 120-aylık eğitim/12-aylık test için ayrılması

Çizelge 3.2’de verildiği gibi eğitim test bölümlenmesinde 120 aylık eğitim ve 12 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Derin öğrenme ve istatistiksel modelleri model karşılaştırmaları başlığı altında ayrı olarak incelenecektir.

Çizelge 3. 2 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 12-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	12 aylık tahminler için, veri setinin %91’i (120 aylık) eğitim %9’u (12 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	14543.261	11837.327	49.18372	2.5094196
ETS	13579.987	10445.681	45.09873	2.2144015
STL	18861.122	15185.046	62.87592	3.2191094
SES	14569.848	11642.845	49.03143	2.4681910
TBATS	15182.550	12401.016	51.46153	2.6289171
HOLT-WINTERS	16677.582	14188.047	56.8272	3.0077535
THETAF	21651.728	18205.68	71.49376	3.8594604
ELM	17935.804	15637.90	61.42291	3.315112
MLP	12804.773	10518.3131	43.25969	2.2297990
NNAR	11852.193	8911.932	38.88663	1.889259



Şekil 3. 2 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 12-aylık tahmin grafikleri

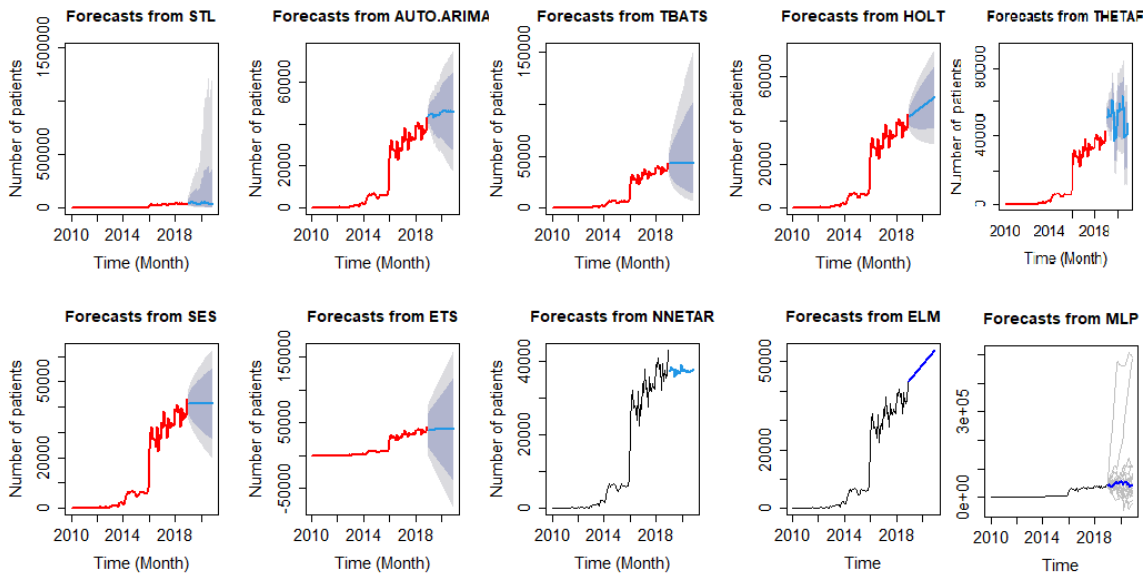
Şekil 3.2 'de görüldüğü gibi, koyu gölgeli alan tahmin edilen %80 aralıkları göstermektedir. Diğer bir deyişle, her potansiyel değer için %80 olasılıkla koyu gölgeli alanda olduğu tahmin edilmektedir. Açık gölgeli alan %95 tahmin aralıklarını gösterir. Bu tahmin aralıkları, tahmindeki değişkenliği göstermenin yararlı bir yoludur. Bu durumda tahminin güvenilir olduğu varsayılır ve bu nedenle tahmin aralıkları çok dardır. Mavi çizgi, nokta tahminleri dediğimiz potansiyel gelecek değerlerin ortalamasıdır.

3.2.2 24-Aylık tahmin analizleri: zaman serisinin 108-aylık eğitim/24-aylık test için ayrılması

Çizelge 3.3'te verildiği gibi eğitim test bölümlenmesinde 108 aylık eğitim ve 24 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Tahmin grafikleri Şekil 3.3'da verilmiştir.

Çizelge 3. 3 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 24-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	24 aylık tahminler için, veri setinin % 81'i (108 aylık) eğitim % 19'u (24 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	10313.32	7090.184	27.49869	1.480804
ETS	7655.999	4926.255	19.37900	1.0288618
STL	13168.34	9749.611	35.52262	2.0362331
SES	8007.982	5043.376	20.41317	1.0533230
TBATS	8613.322	5495.769	22.20241	1.1478065
HOLT-WINTERS	11823.133	8287.309	31.2955	1.7308273
THETAF	16822.966	13663.020	46.61802	2.8535592
ELM	13731.488	10349.417	37.40187	2.1615041
MLP	16137.418	12079.5980	43.01581	2.52285721
NNAR	7711.900	4751.014	19.15781	0.9922622



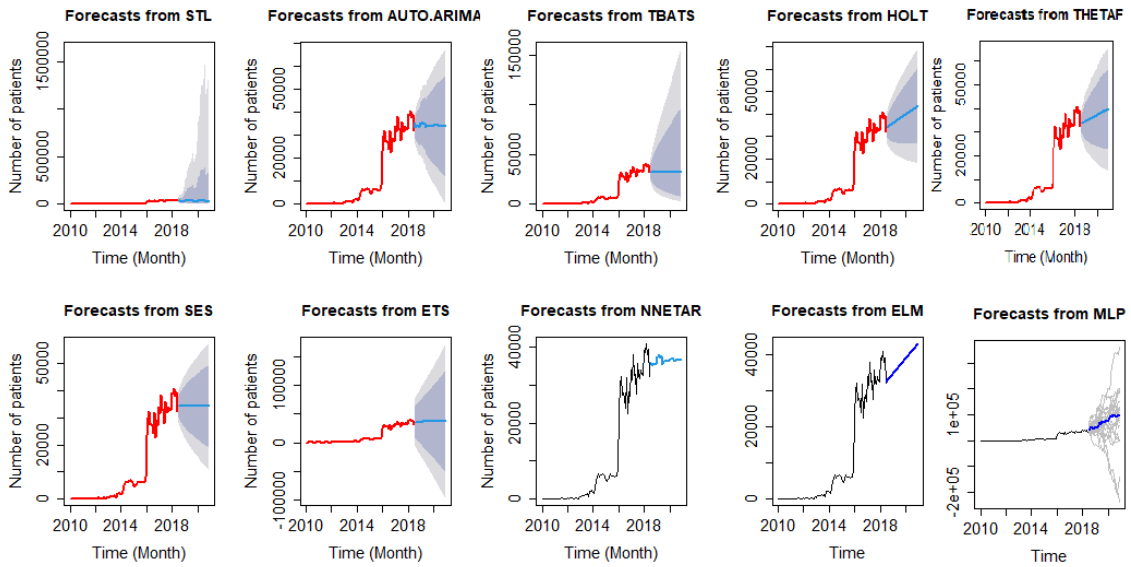
Şekil 3. 3 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 24-aylık tahmin grafikleri

3.2.3 30-Aylık tahmin analizleri: zaman serisinin 102-aylık eğitim/30-aylık test için ayrılması

Çizelge 3.4'te gösterildiği gibi eğitim test bölümlenmesinde 102 aylık eğitim ve 30 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Tahmin grafikleri Şekil 3.4'te verilmiştir.

Çizelge 3. 4 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 30-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	30 aylık tahminler için, veri setinin % 77'si (102 aylık) eğitim % 23'ü (30 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	7855.677	6384.610	19.92843	1.3298900
ETS	7068.801	4705.719	16.33100	0.9801833
STL	11970.207	10395.095	30.32445	2.1652588
SES	7980.378	6537.717	20.23326	1.3617816
TBATS	8923.264	7927.169	23.35809	1.651199
HOLT-WINTERS	7938.785	5647.481	20.1358	1.1763490
THETAF	7569.763	5434.386	18.55221	1.1319620
ELM	8070.876	6066.481	20.94631	1.2636249
MLP	9123.4501	6816.2718	23.46980	1.41980356
NNAR	7248.625	5125.901	17.15960	1.0677057



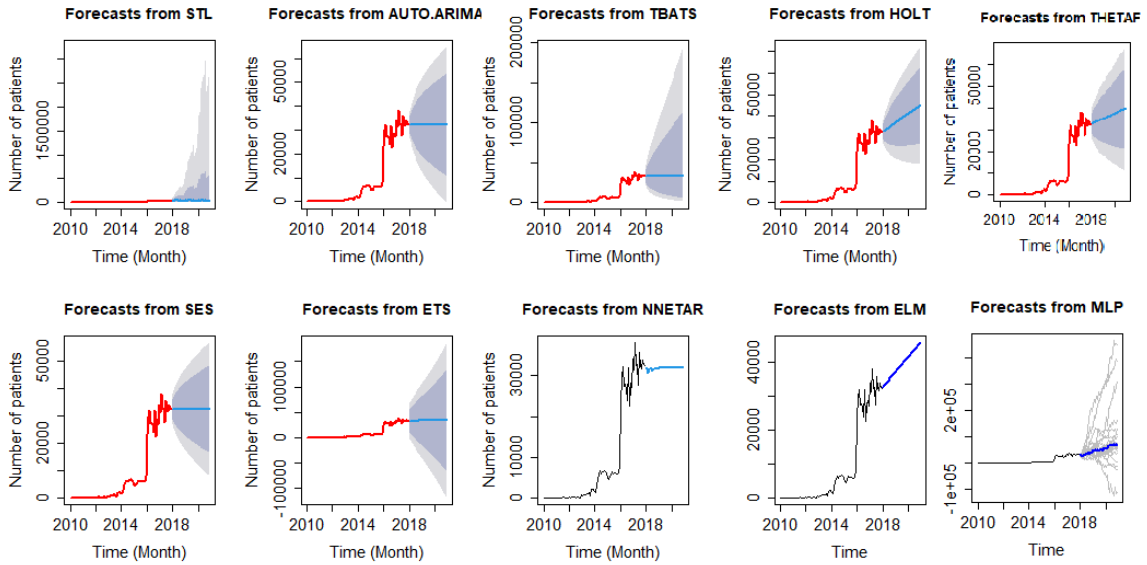
Şekil 3. 4 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 30-aylık tahmin grafikleri

3.2.4 36-Aylık tahmin analizleri: zaman serisinin 96-aylık eğitim/36-aylık test için ayrılması

Çizelge 3.5'de gösterildiği gibi eğitim test bölümlenmesinde 96 aylık eğitim ve 36 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Tahmin grafikleri Şekil 3.5'de verilmiştir.

Çizelge 3. 5 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 36-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	36 aylık tahminler için, veri setinin % 73'ü eğitim (96 aylık) % 27'si (36 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	8683.096	7733.419	22.28532	1.6217151
ETS	8043.516	6876.422	8.285898	0.39216
STL	9185.434	6808.318	22.20748	1.4277195
SES	8440.012	7433.648	21.60522	1.5588525
TBATS	8517.387	7530.225	21.82460	1.5791048
HOLT-WINTERS	7735.434	5461.891	19.1333	1.1453707
THETAF	7216.886	5301.825	17.44204	1.1118045
ELM	7988.081	5598.307	19.71282	1.1739775
MLP	22741.3458	14877.1907	50.35276	3.11977995
NNAR	8459.065	7459.764	21.66060	1.5643290



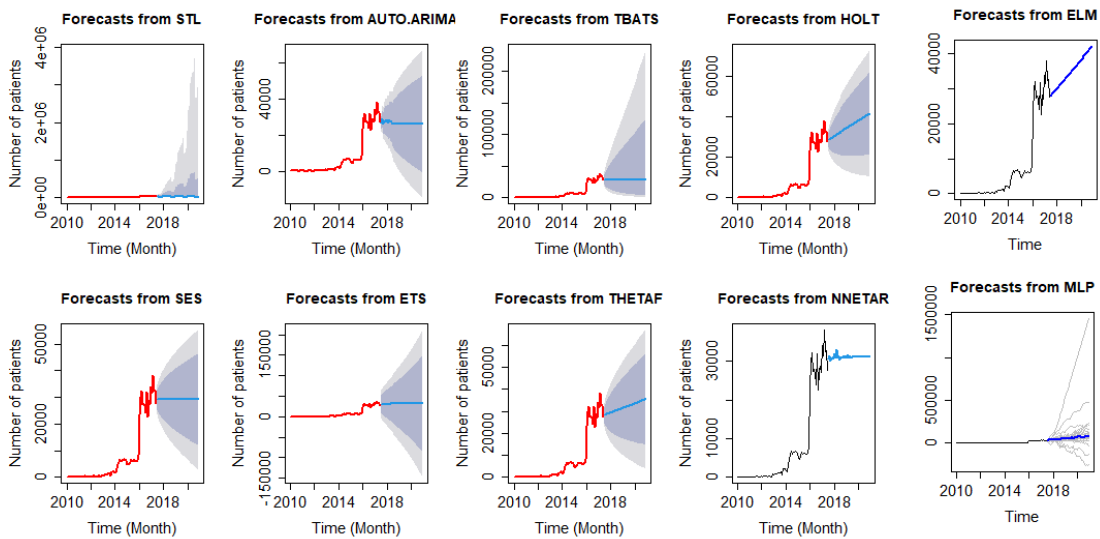
Şekil 3. 5 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 36-aylık tahmin grafikleri

3.2.5 42-Aylık tahmin analizleri: zaman serisinin 90-aylık eğitim/42-aylık test için ayrılması

Çizelge 3.6 'de gösterildiği gibi eğitim test bölümlenmesinde 90 aylık eğitim ve 42 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Derin öğrenme ve istatistiksel modelleri model karşılaştırmaları başlığı altında ayrı olarak incelenecektir. Tahmin grafikleri Şekil 3.6'de verilmiştir.

Çizelge 3. 6 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 42-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	42 aylık tahminler için, veri setinin % 69'ü eğitim (90 aylık) % 31'si (42 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO.ARIMA	12608.099	11878.598	31.78319	2.5497708
ETS	8553.529	7466.187	21.29665	1.6026358
STL	15041.799	13945.217	37.96597	2.9933757
SES	10392.609	9618.308	26.43452	2.0645940
TBATS	11500.801	10828.44	29.37803	2.3243511
HOLT-WINTERS	7454.82	5833.858	18.73846	1.2522523
THETAF	8481.048	7304.381	21.44906	1.5679036
ELM	7616.605	6040.163	19.39089	1.2965362
MLP	22598.8633	17274.0662	54.08647	2.45230067
NNAR	8794.586	7807.224	22.07086	1.6854425



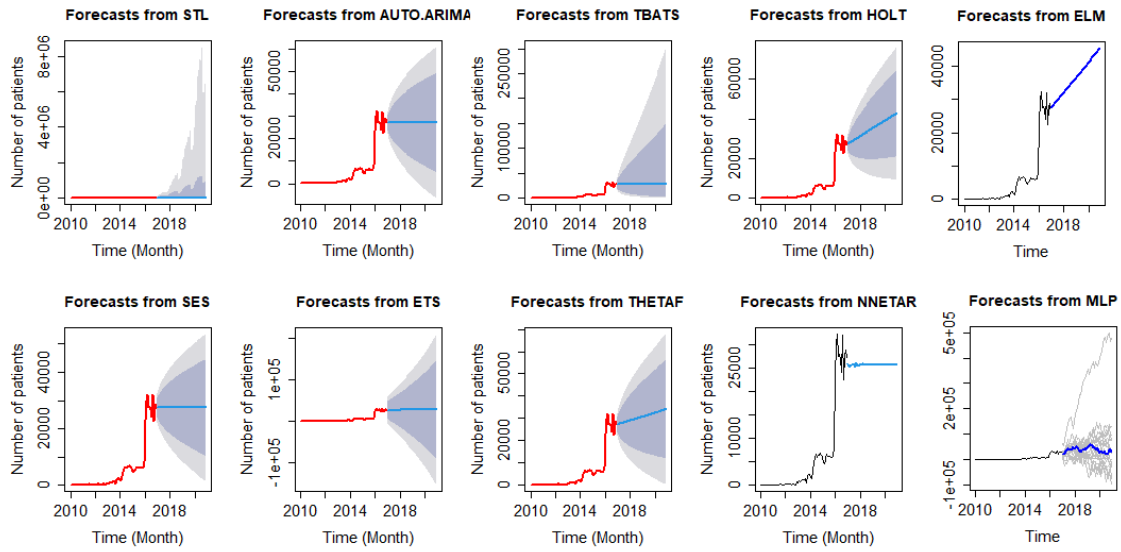
Şekil 3. 6 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 42-aylık tahmin grafikleri

3.2.6 48-aylık tahmin analizleri: zaman serisinin 84-aylık eğitim/48-aylık test için ayrılması

Çizelge 3.7’de gösterildiği gibi eğitim test bölümlenmesinde 84 aylık eğitim ve 48 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Derin öğrenme ve istatistiksel modelleri model karşılaştırmaları başlığı altında ayrı olarak incelenecektir. Tahmin grafikleri Şekil 3.7’te verilmiştir.

Çizelge 3. 7 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 48-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	48 aylık tahminler için, veri setinin % 64'ü eğitim (84 aylık) % 36'si (48 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	11492.518	10681.75	28.98438	2.3001941
ETS	10787.49	9976.930	27.32205	2.148419
STL	10355.682	8062.330	24.03344	1.7361316
SES	11220.777	10387.7086	28.24317	2.2368756
TBATS	11490.306	10679.3666	28.97837	2.2996809
HOLT-WINTERS	7054.640	5356.483	17.47589	1.1534581
THETAF	8641.998	7628.3891	21.99629	1.6426874
ELM	7249.148	5201.051	17.53616	1.1199875
MLP	10084.1248	8263.2906	23.60782	1.7794062
NNAR	12715.144	11984.9388	32.28306	2.580821



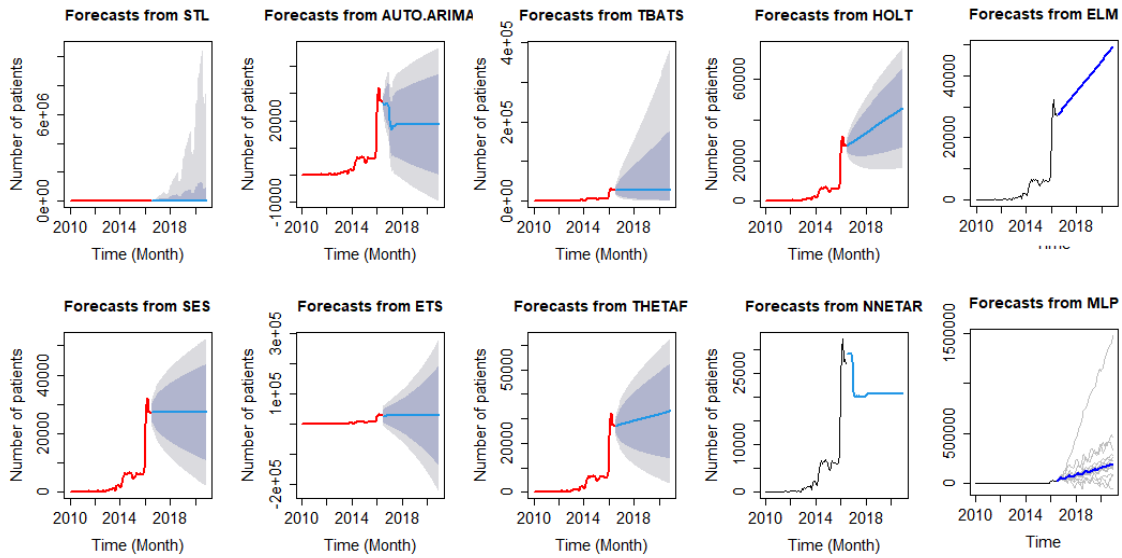
Şekil 3. 7 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 48-aylık tahmin grafikleri

3.2.7 54-Aylık tahmin analizleri: zaman serisinin 78-aylık eğitim/54-aylık test için ayrılması

Çizelge 3.8' da gösterildiği gibi eğitim test bölümlenmesinde 78 aylık eğitim ve 54 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Derin öğrenme ve istatistiksel modelleri model karşılaştırmaları başlığı altında ayrı olarak incelenecektir. Tahmin grafikleri Şekil 3.8'te verilmiştir.

Çizelge 3. 8 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 54-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	54 aylık tahminler için, veri setinin % 60'ü eğitim (78 aylık) % 40'si (54 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	18234.475	16809.1115	44.61080	5.261193
ETS	10672.088	9617.435	26.52015	3.010223
STL	14974.224	13472.7595	37.20791	4.216926
SES	10814.021	9695.3224	26.62030	3.0346017
TBATS	11073.637	9968.4071	27.30658	3.1200762
HOLT-WINTERS	6708.412	4481.3384	15.69018	15.69018
THETAF	8381.143	7263.8461	20.99569	2.2735582
ELM	7561.714	4760.9519	17.04753	1.4901611
MLP	86793.5739	75367.86899	218.9294	23.5898767
NNAR	16477.73	15178.6571	40.59152	4.7508660



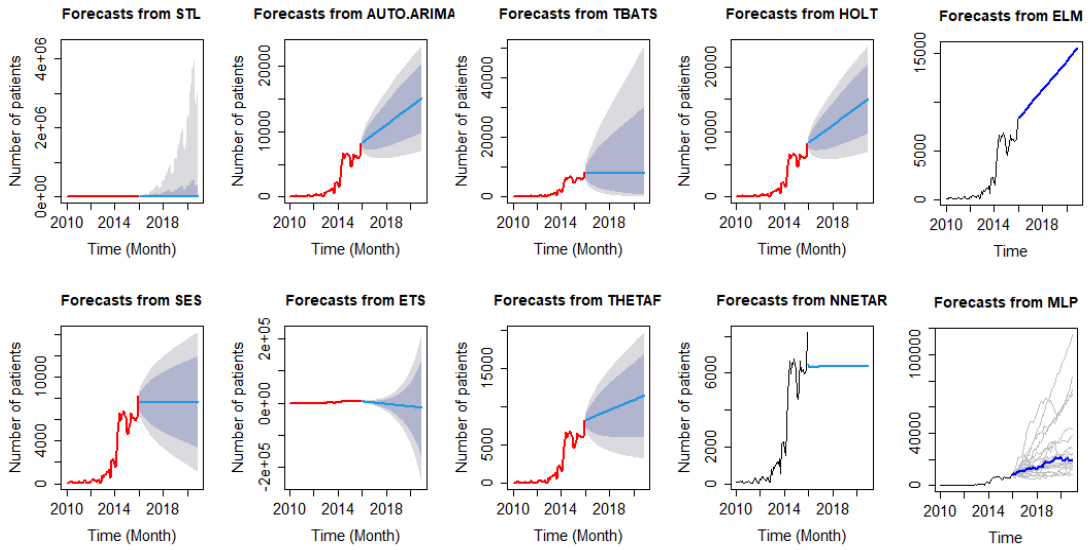
Şekil 3. 8 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 54-aylık tahmin grafikleri

3.2.8 60-aylık tahmin analizleri: Zaman serisinin 72-aylık eğitim/60-aylık test için ayrılması

Çizelge 3.9'de görüldüğü gibi eğitim test bölümlenmesinde 72 aylık eğitim ve 60 aylık test verisine ayrılmış ve analizleri gerçekleştirilmiştir. Derin öğrenme ve istatistiksel modelleri model karşılaştırmaları başlığı altında ayrı olarak incelenecektir. Tahmin grafikleri Şekil 3.9'te verilmiştir.

Çizelge 3. 9 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) model performanslarını karşılaştırmak amacıyla 60-aylık tahmin sonucunda elde edilen RMSE, MAE, MAPE ve MASE hata metrik değerleri

Model Adı	60 aylık tahminler için, veri setinin % 55'ü eğitim (72 aylık) % 45'si (60 aylık) test için ayrılmıştır.			
	RMSE (Test)	MAE (Test)	MAPE (Test)	MASE (Test)
AUTO. ARIMA	24093.9724	23338.2939	65.43491	18.3445906
ETS	41278.540	39845.4624	113.12230	31.3197142
STL	27894.4317	27008.0748	75.85602	21.2291472
SES	28193.2032	27381.8627	77.095717	21.5229555
TBATS	27850.9560	27029.3443	76.03891	21.2458656
HOLT-WINTERS	24101.863	23346.1873	65.45756	18.35080
THETAF	25940.7756	25163.8469	70.66626	19.77952184
ELM	23855.475	23099.4879	64.75059	18.1568820
MLP	20307.3009	19730.6508	55.93070	15.5091356
NNAR	29454.8155	28678.4742	80.98021	22.5421305



Şekil 3. 9 İstatistiksel tabanlı (7-model) ve derin öğrenme tabanlı (3-model) 60-aylık tahmin grafikleri

4. MODEL KARŞILAŞTIRMALARI

4.1 İstatistiksel ve Derin Öğrenme Tabanlı Model Karşılaştırmaları

4.1.1 12-Aylık tahminler için model karşılaştırmaları

12-aylık tahminler için zaman serisinin ilk 120-aylık kısmı, modellerin eğitimi için geriye kalan son 12-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.2’te görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden ETS, SES ve TBATS modelleri sırasıyla %45,098, %49,031 ve %51,461 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %54,902, %50,969 ve %48,539 dür. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 2,214, 2,468 ve 2,628 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği NNAR, MLP ve ELM için hata değerleri sırasıyla %38,886, %43,259 ve %61,422 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %61,114, %56,741 ve %38,578 dir. Aynı modellerin MASE değerleri ise sırasıyla 1,889, 2,229 ve 3,315 dir. Bu durumda derin öğrenme modellerinden olan NNAR %6,212 lik bir değerle en iyi tahmini yapan istatistik tabanlı ETS modelinden %6,212 kadar daha iyi tahmin yapmıştır. Genel anlamda tahmin sonuçlarının düşük çıkmasının nedeni test için kullanılan verinin oldukça kısıtlı olmasına bağlanabilir.

4.1.2 24-Aylık tahminler için model karşılaştırmaları

24-aylık tahminler için zaman serisinin ilk 108-aylık kısmı, modellerin eğitimi için geriye kalan son 24-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.3’te görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden ETS, SES ve TBATS modelleri sırasıyla %19,379, %20,413 ve %22,202 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %80,621, %79,587 ve %77,798 dir. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 1,028, 1,053 ve 1,147 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği NNAR, ELM ve MLP için hata değerleri sırasıyla %19,157, %37,401 ve %43,015 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %80,843, %62,599 ve %56,85 dir. Aynı modellerin MASE değerleri ise sırasıyla 0,992, 2,161 ve 2,522 dir. Bu durumda derin öğrenme modellerinden olan NNAR %0,222 lik bir değerle en iyi tahmini yapan istatistik tabanlı ETS modelinden %0,222 kadar daha iyi tahmin yapmıştır. Her iki gruptaki en iyi tahmin yapan modeller kendi aralarında oldukça yakın tahmin yapmışlardır. Ayrıca test verilerindeki artışın tahmin sonuçlarını da genel anlamda olumlu etkilediğini söylemek mümkündür.

4.1.3 30-Aylık tahminler için model karşılaştırmaları

30-aylık tahminler için zaman serisinin ilk 102-aylık kısmı, modellerin eğitimi için geriye kalan son 30-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.6'da görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden ETS, THETAF ve AUTO. ARIMA modelleri sırasıyla %16,331, %18,552 ve %19,928 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %83,669, %81,448 ve %80,072 dir. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 0,980, 1,131 ve 1,329 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür. Derin öğrenme metotlarının MAPE metriği NNAR, ELM ve MLP için hata değerleri sırasıyla %17,159, %20,946 ve %23,469 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %82,841, %79,054 ve %76,531 dir. Aynı modellerin MASE değerleri ise sırasıyla 1,067, 1,263 ve 1,419 dir. Bu durumda istatistiksel tabanlı ETS modeli derin öğrenme modellerinden olan NNAR'dan %0,828 lik bir değerle daha iyi tahmin yapmıştır. Her iki gruptaki en iyi tahmin yapan modeller kendi aralarında oldukça yakın tahmin yapmışlardır. Bu analizde de test verilerindeki artışın tahmin sonuçlarını da genel anlamda olumlu etkilediğini söylemek mümkündür.

4.1.4 36-Aylık tahminler için model karşılaştırmaları

36-aylık tahminler için zaman serisinin ilk 96-aylık kısmı, modellerin eğitimi için geriye kalan son 36-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.5'de görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden ETS, THETAF ve HOLT-

WINTERS modelleri sırasıyla %8,285, %17,442 ve %19,133 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %91,715, %82,558 ve %80,867 dir. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 0,392, 1,111 ve 1,145 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği ELM, NNAR ve MLP için hata değerleri sırasıyla %19,712 , %21,660, ve %50,352 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %80,288, %78,34, %79,054 ve %49,648 dir. Aynı modellerin MASE değerleri ise sırasıyla 1,173, 1,564 ve 3,119 dir. Bu durumda istatistiksel tabanlı ETS modeli derin öğrenme modellerinden olan ELM'den %11,427 lik bir değerle daha iyi tahmin yapmıştır. Bu analizde, istatistiksel tabanlı modellerin performansları artarken derin öğrenme tabanlı modellerin performansları düşmüştür.

4.1.5 42-Aylık tahminler için model karşılaştırmaları

42-aylık tahminler için zaman serisinin ilk 90-aylık kısmı, modellerin eğitimi için geriye kalan son 42-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.7'de görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden HOLT-WINTERS, ELM ve THETAF modelleri sırasıyla %18,738, %21,296 ve %21,449 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %81,262, %78,704 ve %78,551 dir. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 1,252, 1,602 ve 1,567 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği ELM, NNAR ve MLP için hata değerleri sırasıyla %19,390, %22,070 ve %54,086 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %80,61, %77,93 ve %45,914 dir. Aynı modellerin MASE değerleri ise sırasıyla 1,296, 1,685 ve 2,452 dir. Bu durumda istatistik tabanlı öğrenme modellerinden olan HOLT-WINTERS %0,652 lik bir değerle en iyi tahmini yapan derin öğrenme modeli ELM modelinden %0,652 kadar daha iyi tahmin yapmıştır. Genel anlamda tahmin sonuçlarının düşük çıkmasının nedeni test için kullanılan verinin oldukça kısıtlı olmasına bağlanabilir.

4.1.6 48-aylık tahminler için model karşılaştırmaları

48-aylık tahminler için zaman serisinin ilk 84-aylık kısmı, modellerin eğitimi için geriye kalan son 48-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.8'te görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden HOLT-WINTERS, THETAF ve STL modelleri sırasıyla %17,475, %21,996 ve %24,033 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %82,525, %78,004 ve %75,967 dir. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 1,153, 1,642 ve 1,736 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği ELM, MLP ve NNAR için hata değerleri sırasıyla %17,536, %23,607 ve %32,283 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %82,464, %76,393 ve %67,717 dir. Aynı modellerin MASE değerleri ise sırasıyla 1,119, 1,779 ve 2,580 dir. Bu durumda istatistik tabanlı öğrenme modellerinden olan HOLT-WINTERS %0,061 lik bir değerle en iyi tahmini yapan derin öğrenme modeli ELM modelinden %0,061 kadar daha iyi tahmin yapmıştır. Genel anlamda tahmin sonuçlarının düşük çıkmasının nedeni test için kullanılan verinin oldukça kısıtlı olmasına bağlanabilir.

4.1.7 54-aylık tahminler için model karşılaştırmaları

54-aylık tahminler için zaman serisinin ilk 78-aylık kısmı, modellerin eğitimi için geriye kalan son 54-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.9'da görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden HOLT-WINTERS, THETAF ve ETS modelleri sırasıyla %15,690, %20,995 ve %26,520 gibi hata değerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %84,31, %79,005 ve %73,48 dir. MASE metriğinin küçük değeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE değerleri sırasıyla 1,569, 2,273 ve 3,01 dir. Burada hem MAPE ve hem de MASE metrik değerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği ELM, MLP ve NNAR için hata değerleri sırasıyla %17,047, %21,892 ve %40,591 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %82,953, %78,108 ve %59,409 dir. Aynı modellerin MASE değerleri ise sırasıyla 1,490, 2,358 ve 4,750 dir. Bu durumda istatistik tabanlı öğrenme

modellerinden olan HOLT-WINTERS %1,357 lik bir deęerle en iyi tahmini yapan derin öğrenme modeli ELM modelinden %1,357 kadar daha iyi tahmin yapmıştır. Genel anlamda tahmin sonuçlarının düşük çıkmasının nedeni test için kullanılan verinin oldukça kısıtlı olmasına bağlanabilir.

4.1.8 60-aylık tahminler için model karşılaştırmaları

60-aylık tahminler için zaman serisinin ilk 72-aylık kısmı, modellerin eğitimi için geriye kalan son 60-aylık kısım ise model performanslarını değerlendirmek için test amacıyla kullanıldı. Çizelge 3.10'da görüldüğü gibi MAPE metriğini referans aldığımızda en iyi tahmin yapan istatistiksel tabanlı modellerden AUTO-ARIMA, HOLT-WINTERS ve THETAF modelleri sırasıyla %65,434 %65,457 ve %70,666 gibi hata deęerleri ile ön plana çıkmaktadırlar. Aynı modellerin doğruluk tahminleri ise sırasıyla %34,566, %34,543 ve %29,334 dür. MASE metriğinin küçük deęeri daha iyi tahmin anlamına geldiği için aynı modellerin MASE deęerleri sırasıyla 18,344, 18,350 ve 19,779 dir. Burada hem MAPE ve hem de MASE metrik deęerleri arasında bir uygunluk ilişkisinden söz etmek mümkündür.

Derin öğrenme metotlarının MAPE metriği MLP, ELM ve NNAR için hata deęerleri sırasıyla %55,930, %64,750 ve %80,980 dir. Aynı modellerin MAPE doğruluk yüzdeleri ise sırasıyla %44,07, %35,25 ve %19,02 dir. Aynı modellerin MASE deęerleri ise sırasıyla 15,509, 18,156 ve 22,542 dir. Bu durumda derin öğrenme modellerinden olan MLP %9,504 lik bir deęerle en iyi tahmini yapan istatistik tabanlı AUTO-ARIMA modelinden %9,504 kadar daha iyi tahmin yapmıştır. Genel anlamda tahmin sonuçlarının düşük çıkmasının nedeni test için kullanılan verinin oldukça kısıtlı olmasına bağlanabilir.

4.2 Zaman Serileri için Çapraz-Doğrulama

Model performansını daha sağlıklı değerlendirmek için makine öğrenmede çapraz doğrulama yöntemi kullanılmaktadır. Bu yöntemde verisetin bir kısmı eğitim ve dięer bir kısmı sabit uzunluklu test olmak üzere ikiye ayrılır. Her defasında test verisi k adım kadar ilerleterek geriye kalan kısım eğitim olarak kullanılır. Böylece verinin tamamı hem test hem de eğitim için kullanılma imkânı sağlanır. Nihai olarak elde k adedince bölünen eğitim/test verilerine bağlı olarak yapılan tahminlerin ortalaması alınır.

Ancak bu rastgele yöntem zaman serileri için uygun deęildir. Zaman serileri için başta eğitim verisi hemen ardında test verisi olmak kaydıyla geçmiş ve gelecek arasındaki

ilişkiye zarar vermeden bu işlem gerçekleştirilir ve elde edilen tahminlerin ortalaması alınır.

Şekil 4.1 de verildiği gibi veriseti 132 aylıktan oluşmakta ve başlangıçta test/egitim oranı 1/3 oranında tutulmuştur. K değeri 8 alınmış ve çalışmada kullanılan 10 model için zaman serilerine uygun olarak bir çapraz doğrulama metodu uygulanmıştır. Tahmin için kullanılan test verisini uzunluğu sabit bir şekilde 12-aylık olarak tutulmuştur. Her k değeri için eğitim verisini uzunluğu 12 ay artırılmıştır. Başlangıçta 36-aylık olan eğitim verisi sırasıyla 48, 60, 72, 84, 96, 108 ve 120-aylık olacak şekilde değiştirilmiş ve her model için 8 tane MAPE metrik değeri elde edilmiştir. MAPE metrik değerlerinin model bazındaki ortalamaları ve modellerin tahmin sıralamaları Çizelge 4.1 de verilmiştir.

K/aylar	12	24	36	48	60	72	84	96	108	120	132
1	Eğitim		Test								
2	Eğitim			Test							
3	Eğitim				Test						
4	Eğitim					Test					
5	Eğitim						Test				
6	Eğitim							Test			
7	Eğitim								Test		
8	Eğitim									Test	

Şekil 4. 1 Test verisi sabit olarak uygulanan Zaman serilerinde Çapraz-Doğrulama

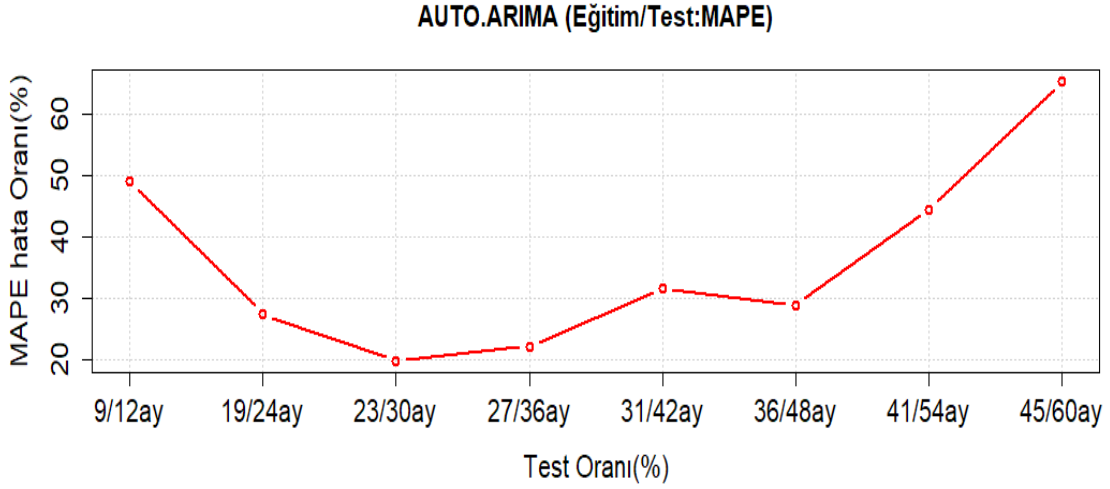
Çizelge 4. 1 12-aylık MAPE tahmin ortalaması

Model adı	MAPE için 12-aylık tahmin ortalaması (%)
ELM	32,59292
AUTO. ARIMA	32,98738
HOLT-WINTERS	33,57381
SES	36,37076
NNAR	38,03891
THETAF	40,51806
ETS	45,66436
MLP	47,20681
TBATS	66,38141
STL	73,13581

Çizelge 4.1'de görüldüğü gibi zaman serilerine uygun olarak k=9 için gerçekleştirilen çapraz-doğrulama neticesinde en iyi başarımlar sırasıyla ELM, AUTO. ARIMA, HOLT-WINTERS, SES ve NNAR olarak elde edilmiştir. ELM ve AUTO. ARIMA modellerinin performansları oldukça yakın olduğu gözlenmektedir. MAPE metriği % olarak modelin yaptığı hatayı ifade ettiğinden dolayı ELM ve AUTO. ARIMA modellerinin tahmin performansları ise sırasıyla %67,41 ve %67,01 olmaktadır.


4.3 Mape hata metriğine göre hata değerlerinin grafiksel incelenmesi

Tez kapsamında uygulanan 10 adet tahmin algoritması ve 8 adet tahmin analizi sonucunda eğitim/test oranına bakılarak algoritma bazlı en iyi tahmin yaptığı eğitim/test oranı saptanmıştır. Kullanılan veri setine bağlı olarak tahmin sürecindeki her bir model için bu oran değişkenlik göstermiştir. Ancak her bir model için eğitim/test oranı kesin olarak ortaya konulmuştur.




Şekil 4. 2 Zaman serilerinde AUTO.ARIMA algoritması için uygulanan 8 tahmin analizi

AUTO.ARIMA modeli için Şekil 4.2' e bakıldığında en iyi tahmin eğitim/test oranı %23 ile 102/30 ay olduğu görülmüştür.




Şekil 4. 3 Zaman serilerinde ETS algoritması için uygulanan 8 tahmin analizi

ETS modeli için Şekil 4.3' e bakıldığında en iyi tahmin eğitim/test oranı %27 ile 96/36 ay olduğu görülmüştür.




Şekil 4. 4 Zaman serilerinde ELM algoritması için uygulanan 8 tahmin analizi

ELM modeli için Şekil 4.4' e bakıldığında en iyi tahmin eğitim/test oranı %41 ile 78/54 ay olduğu görülmüştür.




Şekil 4. 5 Zaman serilerinde HOLT-WINTERS algoritması için uygulanan 8 tahmin analizi

HOLT-WINTERS modeli için Şekil 4.5' e bakıldığında en iyi tahmin eğitim/test oranı %41 ile 78/54 ay olduğu görülmüştür.




Şekil 4. 6 Zaman serilerinde NNAR algoritması için uygulanan 8 tahmin analizi

NNAR modeli için Şekil 4.6' e bakıldığında en iyi tahmin eğitim/test oranı %23 ile 102/30 ay olduğu görülmüştür.




Şekil 4. 7 Zaman serilerinde MLP algoritması için uygulanan 8 tahmin analizi

MLP modeli için Şekil 4.7' e bakıldığında en iyi tahmin eğitim/test oranı %41 ile 78/54 ay olduğu görülmüştür.




Şekil 4. 8 Zaman serilerinde STL algoritması için uygulanan 8 tahmin analizi

STL modeli için Şekil 4.8' e bakıldığında en iyi tahmin eğitim/test oranı %27 ile 96/36 ay olduğu görülmüştür.




Şekil 4. 9 Zaman serilerinde SES algoritması için uygulanan 8 tahmin analizi

SES modeli için Şekil 4.9' e bakıldığında en iyi tahmin eğitim/test oranı %23 ile 102/30 ay olduğu görülmüştür.



Şekil 4. 10 Zaman serilerinde THETAF algoritması için uygulanan 8 tahmin analizi

THETAF modeli için Şekil 4.10' e bakıldığında en iyi tahmin eğitim/test oranı %27 ile 96/36 ay olduğu görülmüştür.



Şekil 4. 11 Zaman serilerinde TBATS algoritması için uygulanan 8 tahmin analizi

TBATS modeli için Şekil 4.11' e bakıldığında en iyi tahmin eğitim/test oranı %27 ile 96/36 ay olduğu görülmüştür.

5. SONUÇLAR ve ÖNERİLER

5.1 Sonuçlar

Tez kapsamında yapılan 8 adet tahmin analizin model bazında tahmin ortalamaları Çizelge 5.1 de verilmiştir.

Çizelge 5. 1 Tez kapsamında yapılan 8 adet tahmin analizi ve mape ortalamaları

Model Adı	12-aylık	24-aylık	30-aylık	36-aylık	42-aylık	48-aylık	54-aylık	60-aylık	Ortalama MAPE (%)
HOLT-WINTERS	56,8272	31,2955	20,1358	19,1333	18,73846	17,47589	15,69018	65,45756	30,59423625
ELM	61,42291	37,40187	20,94631	19,71282	19,39089	17,53616	17,04753	64,75059	32,276135
SES	49,03143	20,41317	20,23326	21,60522	26,43452	28,24317	26,6203	77,09572	33,70959838
NNAR	38,88663	19,15781	17,1596	21,6606	22,07086	32,28306	40,59152	80,98021	34,09878625
ETS	45,09873	19,379	16,331	8,285898	21,29665	27,32205	26,52015	113,1223	34,66947225
TBATS	51,46153	22,20241	23,35809	21,8246	29,37803	28,97837	27,30658	76,03891	35,068565
THETAF	71,49376	46,61802	18,55221	17,44204	21,44906	21,99629	20,99569	70,66626	36,15166625
AUTO. ARIMA	49,18372	27,49869	19,92843	22,28532	31,78319	28,98438	44,6108	65,43491	36,21368
MLP	43,25969	43,01581	23,4698	50,35276	54,08647	23,60782	21,89294	55,9307	39,45199875
STL	62,87592	35,52262	30,32445	22,20748	37,96597	24,03344	37,20791	75,85602	40,74922625

MAPE metriğine göre ortalamalar dikkate alındığında ilk beşte yer alan model performansları HOLT-WINTERS, ELM, SES, NNAR ve ETS olarak sıralanmaktadır. Çizelge 5.1'e göre istatistik tabanlı 7 adet modelin MAPE metriğine göre hata ortalamaları %35,308 iken derin öğrenme tabanlı modellerin hata ortalamaları ise %35,275 tir. Mevcut veriseti üzerinde her iki gruptaki modellerin hataları birbirlerine yakın olmakla birlikte genel anlamda derin öğrenme modellerin daha iyi tahmin yaptığını söylemek mümkündür.

Herhangi bir araştırma niteliği kabul edilen metodolojinin kapsamı ile belirlenir. Bu bölümde hastane servislerine gelen ve radyolojik görüntü istenen hasta sayılarının analizleri yapılmıştır. Geçmişte Muş Devlet Hastanesinde bilgi işlem personeli olarak çalışmam ve bulunduğumuz ildeki tek devlet hastanesi olması hastane seçimimizi etkilemiştir.

Çalışmalarımızda kullanılan veriler kişisel verileri barındırmadığı için etik kurul kararı alınmamıştır. Hastane bilgi işleminden 2010-2020 yılları arasından 132 aylık eğitim/test verisi alınmıştır. Alınan eğitim/test verileri incelendiğinde ilk yıllardaki verilerin tutarsızlığı açıkça fark edilmiştir. Bu eksiklik iki nedene bağlanmıştır. Birincisi dönemin mevcut cihaz sayıları ile yıllar arasındaki cihaz sayılarının eşit olmaması, ikincisi ise hastane bilgi yönetim sistemlerinin ve personellerin belirli aralıklar ile ihale edilerek el değişmesinden kaynaklandığı düşünülmektedir.

Hastaneden alınan ve Çizelge 3.1'de gösterilen verilerdeki eksiklik nedeni tam olarak bilinmediğinden göz ardı edilmiş ve orijinal veri seti üzerinde bir düzeltme işlemi

yapılmadan analizler gerçekleştirilmiştir. Çünkü cihaz yetersizliği, bakımından kaynaklı görüntüleme sayılarındaki tutarsızlık gerçekleşmiş ise orijinal verilere müdahale etmemiz çalışmalarımızın seyrini değiştireceğinden orijinal veriler kullanılmıştır.

Muş devlet hastanesinden almış olduğumuz 132 aylık verimizi 8 ayrı eğitim/test verisi olarak ayrıştırılıp analiz edilmiştir. 120/12, 108/24, 102/30, 96/36, 90/42, 84/48, 78/54 ve 72/60 aylık olarak böldüğümüz verileri belirlemiş olduğumuz istatistiksel ve derin öğrenme modelleri ile eğitilmiş ve çıkan sonuçlar test verileri ile karşılaştırılmıştır. Karşılaştırmalarda kullanılan hata metriklerinde MAPE ve RMSE metrikleri dikkate alınmıştır.

Verilerin analizi sonucu istatistiksel tahmin modellerinden Holt-Winters yöntemi, derin öğrenme modellerinden ise ELM yöntemi en iyi tahmin yapan yöntemler olmuştur. En iyi tahmin yapan bu iki model karşılaştırıldığında 102/30 aylık eğitim/test analiz süreci dışında Holt-Winters yöntemi ELM yönteminden daha başarılı olduğu görülmüştür. 102/30 aylık eğitim/test analiz sürecinde ise ELM yöntemi Holt-Winters yöntemine göre daha başarılı sonuçlar vermiştir. Orijinal verilerdeki eksiklik ve son yıllardaki pandemi süreci analizimizde bir kısıtlılığa neden olmuştur. Genel anlamda tahmin sürecinde en iyi sonuçların Holt-Winters modeli tarafından yapıldığı söylenebilir.

5.2 Öneriler

Sağlık çalışanlarının en büyük yardımcılarının görüntüleme cihazları olduğu bilinmektedir. Bu nedenle görüntüleme cihazlarının yıllık bakımlarının önceden planlanması ve zamanında yapılması hastane, hasta ve doktor için büyük önem arz etmektedir. Görüntüleme sayılarındaki kısıtlılıklar göz ardı edilerek her yıl önceki yıllardan daha fazla görüntüleme sayısına sahip olduğu görülmektedir.

Bu nedenle görüntüleme sayılarındaki artış eğilimlerine bakılarak hastane görüntüleme cihaz ihtiyaçları belirlenmeli ve stratejik planlara dahil edilmelidir.

KAYNAKLAR

- Atakan, Y. 2006. İyonlayıcı Radyasyon, Bilim ve Teknik Dergisi ek: 1.
- Andreas Ekström; Lisa Kurland; Nasim Farrokhnia; Maaret Castrén and Martin Nordberg 2014. Forecasting Emergency Department Visits Using Internet Data. Vol. 65(4), pp. 436-442.
- Brockwell, P. J. and Davis, R. A. 2016. Introduction to time series and forecasting Springer International Publishing.
- Brownlee, J., 2016. “What is Deep Learning?”, Erişim: <https://machinelearningmastery.com/what-is-deep-learning/>
- BROWN, R. G., MEYER, R. F., The fundamental theory of exponential smoothing, Operations Research, 9, 1961, pp. 673-685
- BuHamra, S., Smaoui, N. and Gabr, M. 2003. The BoxJenkins Analysis and Neural Networks: Prediction and Time Series Modelling. Applied Mathematical Modelling, 28, pp. 805-815.
- Chai, T. and Draxler, R. R. 2014. Root mean square error (RMSE) or mean absolute error (MAE)?. Geosci. Model Dev., 7, 1247-1250. Erişim: <https://doi.org/10.5194/gmd-7-1247-2014>.
- Chapman and C Hall/CRC 2000. Time series forecasting. Vol:63(5), pp.85-104
- Çarkacı, N. 2018 Derin Öğrenme Uygulamalarında En Sık kullanılan Hiperparametreler Erişim Adresi: <https://medium.com/deep-learning-turkiye/derin-ogrenmeuygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>
- Dagum, E.B.; Bianconcini, S. *Seasonal Adjustment Methods and Real Time Trend-Cycle Estimation*; Springer: Berlin/Heidelberg, Germany, 2016.
- Davood Golmohammadi 2016. Predicting hospital admissions to reduce emergency department boarding.
- De Livera, A.M.; Hyndman, R.J.; Snyder, R.D. Forecasting Time Series with Complex Seasonal Patterns using Exponential Smoothing. J. Am. Stat. Assoc. **2010**, 106, 1513–1527.
- Eleftherios Thalassinos and Diana-Mihaela Pociovălişteanu (2008). A Time Series Model for the Romanian Stock Market.
- Fuh-Yuan Shih; Matthew Heui-Ming; Shyr-Chyr Chen; Hsio-Po Wang; Cheng-Chung Fang; RenShi Shyu; Guan-Tarn Huang and Shih-Ming Wang 1997. ED Overcrowding in Taiwan: Facts and Strategies.
- Gardner Jr, E. S. 1985. Exponential smoothing: The state of the art. *Journal of forecasting*, 4(1), 1-28.
- Golmohammadi, Davood. 2016. “Predicting Hospital Admissions to Reduce Emergency Department Boarding.” International Journal of Production Economics 182:535–44.
- Gökhan, P. 2017. Radyasyonun Sağlık Etkileri Sunum Öncesi Pretest
- Gürsu, S., Gürsu, T., Çamurcu, Y., Yıldırım, Y., Gürsu, A., Şahin, V. (2013) Pediatrik Pelvis Röntgenlerinde Gonad Koruyucu Kullanımının Etkinliği, Eklem Hastalıkları

ve Cerrahisi Dergisi, 2013;24(2):87-90.
http://www.taek.gov.tr/ogrenci/bolum4_04.html erişim tarihi 17-04-2014.

- Harrou, Fouzi, Abdelkader Dairi, Farid Kadri, and Ying Sun. 2020. "Forecasting Emergency Department Overcrowding: A Deep Learning Framework." *Chaos, Solitons and Fractals* 139:110247.
- Hyndman, R. Forecast: Forecasting Functions for Time Series and Linear Models. R Package Version 8.2. 2017. Erişim: <http://pkg.robjhyndman.com/forecast> Erişim Tarihi: 09.08.2017.
- Hyndman, R.J.; Athanasopoulos, G. *Forecasting: Principles and Practice*; OTexts: Melbourne, Australia, 2018.
- Ihaka, R., and Gentleman, R., "R: A Language for Data Analysis and Graphics", *Journal of Computational and Graphical Statistics*, 5(3), 299-314 1996.
- Jilani, Tahseen, Gemma Housley, Graziela Figueredo, Pui Shan Tang, Jim Hatton, and Dominick Shaw. 2019. "Short and Long Term Predictions of Hospital Emergency Department Attendances." *International Journal of Medical Informatics* 129:167–74.
- Jochen Bergs; Philippe Heerinckx and Sandra Verelst (2013). Knowing what to expect, forecasting monthly emergency department visits: A time-series analysis.
- John E. Hanke and Dean Wichern 2014. *Business Forecasting*.
- Jones, Spencer S., Alun Thomas, R. Scott Evans, Shari J. Welch, Peter J. Haug, and Gregory L. Snow. 2008. "Forecasting Daily Patient Volumes in the Emergency Department." *Academic Emergency Medicine* 15(2):159–70.
- Kaynar O, Taştan S 2009. Zaman serisi analizinde MLP yapay sinir ağları ve arıma modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 33: 161-172.
- Kın, B.Z., 2019 Türk İşaret Dili Alfabetinin Derin Öğrenme Yöntemi İle Sınıflandırılması, Başkent Üniversitesi, Yüksek Lisans Tezi
- Leslie S. Zun 2009. *Analysis of the Literature on Emergency Department Throughput*
- Lisa M. Schweigler; Jeffrey S. Desmond; Melissa L. McCarthy; Kyle J. Bukowski; Edward L. Ionides and John G. Younger 2009. *Forecasting Models of Emergency Department Crowding*.
- Mohamed Afilal; Farouk Yalaoui; Frederic Dugardin; Lionel Amodeo; David Laplanche and Philippe Blua 2016. *Emergency Department Flow: A new practical patient classification and forecasting daily attendance*. Vol. 49. pp.721-726.
- M. Q. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings," *Renew. Sustain. Energy Rev.*, vol. 50, pp. 1352–1372, Oct. 2015.
- Neural Network. 2016 Erişim: <http://www.texample.net/tikz/examples/neuralnetwork/>.
- Orhunbilge, N. 1999. *Zaman Serileri Analizi Tahmin ve Fiyat Endeksleri*, Avcıol. Basım Yayın; İstanbul.
- Öztemel E 2012. *Yapay Sinir Ağları*. Üçüncü baskı. Papatya Yayıncılık Eğitim AŞ. İstanbul, No. 11/3, 29-59.

- Ünlük, İ. H. and Pala, Z. 2019 ‘Prediction of monthly electricity consumption used in Muş Alparslan University Complex by means of Classical and Deep Learning methods’, *International Conference on Data Science, Machine Learning and Statistics - 2019 (DMS-2019)*, 1(1), pp. 237–239.
- Pala, Z. 2019 ‘Using Decomposition-based Approaches to Time Series Forecasting in R Environment’, *International Conference on Data Science, Machine Learning and Statistics - 2019 (DMS-2019)*, 1(1), pp. 231–233.
- Pala, Z. 2019 ‘Using forecastHybrid Package to Ensemble Forecast Functions in the R’, *International Conference on Data Science, Machine Learning and Statistics - 2019 (DMS-2019)*, 1(1), pp. 45–47.
- Pala, Z. 2021 ‘Examining EMF Time Series Using Prediction Algorithms With R’. *IEEE*, 44(2), pp. 223–227.
- Pala, Z., Ünlük, İ. H. and Yaldız, E. 2019 ‘Forecasting of electromagnetic radiation time series: An empirical comparative approach’, *Applied Computational Electromagnetics Society Journal*, 34(8).
- Pala, Z., Bozkurt, I. and Etem, T. 2017 ‘Estimation of low frequency electromagnetic values using machine learning’, in *2017 13th International Conference Perspective Technologies and Methods in MEMS Design, MEMSTECH 2017 - Proceedings*. doi: 10.1109/MEMSTECH.2017.7937550.
- Pala, Z. and Atici, R. 2019 ‘Forecasting Sunspot Time Series Using Deep Learning Methods’, *Solar Physics*. Springer Nature B.V., 294(5). doi: 10.1007/s11207-019-1434-6.
- Pala, Z. and Pala, A. F. 2020 ‘Perform Time-series Predictions in the R Development Environment by Combining Statistical-based Models with a Decomposition-based Approach’, *Muş Alparslan University Journal of Engineering and Architecture Faculty*, 1(1), pp. 55–63.
- Pala, Z. and Özkan, O. 2020 ‘Artificial Intelligence Helps Protect Smart Homes against Thieves’, *DÜMF Mühendislik Dergisi*, 11(3), pp. 945–952. doi: 10.24012/dumf.700311.
- Pala, Z., Yamli, V. and Ünlük, İ. H. 2017 ‘Deep Learning researches in Turkey: An academic approach’, in *2017 13th International Conference Perspective Technologies and Methods in MEMS Design, MEMSTECH 2017 - Proceedings*. doi: 10.1109/MEMSTECH.2017.7937546.
- Pala, Z. and Şana, M. 2020 ‘Attackdet: Combining web data parsing and real-time analysis with machine learning’, *Journal of Advances in Technology and Engineering Research*, 6(1), pp. 37–45. doi: 10.20474/jater-6.1.4.
- Patrick Aboagye-Sarfo; Qun Mai; Frank M. Sanfilippo; David B. Preen; Louise M. Stewart and Daniel M. Fatovich 2015. A comparison of multivariate and univariate time series approaches to modelling and forecasting emergency department demand in Western Australia.
- Salaudeen, A. A. 2018. Forecasting Patient Volume In An Emergency Department Using Time Series Methods : An Application Of A Medical. I.
- Sena, D., & Nagwani, N. K. 2016. A neural network auto regression model to forecast per capita disposable income. *ARNP Journal of Engineering and Applied Sciences*, 11(22), 13123–13128.

- Shahid, Khubaib, Tariq Manzoor, Muhammad Ibrahim, Tanveer Ahmed, and Muhammad Fiaz. 2016. "Forecasting of Monthly Patient Volume at Radiology Department Coming for Ultrasound: A Time Series Approach." *Journal of University Medical and Dental College, JUMDC* 7(3):22–27.
- Spencer S. Jones; Alun Thomas; R. Scott Evans; Shari J. Welch; Peter J. Haug and Gregory L. Snow 2008. *Forecasting Daily Patient Volumes in the Emergency Department* Vol. 15. pp. 159-170.
- T.C. Sağlık Bakanlığı. 2019. 2018 Sağlık İstatistikleri Yıllığı. *Sağlık Bilgi Sistemleri Genel Müdürlüğü*, 27.
- T.C. Sağlık Bakanlığı. 2020. 2019 Sağlık İstatistikleri Yıllığı. *Sağlık Bilgi Sistemleri Genel Müdürlüğü*, 176.
- Yaldız, E. and Pala, Z. 2018 'Time Series Analysis of Radiological Data of Outpatients and Inpatients in Emergency Department of Mus State Hospital', *International Conference on Data Science, Machine Learning and Statistics - 2019 (DMS-2019)*, pp. 234–236.
- Wang, J.; Hu, J. A robust combination approach for short-term wind speed forecasting and analysis – Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. *Energy* **2015**, 93, 41–56.
- Wolpert, D. and Macready, W. 1997. No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1):67-82.
- Xu, Qinneng, Kwok Leung Tsui, Wei Jiang, and Hainan Guo. 2016. "A Hybrid Approach for Forecasting Patient Visits in Emergency Department." Pp. 2751–59 in *Quality and Reliability Engineering International*. Vol. 32. John Wiley and Sons Ltd.
- Zhang, G. P., Patuwo, B. E. and Hu, M. Y. 2001. A simulation study of artificial neural networks for nonlinear time series forecasting. *Computers & Operations Research*, vol. 28, pp. 381-396.
- Zhang, Yumeng, Li Luo, Fengyi Zhang, Ruixiao Kong, Jianchao Yang, Yabing Feng, and Huili Guo. 2020. "Emergency Patient Flow Forecasting in the Radiology Department." *Health Informatics Journal* Vol
- Zhou, G.Z., Wong, D.D., Nguyen. L.K., Mendelson, RM. 2010. Student and intern awareness of ionising radiation exposure from common diagnostic imaging procedures. *Journal of Medical Imaging and Radiation Oncology*, 54 2010. 17–23.
- www.taek.gov.tr/bilgi/bilg erişim tarihi 17-04-2014.
- <http://www.taek.gov.tr/radyasyon-guvenligi-sss/681-radyoloji-unitelerinde-koruyucugiyisi-kullanilmasi-zorunlu-mudur.html> Erişim tarihi:13.07.2014.