



T.C.

ALTINBAŞ ÜNİVERSİTESİ

Lisansüstü Eğitim Enstitüsü

Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı

**SAĞLIK 4.0 BÜTÜNCÜL YAKLAŞIM
AŞI TALEP TAHMİN ÖRNEĞİ**

Neriman ŞEN EKŞİ

Doktora Tezi

Danışman

Doç. Dr. Doğu Çağdaş ATILLA

İstanbul, 2025

SAĞLIK 4.0 BÜTÜNCÜL YAKLAŞIM: AŞI TALEP TAHMİN ÖRNEĞİ

Neriman ŞEN EKŞİ

Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı

Doktora Tezi

ALTINBAŞ ÜNİVERSİTESİ

2025

“Neriman ŞEN EKŞİ” tarafından hazırlanmış ve 28.01.2025 tarihinde sunulmuş “SAĞLIK 4.0 BÜTÜNCÜL YAKLAŞIM: AŞI TALEP TAHMİN ÖRNEĞİ” başlıklı tez Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalında Doktora Tezi olarak **oy birliği** ile kabul edilmiştir.

Doç. Dr. Doğu Çağdaş ATILLA

Danışman

Tez Savunma Sınavı Jüri Üyeleri:

Doç. Dr. Doğu Çağdaş ATILLA

Elektrik-Elektronik Mühendisliği
Bölümü

Altınbaş Üniversitesi

Doç. Dr. Oğuz ATA

Yazılım Mühendisliği Bölümü

Altınbaş Üniversitesi

Doç. Dr. Aytuğ BOYACI

Bilgisayar Mühendisliği Bölümü

Milli Savunma Üniversitesi

Dr. Öğr. Üyesi Abdullahı Abdu IBRAHİM

Elektrik-Elektronik Mühendisliği
Bölümü

Altınbaş Üniversitesi

Dr. Öğr. Üyesi Cahit KARAKUŞ

Bilgisayar Mühendisliği Bölümü

İstanbul Esenyurt Üniversitesi

Bu tezin doktora tezi olarak bütün şartları sağladığını beyan ederim.

Bu tezdeki tüm bilgilerin akademik kurallara ve etik davranışlara uygun olarak edinildiğini ve sunulduğunu beyan ederim. Ayrıca, bu kuralların ve davranışların gerektirdiği şekilde, bu çalışmada, orijinal olmayan tüm materyalleri ve sonuçları tamamen alıntı yaptığımı ve referans gösterdiğimi de beyan ederim.

Neriman ŞEN EKŞİ

İmzası

XXXXXX

ÖZET

SAĞLIK 4.0 BÜTÜNCÜL YAKLAŞIM: AŞI TALEP TAHMİN ÖRNEĞİ

EKŞİ ŞEN Neriman

Doktora, Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı, Altınbaş Üniversitesi

Danışman: Doç. Dr. Doğu Çağdaş ATILLA

Tarih: Ocak/2025

Sayfa: 109

Bu çalışmada Sağlık 4.0 açıklanarak, mevcut yöntemlerden farklı olarak, aşı kıtlığı ve fazlalığını önlemek için uygun aşı stokunu tahmin etmek amacıyla makine öğrenmesi yöntemleri uygulanmış ve başarıları karşılaştırılmıştır. Aşı talebi, artan nüfus hareketliliği ve salgınların yaygınlığı nedeniyle çeşitli ülkelerde önemli ölçüde artmaktadır. Bu çalışma hem aşı kıtlığını hem de aşırı arzı önlemeyi amaçlayarak en uygun aşı stok seviyelerini tahmin etmek için makine öğrenimi yöntemleri kullanmıştır ve bu tahminlerin etkinliğini karşılaştırmayı hedeflemiştir. Tahmin modellerinde kullanılan veriler, Hudut ve Sahiller Sağlık Genel Müdürlüğü'nden temin edilmiştir. Bu çalışma, 2003 ile 2023 yılları arasında toplanan 21 yıllık geriye dönük bir veri setini analiz edilmektedir; bu veri seti aylık aşılama kapsamı verilerini içermektedir. Yıllık aşı talebini tahmin etmek için literatürde yaygın olarak kullanılan dört farklı yöntem uygulanmaktadır. Bunlar arasında en yaygın kullanılan yöntem Otoregresif Entegre Hareketli Ortalama (ARIMA) olduğu tespit edilmektedir. Ayrıca, Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA), Doğrusal Regresyon ve XGBoost modelleri de kullanılmaktadır. COVID-19 pandemisi gibi belirli olaylar, veri setindeki kalıpları bozmuştur. Budama testlerinde, ham veri setindeki veri frekansındaki değişiklikler analiz edilmektedir. Modeller, Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Hata (MAE) kullanılarak değerlendirilmektedir. Tüm veri seti, durağanlık sağlamak için dönüş-

türülmektedir. Mevsimselliğin ve beyaz gürültünün kaldırılmasının ardından modeller yeniden değerlendirilmektedir. En doğru tahminleri veren modellere çapraz doğrulama uygulanmaktadır. Optimize edilmiş modelden elde edilen tahmin sonuçları, Değer Risk (VaR) modeline girdi olarak kullanılmaktadır. Gerçek, kestirim ve ortalama aşılama sayıları, SARIMA, Doğrusal Regresyon ve XGBoost tahminlerine dayalı olarak %95 ve %99 güven aralıkları (kritik stok aralığı) ile sunulmaktadır. Aşı tahmin aralığı dengesi nedeniyle, XGBoost'un çıktıları Değer Risk (VaR) modeline girdi olarak alınmakta ve önümüzdeki günlerde ortaya çıkabilecek güvenli aşı stoku ile ilgili maliyet riski değerlendirilmektedir. Çalışma boyunca, modellerin etkili bir şekilde öğrenmeye devam edebileceği koşullar ile bu modellerin seçilme gerekçesi izlenebilmektedir.

Anahtar Kelimeler: Sarı Humma Aşı, Makine Öğrenimi, Birliktelik Teknikleri, ARIMA, SARIMA, Lineer Regresyon, XGBoost.

ABSTRACT

HEALTH 4.0 HOLISTIC APPROACH: VACCINE DEMAND FORECASTING EXAMPLE

EKŞİ ŞEN Neriman

Ph.D., Electrical and Computer Engineering, Altınbaş University

Supervisor: Assoc. Prof. Dr. Doğu Çağdaş ATİLLA

Date: January/2025

Page: 109

In this study, Health 4.0 is explained, and unlike existing methods, machine learning techniques are applied to predict the appropriate vaccine stock in order to prevent vaccine shortages and surpluses, and their successes are compared. The demand for vaccines is significantly increasing in various countries due to heightened population mobility and the prevalence of epidemics. This study employed machine learning methods to predict optimal vaccine stock levels, aiming to prevent both shortages and oversupply, and to compare the effectiveness of these predictions. The data utilized in the prediction models were sourced from the General Directorate of Border and Coastal Health. This study analyzed a 21-year retrospective dataset collected between 2003 and 2023, which contains monthly vaccination coverage data. Four different methods commonly used in the literature were applied to estimate annual vaccine demand. Among these, the most widely utilized method was the Autoregressive Integrated Moving Average (ARIMA). Additionally, Seasonal Autoregressive Integrated Moving Average (SARIMA), Linear Regression, and XGBoost models are employed. Certain events, such as the COVID-19 pandemic, disrupt patterns within the dataset. In pruning tests, variations in data frequency within the raw dataset are analyzed. The models are evaluated using Root Mean Square Error (RMSE) and Mean Absolute Error (MAE). The entire dataset is then transformed to achieve stationarity. The models are re-evaluated after removing seasonality and white noise. Cross-validation is applied to the models that yield the most accurate predictions. The forecast results obtained from the optimized model serve

as input for the Value at Risk (VaR) model. Actual, projected, and average vaccination numbers are presented with 95% and 99% confidence intervals (critical stock range) based on SARIMA, Linear Regression and XGBoost estimates. Due to the vaccine forecast range balance, XGBoost's outputs are input into the Value at Risk (VaR) model and the cost risk related to the safe vaccine stock that may arise in the coming days is evaluated. Throughout the study, the conditions under which models can continue to learn effectively, as well as the rationale for selecting these models, can be monitored.

Keywords: Yellow Fever, Machine Learning, Ensemble Technique, ARIMA, SARIMA, Linear Regression, XGBoost.



İÇİNDEKİLER

Sayfa

ÖZET	v
ABSTRACT	vii
TABLO LİSTESİ.....	xi
ŞEKİL LİSTESİ	xiii
KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. MALZEME VE YÖNTEMLER	6
2.1 SAĞLIK 4.0 TEKNOLOJİLERİ	9
2.2 SAĞLIK ALANINDA MAKİNE ÖĞRENİMİ ÇALIŞMA ÖRNEKLERİ	14
2.3 AŞILAMA LİTERATÜR ARAŞTIRMASI	17
2.4 SARIHUMMA AŞI VERİLERİNİN ANALİZİ.....	17
2.4.1 Verilerin Analizi	18
2.4.2 Verilerin Hazırlanması.....	20
2.4.3 Modelleme	22
2.4.4 ARIMA	23
2.4.5 SARIMA	29
2.4.6 Lineer Regresyon	31
2.4.7 XGBoost	33
2.4.8 Denetimli Öğrenme.....	33
2.4.9 Denetimsiz Öğrenme	34
2.4.10 Takviyeli Öğrenme	34
2.4.11 Arttırma Karar ağaçları	34
2.4.12 Aşırı Arttırma Karar ağaçları	34
2.4.13 Karekök Ortalama Hata	38
2.4.14 Ortalama Mutlak Hata.....	38

2.4.15 Uygulama.....	39
2.4.16 Veri Manüplasyonu.....	41
2.4.17 Sarı Humma Aşılama Kapsamı Zaman Serisi Analizleri	51
2.5 EKONOMİ UYGULAMASI.....	65
2.5.1 Riske Maruz Değer (VAR)	76
3. TARTIŞMA VE LİMİTLER	87
4. SONUÇ	88
REFERANSLAR	90
EK A	101

TABLO LİSTESİ

	<u>Sayfa</u>
Tablo 2.1: Literatürdeki Aşı Tahmin Çalışmaları	18
Tablo 2.2: 2023 ile 2009 Arası Sarıhumma Aşılama Sayıları.....	19
Tablo 2.3: 2010 ile 2016 Arası Sarıhumma Aşılama Sayıları.....	19
Tablo 2.4: 2017 ile 2023 Arası Sarıhumma Aşılama Sayıları.....	20
Tablo 2.5: Tüm Veri Setinin Tanımlayıcı İstatistiği.....	44
Tablo 2.6: Tüm Veri Setinde Eğitilen Modellerin Başarı Sıralaması.....	44
Tablo 2.7: COVID-19 Salgın Hariç Tanımlayıcı İstatistikler	48
Tablo 2.8: COVID-19 Hariç Tutulduğunda Modellerin Başarı Sıralaması.....	48
Tablo 2.9: Veri Varyansını Bozan Günlük Siyasi Atak Dönemleri Hariç İstatistikler	50
Tablo 2.10: Varyansın Etkisi Elimine Edilince Model Başarı Sıralaması	50
Tablo 2.11: Mann-Kendal ve Tau Test Sonuçları	53
Tablo 2.12: İlk ADF ve KPSS Sonuçları.....	54
Tablo 2.13: Fark Alma İşlemi Sonrası ADF ve KPSS Sonuçları.....	55
Tablo 2.14: Beyaz Gürültü Ljung-Box Test Sonuçları.....	55
Tablo 2.15: AIC Sonuçları.....	56
Tablo 2.16: SARIMA ve ARIMA'nın Ham Veri ve İşlenmiş Veri Seti Üzerindeki Başarıları	57
Tablo 2.17: Mevsimsellikten Arındırılan ve Duranlaştırılan Veri Setindeki Modellerin Başarı Sıralaması	58
Tablo 2.18: SARIMA Aşırı Öğrenme Eğilimin Nedeniyle Modele Çapraz Doğrulama Uygulanması.....	60

Tablo 2.19: SARIMA (1,1,1)(1,1,1,12) Tahmin Sayıları	61
Tablo 2.20: ARIMA (0,1,2) Tahmin Sayıları	61
Tablo 2.21: SARIMA (0,1,2)(0,1,2,12) Tahmin Sayıları	62
Tablo 2.22: SARIMA(0,1,2)(0,1,2,12) Gerçek ve Tahmin Güven Aralıkları	66
Tablo 2.23: SARIMA(1,1,1)(1,1,1,12) Gerçek ve Tahmin Güven Aralıkları	68
Tablo 2.24: Lineer Regresyon Gerçek ve Tahmin Güven Aralıkları	71
Tablo 2.25: XGBoost Tahmin Güven Aralıkları	72
Tablo 2.26: SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralıkları(Daraltılmış Aralıklar) ..	73
Tablo 2.27: XGBoost Tahmin Güven Aralıkları (Daraltılmış Aralıklar)	75
Tablo 2.28: VaR Parametreleri	79
Tablo 2.29: VaR Değerleri	79

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: Veri Madenciliği için Çapraz Endüstri Standart Süreci ile Çalışmanın Akışı	4
Şekil 2.1: Sağlık 4.0 Bütüncül Kavramsal Yaklaşım	12
Şekil 2.2: Sağlık 4.0 İlişkisel Teknoloji Yönetim	16
Şekil 2.3: 2003-2023 Yılları Sarıhumma Aşı Verilerinin Aylara Göre Kullanımı	21
Şekil 2.4: COVID-19'un Etkilediği 2021 ve 2022 Hariç.	21
Şekil 2.5: 2003-2023 Yılları Arasında Sarıhumma Aşı Verilerinin Aylara Göre Yıllık Akışı, (2018 ve 2022 hariç).....	22
Şekil 2.6: Sarı Humma Aşılarının Zamana Bağlı En Yüksek ve Düşük Kullanımı	25
Şekil 2.7: Single Entitiy Annual Distribution (SMA)	26
Şekil 2.8: Cumulative Entitiy Annual Distribution (CMA)	27
Şekil 2.9: Waightage Entitiy Annual Distribution (WMA).....	28
Şekil 2.10: Exponential Annual Distribution (EMA).....	29
Şekil 2.11: Single, Bagging, Boosting Çalışma Mantığı.....	36
Şekil 2.12: Boosting Çalışma Mantığı.....	37
Şekil 2.13: ARIMA(1,1,1) Sarı Humma Artık Değeri ve Gözlem Sırası Grafiği	42
Şekil 2.14: Sarı Humma Aşısı Yoğunluk	45
Şekil 2.15: ARIMA Modeli Gerçek Verilere Karşı Model Tarafından Tahmin Edilen Aşı Verilerinin Grafiği	46
Şekil 2.16: SARIMA Öncesi RMSE Sonuçları	47
Şekil 2.17: Tüm Ham Veri RMSE and MAE Scorlar Grafiği (Mevsimsellik ve Durağanlık Test Öncesi).....	47

Şekil 2.18: COVID-19 Hariç Veri RMSE and MAE Scorlar Grafiği (Mevsimsellik ve Durağanlık Test Öncesi).....	49
Şekil 2.19: SARIMA Sonuçları 1 (Mevsimsellik Etkisi ve Durağanlaştırılmadan).....	52
Şekil 2.20: Mevsimsel Aşılarda Sayısının Zamanla Değişimi.....	52
Şekil 2.21: Mevsimsel Fark Alınmış ADF ve PACF Grafiği.....	54
Şekil 2.22: SARIMAX(1,1,1)(1,1,1,12) Sonuçları.....	57
Şekil 2.23: SARIMA(1,1,1)(1,1,1,12) Sarı Humma Artık Değeri ve Gözlem Sırası Grafiği	59
Şekil 2.24: SARIMA İlk Tahmin Sonucu	63
Şekil 2.25: SARIMA ve ARIMA Tahminleri Karşılaştırması	64
Şekil 2.26: SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralığının Gerçek Veri Grafiği ...	667
Şekil 2.27: SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralığı	68
Şekil 2.28: SARIMA(1,1,1)(1,1,1,12) Tahmin Güven Aralığı	69
Şekil 2.29: Lineer Regresyon Tahmin Doğrusunun Gerçek Verilerle Gösterimi	70
Şekil 2.30: Lineer Regresyon Tahmin Güven Aralığı.....	71
Şekil 2.31: 2003-2023 Yılları Arasında Aylık Aşı Verilerinin Yıllık Akışları	72
Şekil 2.32: XGBoost Tahmin Güven Aralıkları	73
Şekil 2.33: Sadeleştirilen SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralıkları	74
Şekil 2.34: Sadeleştirilen XGboost Tahmin Güven Aralıkları	74
Şekil 2.35: Standart Sapma Güven Aralıkları	76
Şekil 2.36: XGboost Binde Tahmin Hata/RPN İle Güvenli Stok Aralığı Dengesi	77

KISALTMALAR

AI	:	Artificial Intelligence
ARIMA	:	Autoregressive Integrated Moving Average
AG	:	Augmented Reality
BMA	:	Bussiness Management Application
BCAM	:	Bio Computer Aided Manufacturing
CRISPDM	:	Cross Industry Standard Process for Data Mining
DG	:	Digital Grift
EHR	:	Electronic Health Record
EB	:	Ensemble Boosting
EDGE	:	Cutting Edge of the Technology
EHR	:	Electronic Health Record
e-GM	:	e-Government Entegration
HCT	:	High Compression Technology
HIPAA	:	Health Insurance Portability and Accountability Act
IC	:	Integrity Container
IDE	:	Integrated Development Environment
IoHT	:	Internet of Health Things
INFRAM	:	Infrastructure Analytics Model
IO	:	Intelligence Orchestrator
KPI	:	Key Performance Index
LTE	:	Internet of Things Long-Term Evolution
MAE	:	Mean Absolute Error


MCAD	:	Medical Computer Aided Design
MSS	:	Micro Source Services
NASA	:	National Aeronautics and Space Administration
QMS	:	Quality Management System
ODS	:	Otonom Data Center
PaaS	:	Platform-as-a-Service
RAMI	:	Reference Architectural Model for Industry 4.0
RMSE	:	Root Mean Square Error
RPN	:	Risk Priority Number
RA	:	Robotic Adaptive
SARIMA	:	Mevsimsel Otoregresif Entegre Hareketli Ortalama
STM	:	Smart Technology Management
SOM	:	System on Module
TSM	:	Total System Maintenance
WiFi	:	Wireless Fidelity
WiMAX	:	Worldwide Interoperability for Microwave Access
WT	:	Wearable Technologies
VMRT	:	Voip Medical Record Technology

1. GİRİŞ

Sağlık sektöründe ilaç arz ve talebinin yönetimi, büyüyen ulusal ekonomiler için bir önceliktir. Daha fazla verimlilik, daha az israf, daha düşük maliyetler ve daha yüksek kâr anlamına gelmektedir. Ancak en önemli konu, küresel ortaklıkların temel amaçlarından biri olan düşük ve orta gelirli ülkelerde aşılar erişiminin sağlanması ve aşıların alımının temin edilmesidir.[1] Bu amaçla, soğuk zincir tedarik yönetiminde ve aşı stok yönetiminde çeşitli talep tahmin yöntemleri kullanılmaktadır.[2] Aşı talebi tahmini, hedef popülasyon büyüklüğüne ve aşılama stratejilerine dayalı olarak gerekli aşı dozu sayısını tahmin eden matematiksel bir hesaplama değildir.[3] Yine de, soğuk zincirlerdeki aşı stoklarına olan talebi tahmin etmek hâlâ bir dizi zorluk içermektedir. Aşı dağıtımının herhangi bir aşamasındaki tedarik zinciri sorunları, aşılama programlarının düzgün işleyişini bozabilmektedir. Kazanılan bilgiler, kuruluş çapında karar almayı desteklemek için kullanılmaktadır.[4] Aynı zamanda, tedarik zinciri ortaklarının seçiminde de önemli bir yardımcıdır. Tahmin teknikleri, kapsamlı veri havuzlarına dayanmaktadır.[5] Çoklu veri kaynakları ve toplama katmanları nedeniyle yüksek derecede karmaşıklık söz konusu olabilmektedir.[6] Soğuk zincirlerle taşınan aşıların depolanması, taşıma kapasitesini ve maliyetleri artırmaktadır; bu nedenle aşı tedarik zincirini yönetmek karmaşık ve zordur. Aşı talebi tahmin aracı, küçük depolama alanı, düşük envanter, stok fazlası ve bakım maliyetleri gibi bir dizi sorunun çözülmesine yardımcı olmaktadır.[7] Ayrıca, aşı talebi tahmini, daha iyi envanter ve gelişmiş tedarik zinciri yönetimi sağlayarak mali durumu güçlendirmektedir. Teslimat duyarlılığında, aşı bulunabilirliğinde, zamanında ve tam teslimat sürelerinde iyileşme, stokta bulunmayan konumların yüzdesinde azalma gibi faydaları bulunmaktadır.[8] Sürekli en uygun şekle sokma fırsatlarını yakalayarak, iş hedeflerimize ulaşmak için yararlanabileceğimiz araçlara ilişkin daha derin içgörüler elde edilmesini sağlamaktadır. Doğru öngörülerle anlamlı KPI'lar oluşturmak daha kolaydır.[9] Amaç, gerçek sayıların olabildiğince yakın tahmin edilmesidir. Dünya çapındaki tedarik zincirlerinin fırsat ve yeteneklerindeki farklılıklar göz önüne alındığında, seyahat mesafelerinin azaltılması ve salgına maruz kalan ülkelerin desteklenmesi, ülkelerin birbirlerinin aşı bulunabilirliğini destekleyebilmesi için bir dizi stratejinin ve hastalık etkilerinin uluslararası ortamda incelenmesini elzem kılmaktadır. Malzeme kıtlığı, güvenlik kaygıları ve atıkların düzenli depolama alanlarından uzaklaştırılması konularını ele alan çalışmalar gibi, kaynak planlaması ve atıkların önlenmesi de önceliklendirilmelidir.

Talep tahmininde kalitatif, kantitatif, karma ve hibrit yöntemler kullanılmaktadır.[10] Niteliksel yöntemler arasında pazar araştırmaları, uzman paneller ve Delphi yöntemi yer almaktadır.[11] Nicel yöntemler ise zaman serisi, regresyon ve üstel düzeltme modellerini içermektedir. Hibrit yöntemler hem niteliksel hem de niceliksel teknikleri birleştirerek daha doğru ve kapsamlı tahminler elde etmek için kullanılabilir. Makine öğrenimi, bu tür hibrit yöntemler arasında yer almaktadır.[12] Son beş yılda makine öğrenimi çalışmaları artış göstererek literatürde belirgin bir etki ve öneme sahip olmuştur. Bu önemli alanlardan biri de karar verme sürecidir. Karar vermenin en önemli bileşenlerinden biri algoritma performansıdır. Bu nedenle, algoritmaların temel özellikleri karar verme kalitesini etkilemektedir. Karar verme kalitesini etkileyen çeşitli veriler ve algoritmalar üzerinde çalışılması gerekmektedir. Bu teori, benzersiz, taklit edilemeyen ve dönüştürülemeyen verilerin farklı yöntemlere uyarlanmasıyla başlangıç noktasıdır. Hangi algoritmanın hangi problemlere iyi gelebileceği ve farklı çalışma mantıklarına odaklanmamıza temel oluşturmaktadır. Sağlık 1.0 mikroorganizmaların ve hastalık yapan ajanların keşfedilmesiyle Sağlık 2.0, elektriğin icadı ve sanayinin gelişmesiyle; Sağlık 3.0, bilgisayarların hayatımıza girmesiyle başlayan bir dönem ifade ederken; Sağlık 4.0, varlıkların iletişim kurabildiği ve bu sayede özelleştirilmiş sağlık hizmetlerinin günümüz teknolojileriyle entegre edildiği bir aşamayı temsil etmektedir. Sağlık 4.0'ın amacı, sağlığın fiziksel, sosyal ve psikolojik olarak tam bir bütünlük içinde desteklenmesini sağlamak; hasta, hasta yakını ve sağlık çalışanları için sağlık hizmetinin gerçek zamanlı ve kişiye özgü olmasını, doğum öncesinden yaşam boyu, bütüncül bir yaklaşımla ele almaktır. Yenilikçi teknolojilerin gelişimi, yaşam bilimleri alanında bu ivmeyi hızlandırmış ve manuel süreçlerin otomasyona geçişini sağlamıştır. Kısacası, bu dijital dönüşüm sayesinde sağlık ve sağlığa bakış açımız yeni kavramlarla şekillenmeye başlamıştır. Sağlık 4.0, nesnelerin interneti, tıbbi siber fiziksel sistemler, sağlık bulutu, sağlık sisi, büyük veri analitiği, makine öğrenimi, blok zinciri ve akıllı algoritmalar gibi yenilikçi teknolojileri yaratıcı bir şekilde entegre ederek kullanabilmektedir. Bilgi sistemlerinde tanımlanan olağan ve kritik süreçlerin güvenli bir şekilde devam etmesi, önceliklerine göre değişen donanım ve hizmetlerin operasyonel, finansal ve güvenlik yönetimini gerektirmektedir. Sağlık bilgi sistemi, cihaz yönetimi ve bilgi altyapısı birçok bileşenden oluşmaktadır. Örneğin, IoT cihazları, insan etkileşimi ve bileşenlerinden başlayarak sağlık hizmetlerinde akıllı bir ortam oluşturmak için topladıkları verilerle internete bağlanmakta ve hızlı bir şekilde işlenemeyen büyük miktarda veri üretmektedir. Günümüzde akıllı, giyilebilir teknolojiler, dronlar ve tıbbi

cihazlardan toplanan büyük veriler, sis bilişimi, 5G, geniş bant, kablosuz ve blockchain teknolojileri sayesinde daha fazla güvenlik, hız ve hareketlilik kazanmaktadır. Büyük veri ve multimedya, yazılım kapsayıcıları, sanallaştırma, robotik, nanoteknoloji, yapay zekâ, makine öğrenimi ve veri madenciliği gibi trend olan teknolojiler sayesinde kendi kendini yönetmektedir. Sağlık 4.0 ile altyapının dijital ikizi oluşturularak yönetim açısından kalite, verimlilik, maliyet-fayda, güvenlik ve uygulanabilirlik testleri yapılmaktadır. Bu çalışmanın amacı, öngörülemeyen olaylar sırasında aşı stoklarını en iyi tahmin eden yöntemi araştırmaktır. Her yöntemin avantajları ve dezavantajları, geçmiş verilerin mevcudiyetine ve salgın hastalıklar, küreselleşen ekonomi ve hareketlilik gibi kuruma özgü diğer faktörlere bağlı olarak değişiklik göstermektedir. Örneğin, şiddetli bir hava olayı, hastaların gerekli ilaçlarını almaya çalıştıkları ve olay sonrası yol erişilebilirliği ile seyahat zorlukları nedeniyle olaydan sonra daha az talep oluşabilir. Bu nedenle tahmin edilen bu olaydan önce ek talep yaratabilmektedir.[13] Geleneksel yöntemlerin yetersiz kalabileceği durumlarda, makine öğrenimi, sektördeki değişen koşulları ve özellikle uyarı vermeden değiştiği durumları kesin bir şekilde öğrenerek dinamik kalıpları ortaya çıkarabilmektedir.[14] Bu nedenle, çalışmanın sonunda algoritmaların belirli koşullar altında ne ölçüde öğrenebildikleri karşılaştırılacaktır. Çalışmanın akışı, aşı talebi tahminini, veri anlama, veri hazırlama, analiz, doğrulama ve makine öğrenimi algoritmalarının karşılaştırılmasını içermektedir. Modellerin başarıları, RMSE ve MAE sonuçları ile kıyaslanmaktadır. Sistemdeki her bir varlığın ortaya çıktığı anda analizi yapıldıktan sonra, olgunluk modeli ve yöntem gereksinimlerine göre izleme ve analiz panoları sistematize edilir. Bu araştırmanın amacı Sağlık 4.0 ile ilgili teknolojilerin olgunluğunu ve aynı zamanda yapay zeka, makine öğrenimi benimseme stratejileri özetlemek, değerlendirmek ve aşılama altyapısı için bir çerçeve sunmaktadır. Benimseme modellerinin seviyesi arttıkça ufak kaynaklardan büyük sonuçlar çıkartan kurumlar gerçekte sürdürülebilir olgunluğa erişebilmektedir. Teknoloji bağlamında yeterince efektif-kolay-etkin çözümler üretilmelidir. Bu nedenle merkezi çözümler desteklenmeli ve çift yönlü kontrol edilmelidir. Teknoloji bağlamında operasyon ve strateji uyumuluğu oldukça önemlidir.



Şekil 1.1: Veri Madenciliği için Çapraz Endüstri Standart Süreci ile Çalışmanın Akışı.

Veri manipölasyonunda önce tüm veri seti üzerinde ham verilerle çalışılmaktadır. Ardından, veri frekansını etkileyen 2018 ve 2022 yılları çıkarılarak analiz edilmektedir. COVID-19 ve etkilerini gözlemek amacıyla 2020 ve 2021 yılları da veri setinden çıkarılmaktadır. Sonrasında, veri setinin mevsimselliği araştırılmakta ve arındırılmaktadır. Durağan hale getirilen veri seti, tekrar tüm modeller üzerinde test edilmektedir. SARIMA ve ARIMA modellerinin başarıları, güven aralıkları ve aşırı öğrenme problemi ele alınarak değerlendirilmektedir. Ham ve işlenmiş veri seti üzerindeki SARIMA ve ARIMA model başarıları karşılaştırılmaktadır. SARIMA, en iyi uyum sağlayan model olarak tespit edilmekte ve bu nedenle 5 katlı çapraz doğrulama uygulanmaktadır. Son olarak, belirli güvenilirlik aralıkları içinde en başarılı tahmin algoritmalarının Ortalama Mutlak Hata değerleri ve tüm merkezlerdeki aşı maliyetleri temel alınarak risk değeri hesaplanmaktadır. Risk Öncelik Katsayısı, bu kuruma özel veri seti ile kurumdan temin edilen risk düzeyinden elde edilmektedir. Value at Risk modeli, modellerden elde edilen MAE sonuçları, RPN ve güven aralıkları üzerinden stok aralıklarını göstermektedir. Model tahmin başarılarına göre stok aralıklarının değişimi grafikler üzerinden sunulmaktadır. Kurumların stratejilerine göre stok fazlası veya stok eksikliği, ayrıca bu durumun kurumun RPN değerine göre direnç düzeyi, stok nedeniyle gelecek günlerde elde tutulan maliyetin kayıp maliyetleri, belirlenen güven aralıklarında hesaplanarak olasılıksal gösterimi yapılmaktadır. Kullanılması planlanan modeller denetimli öğrenme modelleridir. Denetimli öğrenmede, makineye bir cevap anahtarı sağlanır ve doğru sonuçlar arasındaki korelasyonları bulunarak öğrenme gerçekleştirilir. Bu öğrenme modeli ise bir cevap anahtarı içermez; bunun yerine, izin verilen eylemler, kurallar ve potansiyel bitiş durumları kümesi kullanılır. Algoritmanın hedefi sabit veya ikili olduğunda, makineler örnek olarak öğrenebilir. Ancak, istenen sonucun değişken olduğu durumlarda sistem, deneyim ve ödül yoluyla öğrenmektedir. Zaman serileri sayesinde hata düzeltme, eksik veri tamamlama, tahmin ve aykırı veri kaldırma işlemleri de yapılabilmektedir. Proaktif şekilde sağlığın yönetilmesi ve sağlık verisinin işlenmesi maliyet gerektirdiğinden, yapay zeka üzerinden sağlık veri analizlerinde ölçme ve değerlendirme yapmak, objektif yatırım kararları alınmasını içeren çalışmaları ve otomatize dinamik sistemler geliştirilmeye devam etmekle mümkündür.

2. MALZEME VE YÖNTEMLER

Bu çalışmanın akışı, aşı talep tahmini, veri anlama, veri hazırlama, analiz, doğrulama ve makine öğrenimi algoritmalarının karşılaştırılmasını içermektedir.[15] Analistlere doğal örüntülerin tanınmasında yardımcı olmak hedeflenmektedir. Bu çalışmada veri madenciliği için Endüstriler Arası Standart Süreç (CRISP-DM) kullanılmaktadır. Esnek süreçlerin altı başlık altında incelendiği bu metodolojide, öncelikle yapılan işin anlaşılması esastır. Ardından, veriyi anlayabilmek için verinin toplanması, tanımlanması ve bu aşamalardan yola çıkarak verinin kalitesinin belirlenmesi ve temizlenmesi süreci yer almaktadır. Eldeki veriler, çeşitli araçlarla hata, eksiklik, tutarsızlık, sistemsel hatalar ve akış uyumu gibi kalite boyutları açısından analiz edilmektedir. Verilerin tasarlanan çalışma için yeterli olup olmadığı ve ek veri seti ya da kaynağa ihtiyaç olup olmadığına dair durumlar saptanmaktadır. Bu sayede, hangi modellerin modelleme için kullanılacağı ve modelin çalışma prensiplerine uyup uymadığı tespit edilmektedir. Nihayetinde, veriye ve çalışmanın amacına bağlı olarak en uygun modelin oluşturulması hedeflenmektedir. İlgili çalışmaya uygun olan modelleme tekniği ve kullanılacak nitel ve hibrit yöntemler belirlenmektedir. Değerlendirme, sonuçların daha önce belirlenen projenin amaçlarına uygun olup olmadığı ve test değerleri göz önünde bulundurularak yapılmaktadır.[16] Değerlendirme sonrasında, elde edilen sonuçlara dayanarak yapılması gerekenler planlanmaktadır. Bu aşamada, günlük yaşamda kullanımına odaklanılmaktadır. Bu çalışma, özetle şu aşamalardan oluşmaktadır: aşı içgörüsü, veri anlama, veri hazırlama, modelleme, değerlendirme ve dağıtım. Veri hazırlama aşamasında, belirli bir dönemin kalıplarını, döngülerini ve mevsimselliğini belirlemek için bir zaman serisi oluşturulmaktadır. Aşı kullanımı, makine öğrenimi ile tahmin edilmektedir. Örnekler arasında zaman serileri [17], ARIMA [18], ensemble boosting [19] ve regresyon [20] modellerinin kullanımı yer almaktadır. Bu nedenle, çalışmamızda aşı talebini tahmin etmek için ARIMA, XGBoost, SARIMA ve Doğrusal Regresyon tercih edilmektedir. [21] Modeller ham ve işlenmiş veriler üzerinde çalıştırılmaktadır. Model başarıları RMSE ve MAE ile karşılaştırılmaktadır. Model başarı ve tahmin hataları sarıhumma stok düzeylerinin belirlemek amacıyla kullanılmaktadır. Veri madenciliği için Çapraz Endüstri Standart Süreci, altı aşamadan oluşmaktadır: iş anlayışı, veri anlayışı, veri hazırlığı, modelleme, değerlendirme ve yayma. Veri hazırlığı

aşamasında, belirli bir süre boyunca kalıplar, döngüler ve mevsimselliği tanımlamak için bir zaman serisi oluşturulmaktadır. Bu analiz, aşı tüketimindeki durağanlık, trend, mevsimsellik ve döngüsellik incelemektedir. ARIMA, SARIMA [22], XGBoost [23] ve Lineer Regresyon modelleri karşılaştırılmaktadır.[24]. Dijital mükemmellik kavramı, paydaşları motive etmeye yardımcı olabilecek temel bir amaç sunar ve nüfus sağlığını iyileştirmek, maliyetleri kontrol altına almak, hasta deneyimini geliştirmektir. Sağlık hizmeti sağlayıcılarının iş ortamını iyileştirmek için dört ana hedefe yönelik faaliyetleri koordine eder.[25] Sağlığın korunması, hastalığın önlenmesi ve yönetilmesi, sağlık işletmelerinin maliyetlerini düşürmek, kaynakları verimli kullanmak ve kaliteli sağlık hizmeti sunmak, sağlığın yaşam bilimleri bağlamında destekleyici bir rol oynamasıyla doğrudan ilişkilidir. Bu durum, günümüzde teknolojinin ne ölçüde kullanıldığı ile yakından bağlantılıdır.[26] Sağlık 4.0 bağlamında teletıp (mobil bilgi işlem), tıbbi verilerin telefon, internet veya diğer ağlar aracılığıyla iletildiği klinik uygulamalardır. Sağlık verilerinin işlendiği kurumlar büyük ölçüde hastanelerdir. Hastane yönetim sistemi, çeşitli elektronik platformlarla etkileşim halinde olan birincil veri deposudur. Elektronik Sağlık Kayıtları (EHR) işlevleri, bir sağlık otoritesinin sağlık hizmeti kalitesini iyileştirmeye yönelik hedefler belirlemesi için iyi bir başlangıç noktası olabilir. Tüm bu sistemler, tıp dili standartlarına göre değiştirilebilir ve bazı gruplar 30-50 bileşen içerebilmektedir. Bu gruplar, kullanıcının elektronik sağlık kaydını tutmalı, güvenli olmalıdır. Sağlık Sigortası Taşınabilirlik ve Sorumluluk Yasası'nın (HIPAA) gereksinimlerini karşılayarak gizliliği sağlamaya çalışmalıdır.[27] Ayrıca, çeşitli olgunluk modeli çerçevelerine göre sınıflandırılmaktadır.[28] Sağlık 4.0, güvenlik, hacim, kütle, bütünlük ve hız parametreleri ilgili boyutlara göre kategorize edilen veri havuzlarında bulut bilişim ile titizlikle ele alınmaktadır. Sağlıkta dijital olgunluğun genel değerlendirmesi, kaynaklar ve dijital yetenek düzeyi, etki ve iş birliği ile ilişkilidir. Söz konusu ölçümler, çeşitli metrikler, akışlar ve sistemler üzerinden değerlendirilmektedir. 1996 tarihli Sağlık Sigortası Taşınabilirlik ve Hesap Verebilirlik Yasası, 2004 ve ardından gelen 2006 yürütme kararları ile, standartlaştırılmış *elektronik veri alışverişi* bilgi sistemlerinin tasarımını ve kullanımını mümkün olan en kısa sürede zorunlu hale getirmektedir. EMRAM: Yatışlı tedavi kurumlarında elektronik sağlık kaydının benimsenme düzeyini ölçen anket modeli, O-EMRAM: Ayakta tedavi merkezlerinde elektronik sağlık kaydının benimsenme düzeyini ölçen anket modeli, CCMM:

Hastanın farklı yerlerde (ev, hastane, ambulans, vb.) aldığı sağlık hizmetinin sürekliliğinde bilgi ve teknolojinin kullanım düzeyini ölçen model, AMAM: Kişiselleştirilmiş tıp yaklaşımlarının kullanım düzeyini ve hastanenin analitik kapasitesini ölçen anket modeli, Value of Score: Finansal, operasyonel ve klinik karar destek sistemlerinin kullanım düzeyini ve etkinliğini ölçen anket modeli, DIAM: Tüm tıbbi görüntülerin elektronik sağlık kaydı ile etkin kullanım düzeyini ölçen anket modeli ve INFRAM: Bilişim altyapısı düzeyini seviyeleme gibi birçok olgunluk modeli, kurumsal bilgi teknolojilerinin resmini çeker, mevcut durumlarını analiz eder ve proaktif yönetimin temelini oluşturur. BT çözümleri ve politikaları değiştikçe, farklı ayarların zaman içinde dijital durumları sürekli olarak yeniden değerlendirilmesi gerekmektedir.[29] Örneğin, bilgi teknolojileri ve güvenlik ile ilgili modeller, COBIT, ITIL, ISO 27000 ve diğer seriler gibi kurumsal bilgi teknolojilerinin genel görünümünü sunmakta, mevcut durumlarını analiz etmekte ve proaktif yönetimin temelini oluşturmaktadır. Olgunluk düzeyindeki segmentlerin kesişim kümesi, verilerin panolar aracılığıyla izlenmesini sağlayarak bilgiye erişimi kolaylaştırmakta, zaman ve kaynak tasarrufu sağlamaktadır. Ayrıca, otomatik ve finansal risk yönetimine olanak tanımakta ve varlık performans yönetim sistemine dinamizm katmaktadır.[30] Bu durumda, işletme değeri olmayan kullanım ve âtıl kapasiteleri belirlerken, finansal risk analizi çalışmaları için bir kontrol mekanizması sağlanmaktadır. Sürekli güncellenen modeller ve teknoloji sayesinde, yerel kurumların önceliklerini belirlemeleri ve bunları yerel olarak tanımlanmış veya istenen sonuçlara göre, merkezlerden periyodik olarak yeniden değerlendirmeleri için dinamik ve otomatik bir yol içermektedirler. Altyapı yönetimi ve bütünsel entegrasyonlar, azaltılmış bakım maliyetleri, daha yüksek hizmet kalitesi, sistem verimliliği ve geliştirilmiş güvenilirlik gibi birçok rekabet avantajı sağlamaktadır. Bununla birlikte, gerçek zamanlı sağlık uygulamaları düşünüldüğünde, yapay zekâ tabanlı bir bakım ve yönetim stratejisi uygulamak, beraberinde yatırım maliyetleri, fiziksel varlıkların bağlanabilirliği, veri depolama, değerli bilgileri çıkarma ve hassas yapay zekâ, makine öğrenimi algoritmaları geliştirme gibi birçok zorluk ve riski beraberinde getirmektedir. Bu kısıtlamaların üstesinden gelmek için birtakım öncülleri belirlemek önemlidir. Bakım ve yönetim stratejisinin uygulanabilirlik kapsamı teknik, organizasyonel ve ekonomik açıdan iyi planlanmalıdır. Sağlıkta uygulanan yeni teknolojiler ve

trendler gündeme riskleri ile gelmektedir. Örneğin, sis bulutu fikri, Camerino Üniversitesi'nde verileri tek bir sunucu yerine birden çok sunucuya yaymak için öne çıkmaktadır. Dinamik yer değiştirme veya yapay stoklama gibi teknikler sürekli zamanlı kullanılmaktadır. Bu nedenle veriler, mobil formda parçalar halinde kalıcı olarak depolanmaktadır. R. Culmone ve M. Concetta, sis hesaplama kavramını yeniden şekillendirmektedir. Konseptin ana amacı, iyi bir bilgi işlem performansı elde etmek ve sistem maliyetini azaltmaktır.[31] Ancak milyonlarca cihazın devasa akışıyla güvenlik ve gizlilik temel gereksinimler haline gelmektedir. Güvenlik önlemlerinin varlığı ile hesap verebilirlik ve mahremiyet, paydaşlar arasında güven oluşturması amaçlanmaktadır. Kullanılabilirlik, güvenlik, hesap verebilirlik, tüm veri kayıtlarının ve hizmetlerin gizliliği, tüm süreçler ve alınan optimal önlemlere bağlı olarak bu istatistikler paydaşlarla paylaşılmaktadır.[32] Güvenlik ve gizlilik önlemlerindeki herhangi bir gecikme, kullanıcının güvenini sarsabilmektedir. Bu amaçla simülasyon araç takımlarıyla, sis bulutu modellerindeki gecikme, bant genişliği kullanımı, güç tüketimi, yürütme süresi, güvenilirlik ve doğruluk açısından değerlendirmektedir.


2.1 SAĞLIK 4.0 TEKNOLOJİLERİ

Sağlık literatüründe önerilen çalışma mimarilerinin amacı, gerçek zamanlı işleme taleplerinde nasıl performans gösterdiklerini belirlemektir. Teknolojinin gelişmesiyle birlikte, piyasada kullanılan Health 4.0 ürünlerinin çeşitliliği her geçen gün artmaktadır. Bu sistemlerde bulunan cihazlar, sağlık veya altyapı ile ilgili yüksek hacimli veriler üretmektedir. Bu nedenle, sis bilişimi, ağ altyapısının bir parçası olarak bilgi işlem ekleme esnekliği ile sağlık hizmetlerinin ihtiyaçlarını karşılamak için uygun bir kavram gibi görünmektedir.[33] Sis bilgi işlem görevleri, gizliliği korumaya veya ağ üzerindeki yükü azaltmaya yardımcı olmak amacıyla verileri filtrelemektedir. Sis merkezli IoT, ağ cihazlarının veri toplamasına, iletişim kurmasına ve alışverişte bulunmasına olanak tanıyan nesnelerin, hizmetlerin, yerlerin ve ağların yaygın varlığını yansıtan yeni bir değerler dizisi olarak hızla itibar kazanmaktadır. IoT tabanlı uzaktan sağlık izleme sistemlerinin konsept uygulamasına dair kanıtlar her geçen gün artmaktadır. Makine öğrenimi, 5G tabanlı gerçek zamanlı ve uzaktan izleme ile desteklenen IoT tabanlı sağlık platformu [34], yaşam kalitesini iyileştirmeye, hasta merkezli sağlık hizmetlerine ve hastalıkların erken teşhisine odaklanan IoT'nin en önemli parçası haline gel-

mektedir.[35] Kronik hastalıklar, tıbbi acil durumlar ve tedavide kaybedilen zamanın azaltılması, çekici uygulama alanlarından biridir. Sis bilişim, bulut ve IoT uç cihazları arasında orta bir katmanda gerçekleşen bilişimi tanımlamak için Cisco tarafından geliştirilmiş bir terimdir. Sis veya bulanık bilişim, bağlı akıllı cihazlardaki hesaplama açısından yoğun hizmetler sunan bir teknolojidir.[36] Mevcut çalışmaların çoğu, kuyruklama ve iş yükü işleme gecikmelerini analiz etmeye ve optimize etmeye odaklanmakta; ancak araçlar ile bulanık/bulut sunucuları arasındaki erişim gecikmesinin bazen toplam gecikmeyi belirleyici bir şekilde etkileyebileceği göz ardı edilmektedir. Sis bilişim modeli, bulutu genişleterek ağınızın uç ağınızdaki yer birimlere bir yapı sunmaktadır. [37] Daha ve gerçek zamanlı olmayan uygulamalar için bulut bilişimi altyapısı sunan yatırımcı kamu kurumları, kendilerinde bağlı lokasyonlardaki alt genel müdürlük ya da birimlere veya edilmekte, hizmet vermekte ve sistem dengesini sağlamaktadır. Sağlık verileri için güvenlik çok önemlidir blockchain büyük gelecek vaat eden potansiyele sahip olarak ortaya çıkmıştır.[38] Blok zinciri teknolojisi, bir işletme ağında şeffaf bilgi paylaşımını sağlayan gelişmiş bir veritabanı mekanizmasıdır.[39] Blok zinciri veritabanı, birbirine bağlı bloklar halinde bir zincir üzerinde verileri depolar. Blok zinciri, güvenli bir şekilde paylaşılan merkezi olmayan bir veri kayıt defteri olarak tanımlanmaktadır. Bu teknoloji, ortak bir grup katılımcının veri paylaşımını mümkün kılmaktadır. Blok zinciri bulut hizmetleri sayesinde, birden fazla kaynaktan gelen işlem verileri kolayca toplanabilir, entegre edilebilir ve paylaşılabilir hale gelir.[40] Veriler, kriptografik hash'ler biçimindeki benzersiz tanımlayıcılarla zincirlenen paylaşılan bloklara bölünmektedir. Blok zinciri, tek bir doğruluk kaynağı aracılığıyla veri bütünlüğü sağlayarak veri çoğaltımını ortadan kaldırmakta ve güvenliği artırmaktadır. Veriler, tüm tarafların mutabakatı olmaksızın değiştirilemeyeceği için bir blok zinciri sisteminde sahtecilik ve verilere müdahale engellenmektedir.[41] Bir blok zinciri kayıt defteri paylaşılabılır, ancak değiştirilemez. Biri verileri değiştirmeye çalışırsa, tüm katılımcılar uyarılır ve kimin girişimde bulunduğu tespit edilip bildirilir.[42] Diğer yandan, telekomünikasyon için yüksek bant genişliği sağlayabilen yüksek kapasiteli sistemlere (ulaşım ve ağ erişimi) atıfta bulunmak için kullanılan terim "geniş bant"tır. Sabit geniş bant, fiber ve kablo sistemlerini ve ağlarını kapsamaktadır. Geniş bant terimi, bir telekomünikasyon cihazının veya sinyalinin, başka bir standart veya olağan bir sinyal ya da cihazdan daha geniş bir bant genişliğine (trafik için daha büyük bir kapasiteye) sahip olduğunu ifade eder. Geniş bant standardı için farklı bağlamlarda ve zaman dilimlerinde çeşitli kriterler uygulanmaktadır.[43]

Kablosuz geniş bant, Wi-Fi, WiMAX, LTE, 5G ve 6G gibi hücresel geniş bant teknolojilerini içermektedir. Wi-Fi, kablosuz bağlantı noktaları oluşturan radyo dalgaları üreten sistemlerdir. Çeşitli standartlara göre üretilen bu dalgalar, farklı alıcılar tarafından algılanarak sisteme entegre edilmektedir. Pek çok sağlık verisi toplayan cihaz, Wi-Fi alıcısına sahiptir. Bu alıcılar sayesinde dalgaları yakalayarak ağa bağlanabilmektedir. Wi-Fi alıcısı bulunmayan bilgisayarlarda ise kablosuz adaptör kullanarak ağa bağlanmak mümkündür. Kablosuz sistem içerisinde kullanılan bazı ürünler şunlardır. ADSL modem, kablosuz ağ adaptörü, erişim noktası (access point) ve kablosuz köprü (wireless bridge) olarak sayılır.[38] WIMAX, Dünya Çapında Mikrodalga Erişimi için Uyumluluk anlamına gelir. IEEE 802.16 erişim standartlarını kullanan aygıtlar için bir sertifika işaretidir.[44] 802.16, 802 ailelerinin 16. dalıdır ve yüksek hızlı kablosuz erişim sağlamak üzere tasarlanmıştır.[45] LTE, uzun vadeli evrim anlamına gelmektedir. LTE adı ile adı ile dayalı da dayalı aktarım standardıdır. Daha dayanan Advanced ve LTE Advanced Pro türleri dayanan G, 5. Nesil Mobil Telekomünikasyon türleri geliştirilmektedir. G, 5. Nesil Mobil Telekomünikasyon Hizmeti, 5G, beşinci katı veri teknolojisini temsil eder. Dördüncü nesil teknolojinin bir evrimi olarak bilinir ve bu katmana ait hizmetler sunulmaktadır. Bu hızlar, kullanılan cihazın kategorisine göre 1 ile 10 Gbps arasında değişiklik gösterebilmektedir.[46] Hareketlilik yanı sıra güvenlik bağlamında da umut vaat verici çalışmalar yürütülmektedir.[47] 5G'nin gecikme süresi azlığı, sunduğu hızlar ve tüm kullanıcılar için bant genişliği kullanılabilirliğini garanti etmektedir. Yüksek sayıda hasta ve işlemin sürekli izlenmesi için 5G ağının kullanılması gerektiği vurgulanmaktadır.[48] Bulut tabanlı yazılım aracı, gerçek zamanlı verileri toplamak ve 5G ağını kullanarak bulutla paylaşmak amacıyla IoT tabanlı ön-arka kameralarla donatılmaktadır.[49] 5G tabanlı kablosuz sensör ağlarındaki çok sunuculu e-sağlık sistemleri için, zamana bağlıdır. Kullanıcı anonimliği sağlayan hızlı bir üç faktörlü kimlik doğrulama şeması önerilmektedir.[50] Kronik hastaların sürekli izlenmesi, yaşam kalitelerini artırmakta ve sağlık sisteminin ekonomik maliyetlerini azaltmaktadır. Ancak, etkili bir izleme sağlamak için yüksek bant genişliği ve düşük gecikme gereklidir. 5G teknolojisi, önceki teknolojilere göre daha yüksek bant genişliği, daha düşük gecikmeler ve daha az paket kaybı sunmaktadır. Nanoteknoloji, çeşitli uygulamalarda nano cihazların manipülasyonu, üretimi, malzemeleri, modları ve kullanımlarını içermektedir.

Health 4.0 Inverstor Public Organization Digital Management Framework



Şekil 2.1: Sağlık 4.0 Bütüncül Kavramsal Yaklaşım.


Dijital ikiz teknolojisi, herhangi bir nesne, cihaz veya hizmetin fiziksel olarak gerçekleştirilmeden önce dijital ortamda bire bir kopyasını oluşturmaktadır. Dijital ikiz, girdi olarak gerçek hayattaki bir nesne veya sistemle ilgili gerçek verileri kullanmaktadır. Bu girdilere dayanarak, ilgili olgunun davranış modeli çıkarılmakta ve tahminler üretilmektedir.[52] Yazılım kapsayıcıları, bir uygulamayı çalıştırmak için gerekli tüm bileşenleri paketleyen standartlaştırılmış IDE'ler ve yalıtılmış yazılım birimleridir. Yazılım kapsayıcıları, 2013 yılında PaaS altında geliştirilmeye başlanan ancak etkinliği nedeniyle yeniden adlandırılan konteyner teknolojileridir ve birçok ticari isim altında yaygın olarak kullanılmaktadır.[53] Sağlıkta teknoloji gelişimi endüstri 4.0 RAMI ve olgunluk modelleri ile işlenmeye devam etmektedir. Toplam kalite yönetimi, IEC, HIPAA, ISO başta olmak üzere sağlık sektörüne özel olgunluk modelleri INFRAM, EMRAM ve benzeri modeller öne çıkmaktadır. Hiyerarşik seviye belirleyen IEC62264//IEC61512, makine düzeyinden dünyaya bağlantısına kadar olan aşamaları standardize etmektedir. Uluslararası ulusal kamu, özel sektör ve partner ilişkileri ortak paydalar, her geçen gün birlikte çalışabilirlik, uyum için kontrol mekanizmaları arttırılmaktadır. Hibrit yaklaşımlar, birliktelik teknikleri, göstergeler, sis bulutu ile gerçek zamanlı işlemlerin modellemeler hızla gelişmektedir. Uzaktan güvenli çalışma stratejileri, akıllı orkestratörler, elektronik entegrasyonlar, iş yönetiminin modülleri ve mobilitesini arttırarak bir adım öteye, kendi kendini yöneten iş sistemlerine dönüştürülmektedir. Bu gelişmelerde bilginin işlenmesinde güvenlik ve güvenilirlik sistemlerinin rolü ve etkinliği elzemdir. Doğruluk, etkinlik, ulaşılabilirlik, önleme, karmaşıklık ve karmaşıklıkları işleme maliyetleri akıllı dijital dönüşümlerin uygulanabilirliği gibi araştırmalar ivme kaydetmektedir. Kalite sistemleri, stratejik yönetim faaliyetleri, devletlerarası iş birlikleri, dinamik, çevik iletim ve izolasyon gibi ilişkisel garanti ve sigortalar, entegre aynı dil ve kavramlara dönüşerek dünyayı anlama ve algılama uzayını genişletmektedir. Diğer yandan ulusal ve uluslararası kanunlar, yönetmelikler, işin tanımlayıcı istatistikleri, ortak ve yalıtılmış akışların gözden geçirilmesi kısaca ham süreçlerin anlamlı ve akıllı bilgiye dönüştürülmesi birlikte çalışabilirliği arttırmaktadır. Bu gelişmelerin özellikle donanımsal ve yazılımsal teknolojilerin gelişimi ile paralelliği yadsınamaz. Her geçen gün açık bilim ve paylaşım artmaktadır. Uygulama mimarileri, gömülü sistemler, bulut bilişimi, yazılım konteynırlar, arttırılmış kuantum bilgisayarlar, ses ve video teknolojileri, yüksek sıkıştırma veya veri taşıma teknolojileri, artırılmış gerçeklik, giyilebilir teknolojiler, uydu ve uzay araştırmalarının sektöre katkıları, dron teknolojileri, robotik, nano teknolojiler, görüntü işleme, izolasyon teknolojileri, kriptolama,

blockchain, genetik araştırma teknolojileri, veri madenciliği, arşivleme teknolojileri, 3D yazıcı ve 3D teknolojileri, siber güvenlik ve nihayet yapay zekanın kattığı yeniliklerle birlikte bu ivme hızlanmaktadır. Çalışmaların ana stratejilere bağlanarak, sektörel bütüncül yaklaşımlarla diğer sektörler arası adaptasyonu, sistem tasarım ve kurallarının planlanması uygulama öncesi kurgusunu şekillendirilmektedir. Örneğin bir banka şubesinin taşıdığı riskin gereği güvenlik personeli çoğalmak fayda maliyet analizlerinde gider artırıcı unsur olabilmekte ve saldırı düzeyine göre etkinliğini yitirebilmektedir. Onun yerine merkezi güvenlik düzeyi artırımı ve bağlı birimlerin akılcı sigorta yaklaşımları gibi risklerini bertaraf edilmesi, bütüncül servis ve hizmetler sunulması gerek yönetim gerekse kontroller açısından maksimum fayda sağlayabilmektedir. Diğer taraftan serbestisi olan, özerk alanların olması da gerekebilmektedir. Özellikle hız ve etkinlik bağlamında idarenin takdirine bırakılması gereken alanların tasarlanması, iş süreçlerinin endüstriyel adımlarla ele alınması ve risk planlarının bu yönde geliştirilmesi, teknoloji yatırımlarının planlanması ve iş gerçekleştirimi ön koşullardan biri haline gelmektedir.

2.2 SAĞLIK ALANINDA MAKİNE ÖĞRENİMİ ÇALIŞMA ÖRNEKLERİ

Günümüzde yapay zeka, makine öğrenmesi ve veri madenciliği teknik ve yöntemlerinin gelişmesiyle birlikte birçok fizyolojik veri otomatik olarak işlenmektedir. Sis hesaplama ve derin öğrenme teknikleri sayesinde, felç tahmini, felç analizi, EKG izleme, yüz tanıma, serebral palsy veya kalp krizi tahminçisi gibi hastasına yönelik yaklaşmakta olan tehdit hakkında hasta ve doktoru bilgilendirebilmektedir. Dolaşım sistemindeki kalp hakkında toplanan fizyolojik veriler, kolesterol, trigliserit, yaşam tarzı (aktif, sakin veya stresli), alışkanlık (sigara içme) vb. veriler sis hesaplama yoluyla toplanmaktadır. Literatür çalışmalarından örnekler incelendiğinde, trend teknolojilerin oldukça yaygın kullanıldıkları görülmektedir. Örneğin toplanan bu veriler, Kural tabanlı CART (Classification and Regression Tree) sınıflandırıcıları ile sınıflandırılmakta, ardından bireyin kalp krizi geçirdiği yaşı AdaBoost yöntemi ile tahmin edilmekte ve son olarak kalp krizi geçirme hızı belirlenmeye çalışılmaktadır.[54] Beden Kitle İndeksi verileri kullanılarak çocukların gelecekteki obezite durumlarının belirlendiği çalışmada, oylama (voting), ikame yoluyla örnekleme (torbalama), sıralı topluluklarla öğrenme (boosting), rastgele altuzaylar gibi veri madenciliği yöntemleri uygulanmaktadır.[55] Fizyolojik ve insan anatomisine ilişkin gözlemler yoluyla elde edilen veriler, kişisel, sosyal, ekonomik, zihinsel sağlık, fiziksel sağlık, yaşam kalitesi ve

yaşadıkları bölge ana başlıkları altında sınıflandırılmakta, veri madenciliği yöntemleriyle insanın yaşlanması incelenmektedir. Ana veri analizi tekniğinde genel doğrusal model, regresyon (çok değişkenli, çok etiketli, çok düzeyli, lojistik, doğrusal), destek vektör makinesi, yapısal eşitlik modellemesi ve cox orantılı yöntemlerle, ilgili tehlikelerin hesaplanılmasında kullanılmaktadır.[56] Giyilebilir teknoloji aracılığıyla fizyolojik kardiyovasküler ve elektrokardiyal aktivitelerin toplandığı bir çalışmada, veri madenciliği yöntemleri kullanılarak insan-bilgisayar uyumluluğunun daha önce tanımlanmış davranışsal-fizyolojik tepki kalıplarından birine yol açıp açmadığı araştırılabilmektedir.[57] Diyabeti ve kontrolünü etkileyen önemli faktörleri belirlemek için fizyolojik veriler toplanmaktadır. Çalışmada hemoglobin (HbA1c), hastalık öyküsü ve yılı, glikoz, trigliserit, kolesterol, kan basıncı, vücut kitle indeksi verileri toplanmakta, denetimli model yapısıyla uygun özellikler seçilmiş ve naif byes, IB1 ve C4.5 gibi algoritmalar kullanılmaktadır. Hastanın durumunun ne kadar iyi kontrol edildiğini belirlemek için kullanılmaktadır.[58] Güçlü algoritmalarla veri analizi, altyapıya bağlı olduğundan dinamik sağlık yönetiminde hayati önem taşıyan optimal finansal yatırım kararlarını gerektirmektedir. Bu nedenle dijital seviyenin ve hedeflere yönelik haritanın optimum yol haritası ve alternatifleriyle birlikte proaktif olarak değerlendirilmesi uygun olmaktadır. Gerçek zamanlı sağlık takibi özellikle 5G teknolojisi ve akıllı telefonlarla artmaktadır.[59] Sağlık bilişim altyapısında, donanım varlık risk çalışmalarının subjektif yöntemler içermesi ve risk kriterlerinin sıralanamaması, risk analizi çalışmalarında üst yönetim desteğinin alınamaması, yetersiz teknoloji ve hatalı iş-etki analizleri literatürde eleştirilmektedir. Bu araştırma ile mevcut kenar varlıkların yaşam döngüleri ve riske maruz değer olasılıklarının maliyetleri otomatize hesaplanacak ve toplayıcı sisteme iletilecektir. Bu sayede maliyet kayıpları üst yönetim takdirine sunulabilecektir. Bu nedenle tıbbi veri havuzlarının hacim, kütle ve güvenlik açısından bulut bilişim üzerinden hareketi ve gelişimi için öncelikle altyapı analizinin yapılması gerekmektedir. Hastaneler teknoloji anlamında çeşitli bir ekosisteme sahiptir. Olgunluk seviye ve hizmet gruplarına göre bilişim uygulamaları değişmekte olup sağlığın digitalleşmesi, pandemi ve salgın hastalıklar nedeni ile altyapı önemli hale gelmiştir.



Şekil 2.2: Sağlık 4.0 İlişkisel Teknoloji Yönetimi.

Görüntü işleme ve taşıma teknolojileri ve 5G bir araya geldiğinde mekan ve yerden bağımsız başarılı gelişmeler bulunmaktadır.[60] Makine öğrenimi algoritmalarının sınıflandırma yetenekleri diabet hastaları için umut vaad etmektedir.[61] Acil sağlık hizmetlerinde digital ikizlerin kullanımı artmaktadır.[52] Aynı zamanda sağlık hizmet üretinde anahtar performans göstergeleri ve anketler düzenlemek teknoloji sayesinde oldukça kolaylaştırılmaktadır.[62] Sağlık kurumlarında bu amaçla güçlü karar destek sistemleri geliştirilmektedir.[63] Günümüzde, tedarik zincirlerindeki artan zorluklar sağlık kuruluşları üzerinde baskı oluşturmaktadır. Hasta sağlığıyla ilgilenmek, doğru, yeterli ve zamanında tıbbi malzeme gerektirdiğinden, sağlık hizmeti tedarik zincirinin yönetimi diğer sektörlerle göre daha karmaşıktır. Yapay Zeka ve Makine Öğrenimi gibi yeni teknolojiler, birçok sektörü etkilemiştir. Lojistik ve tedarik zinciri endüstrisi, yapay zeka teknolojisindeki gelişmelerden önemli ölçüde etkilenmektedir. Bu güçlü teknoloji, sayısız sürecin otomatikleştirilmesini ve basitleştirilmesini sağlar, böylece şirketlerin zaman ve maliyet tasarrufu yapmalarına yardımcı olur. Karmaşık sorunları, özellikle sağlık tedarik zinciri ile ilgili sorunları çözmek için bilgisayar tekniklerini kullanan makine öğrenimi ve yapay zeka yaklaşımlarının birçok uygulaması bulunmaktadır. İlişkisel Sağlık teknolojisi yönetimi; sağlığın geliştirilmesi, koruma, tedavi, rehabilitasyon ve elektronik sağlık altında beş adet döngüden oluşmaktadır. Bu döngülerin içerisinde izole yada etkilileşimli paralel yürüyen hizmetler bulunmaktadır. Ayrıca sağlığın hizmet sunum bileşenlerinde çeşitli teknolojiler kullanılmaktadır.

2.3 AŞILAMA LİTERATÜR ARAŞTIRMASI

Aşağıda literatürden örnekler ve sonuçlar bulunmaktadır. Atıfta bulunulan makaleler ayrıca referanslar bölümünde sunulmuştur. V.V. Kendre ve arkadaşları, Hükümet Tıp Okulu'nda BCG ve OPV aşılara olan talebi tahmin etmek amacıyla zaman serisi uzman modellerini kullanmaktadır. Zaman serisi analizi ve tahmini, özellikle BCG için Winter'ın eklemeli modeli ve OPV için basit mevsimsel model olmak üzere en iyi uyumlu modellerle gerçekleştirilmektedir. Sonuç olarak, Üssel Düzleştirme en doğru tahmini vererek Ortalama Mutlak Yüzde Hata (MAPE) değeri 17.787 el-de etmiştir. R. Chiu, belirli bir aşı için talebi tahmin etmek amacıyla Sinir Ağları ile Entegre Hareketli Ortalama ve Oto-Regresyonu birleştiren hibrit bir teknik kullanmıştır. ARIMA modeli, aşı tahmininde %5.46'lık Ortalama Hata Oranı elde etmiştir. J.S. Sahisnu ve meslektaşları, Endonezya'da 0-11 aylık çocuklar için aşı stok eksiklikleri veya fazlalıkları ile başa çıkmak amacıyla ARIMA modelini uygulamış

ve 257.59'luk Kök Ortalama Kare Hatası ile 422.9008'lik Ortalama Mutlak Hata elde etmiştir. R. Bendi ve arkadaşları da Hindistan'da kuduz aşısı talebini tahmin etmek için ARIMA modelini kullanmış ve mevsimselliği hesaba katmak için Holt-Winter modelini eklemiştir. Ancak, ARIMA modeli daha doğru tahminler üreterek 257.59'luk RMSE ve 195.6627'lik MAE elde etmiştir. Bu çalışmalar, çeşitli aşı türlerine dair talep ve kullanım tahminleri sunmaktadır. Farklı aşı türlerinin aynı modeller kullanılarak tahmin edilebileceği görülmektedir.

Tablo 2.1: Literatürdeki Aşı Tahmin Çalışmaları.

No	Study	Metod	Value of Forecast
1	V.V Kendre	Exponential Smoothing	MAPE: 17.787
2	R. Chiu	ARIMA	Avarage Error Rate: 5.46%
3	J. S Sahisnu	ARIMA	RMSE/MAE:544.7732/422.9008
4	R. Bendi	ARIMA	RMSE/MAE:257.5948/195.6627
5	R. Bendi	Exponential Smoothing	RMSE/MAE:352.2573/269.8702

Tablo 2.1, çeşitli aşılar üzerinde ARIMA ve zaman serisi analizi kullanan son çalışmaların sonuçlarını sunmaktadır. Gerçek ve tahmin edilen değerler, zaman dilimleri ve veri seti boyutları, algoritmaların etkinliğini değerlendirmek için kritik öneme sahiptir.

2.4 SARIHUMMA AŞI VERİLERİNİN ANALİZİ

2.4.1 Verilerin Analizi

Literatür, aşı stok yönetiminin nasıl gerçekleştirildiğini ve gelecekteki kullanımını tahmin eden çalışmaları ortaya koymakta ve mevsimsellik gibi çeşitli faktörlerin aşı oranlarını önemli ölçüde etkilediğini vurgulamaktadır. Ancak, ülkemizde sarı humma aşıları öncelikle yüksek riskli ülkelere seyahat amacıyla uygulanmakta olduğundan, bu aşılar seyahat kısıtlı malarının yanı sıra uluslararası ticaret, eğitim girişimleri ve ekonomik faaliyetlerden de etkilenmektedir. Bu çalışmada, kuruluşların mevcut risk analizi yöntemlerini desteklemek için, benzersiz varlık yaşam döngüsü, sistem içinde ortaya çıktığı andan itibaren zamana bağlı değişiklikleri dinamik olarak "içgörülmesidir". Ayrıca sistemi yönetenler için varlığın dinamik olarak izlenmesi ve bir maliyet unsuru içeren risklerin dinamik olarak sunulması, atıl kapasitelerin belirlenmesi ve objektif, kanıta dayalı verilerin sunulması amaçlanmaktadır. Zaman serileri sayesinde hata düzeltme, eksik veri tamamlama, tahmin ve aykırı veri kaldırma işlemleri de yapılmaktadır.

Tablo 2.2: 2023 ile 2009 Arası Sarıhumma Aşılama Sayıları.

Years	2003	2004	2005	2006	2007	2008	2009
January	3	471	683	392	725	646	1192
February	4	293	707	443	531	783	955
March	10	371	491	1994	417	552	860
April	2	330	368	516	474	556	885
May	2	376	424	1077	518	745	1126
Jun	3	558	507	735	609	1121	1525
July	21	458	425	511	668	1003	1143
August	109	427	434	921	518	644	1021
September	124	372	458	536	478	707	1231
October	99	372	485	473	579	1266	1162
November	163	421	427	698	667	1024	1194
December	67	524	526	786	511	759	989

Tablo 2.2, çeşitli aşılar üzerinde ARIMA ve zaman serisi analizi kullanan son çalışmaların sonuçları sunulmaktadır.

Tablo 2.3: 2010 ile 2016 Arası Sarıhumma Aşılama Sayıları.

Years	2010	2011	2012	2013	2014	2015	2016
January	1322	1764	1626	2541	2621	2063	2543
February	1086	1347	1287	1662	2051	1594	2799
March	1106	1432	1126	1906	1842	2090	3072
April	907	1496	1395	1978	1923	2000	2232
May	1070	1648	1775	2366	1754	2109	2772
Jun	1387	1371	1716	2535	2148	2265	2431
July	1502	1477	1514	2351	1699	2249	2021
August	1239	1797	1575	1693	1934	2079	2734
September	1313	1731	1593	2675	2285	2471	2201
October	1820	2246	2261	2462	1536	2386	2017
November	2056	1676	1933	2109	1680	2232	1755
December	1488	1991	2360	1728	1722	2270	2076

Tablo 2.3, 2010 ve 2016 yılları arası aşılama sayıları sunulmaktadır. İlk yıllarda veri girişlerinde meydana gelen sorunlar 2010 ve 2016 yılları arasında görece toparlanmaktadır. Grafikler incelendiğinde veri girişlerinde artan bir trend gözlemlenmektedir.


Tablo 2.4: 2017 ile 2023 Arası Sarıhumma Aşılama Sayıları.

Years	2017	2018	2019	2020	2021	2022	2023
January	2185	2036	2513	2121	1139	1570	2278
February	2151	2126	2026	1821	1202	1926	1740
March	1988	2121	2263	776	1533	2288	1536
April	2065	1995	2017	92	1146	1996	725
May	2203	2044	1930	138	961	2007	1709
Jun	2340	2063	1605	486	1499	2770	2261
July	1907	2610	2732	896	1461	1777	2261
August	2243	1957	1586	934	1332	2185	2472
September	1872	2204	2225	1060	1523	2064	2797
October	2019	2682	2168	1078	1564	2274	2228
November	1997	2491	1942	1046	1809	2403	2087
December	1967	2294	1849	1088	1592	2144	1674


Tablo 2.2, 2.3 ve 2.4, aylık sarı humma aşısı sayılarını sunmaktadır. 21 yıllık veri geçmişi, sistemdeki aşı veri girişlerinin ilk on yıl boyunca otomasyon eksikliği nedeniyle düşük olduğunu göstermektedir. Ardından, COVID-19 pandemisi sırasında uygulanan seyahat kısıtlamalarına bağlı olarak takip eden 11 yıllık dönemde aşılamalarda bir düşüş yaşanmaktadır. Ayrıca, 2018 ve 2022 yıllarında siyasi ilişkiler nedeniyle ev sahibi ülkelere günlük ani seyahatler gerçekleşmiştir. Ancak, bu bilgiler zaman serisindeki sayısal verilerden ziyade haber raporlarından elde edilmektedir.[15]

2.4.2 Verilerin Hazırlanması


Türkiye Hudut ve Sahiller Sağlık Genel Müdürlüğünde 2003 ve 2023 yıllarına ait yapılan sarıhumma aşısı bilgileri verilmektedir. Verinin siyasi, ekonomi ya da salgın hastalık dönemlerindeki hareketliliklerden etkilenme derecesi ile başlanmaktadır. Stok seviyelerinin ekonomik değeri ve hatalı stoklama sonucu maddi kayıplar incelenecektir. Her kurumun elde bulundurma stratejileri farklıdır. Bu, kurumun hizmet yapısı ve tedarik zorunlulukları, konakçı ülkede konuşlanması ya da tersi gibi unsurlar göz önünde bulundurularak, aşılama stok yönetimi için risk öncelik numarası hesaplarken değerlendirilmektedir.



Şekil 2.3: 2003-2023 Yılları Sarıhumma Aşı Verilerinin Aylara Göre Kullanımı.



Şekil 2.4: COVID-19'un Etkilediği 2021 ve 2022 Yıllar Hariç.



Şekil 2.5: 2003-2023 Yılları Arasında Sarıhumma Aşı Verilerinin Aylara Göre Yıllık Akışı.

(2018 ve 2022 hariç)

Özetle, Şekil 2.3, 2.4 ve 2.5 günlük aşı tüketim sıklığı verileri aylık ve yıllık verilere ayrılmaktadır.[64] Öncelikle ham veri seti ele alınmaktadır. Ardından, veri frekansı olan yıllar çıkarılmaktadır. Tüm dünyada COVID-19 ve sonrasında değişen iş akışlarının veri setine olan etkileri incelenmektedir. Yıllara göre dağılan grafiklerde her ay, sütun boyunca aynı renkle gösterilmektedir. Genel olarak ilk on yıl ile ikinci on yıl arasında artan bir trend göze çarpmaktadır.

2.4.3 Modelleme

ARIMA yöntemi, çağdaş zaman serisi tahmin çalışmalarında yaygın olarak kullanılan bir yaklaşımdır ve başarılı sonuçlar vermektedir. Ancak, ARIMA modeli, mevsimsellik olmadan bir eğilime sahip tek değişkenli veriler için uygundur. SARIMA modeli, mevsimsel etkileri dikkate alarak daha etkili sonuçlar sağlamak amacıyla ARIMA modelinin bir uzantısı olarak geliştirilmiştir. Doğrusal Regresyon, seyahat kısıtlamalarının aşı etkinliği üzerindeki etkisi gibi çeşitli değişkenler arasındaki ilişkileri ortaya çıkarabilmektedir. Korelasyon yalnızca doğrusal ilişkilerin gücünü ölçtüğü için, Doğrusal Regresyon tercih edilmektedir. Ay-


rica, veri setimiz COVID-19 pandemisi sırasında uygulanan seyahat kısıtlamalarından ve ilk on yıldaki veri girişi eksikliklerinden etkilenmektedir. Bu durum, daha fazla araştırma için makine öğrenimi yöntemlerini dahil etmesi kararına yol açmaktadır. XGBoost, karmaşık ilişkileri modelleme, eksik değerleri işleme ve ek özellikleri kullanma yeteneği gibi bir çok avantaj sunmaktadır. COVID-19'un desen kırıcı etkileri ışığında, sarı humma aşısı için talep tahmininin doğruluğunu artırmak amacıyla XGBoost dahil edilmektedir. Literatürde proaktif araştırmalarda zaman serisi analizi [16][17], toplu teknikler [18] ve regresyon modellerinin [19] kullanımı yaygındır. İkinci aşamada, doğrusal regresyon [20], ARIMA, SARIMA [21] ve XGBoost yöntemlerini [22] kullanarak çalışmalarımıza devam edilmekte ve bu modellerin sonuçları karşılaştırılmaktadır.[23] Son olarak, en başarılı tahmin yapan algoritmalarının Ortalama Mutlak Hata (MAE) değerlerine ve modellerin belirli güvenilirlik aralıkları incelenmektedir. Diğer yandan tüm merkezlerdeki aşı maliyetlerinde kullanılmak üzere risk değeri hesaplanmakta ve RPN değeri VaR modele girdi olarak kullanılmaktadır.

2.4.4 ARIMA

ARIMA modelleri, 1960'larda popüler hale gelerek 1970 yılında Box ve Jenkins tarafından karşılaştırmalı bir yaklaşımla geliştirilmiştir. Zaman serisi tahmin yöntemleri, istatistik alanında kullanılan eski yöntemler olmasına rağmen güncel çalışmalarda yaygın olarak kullanılmaktadır ve makine öğrenimi alanında da yoğun bir şekilde uygulanmaktadır.[65] Holt, 1957'de mevsimsel olmayan ancak trende sahip serilere düzleştirme önerdi; Winters ise 1965'te mevsimselliği de içeren geliştirilmiş Holt-Winters yöntemini geliştirdi. Güncel çalışmalarda bu yöntem, tahmin amaçlı olarak yoğun bir şekilde kullanılmaktadır. Zaman serilerini anlamlandırma aşamasında kullanılan birkaç kavram mevcuttur ve bu kavramlarla birlikte tanımlanmaktadır.[66] Otoregresyon ve hareketli ortalama modelinin birleştirilmesiyle mevsimsel olmayan bir ARIMA modeli elde edilir ve bu modele SARIMA denir.


Durağanlık (Stationary), bir zaman serisinin istatistiksel özelliklerinin zaman içinde değişmemesi durumunu ifade eder. Bir zaman serisinin ortalaması, varyansı ve kovaryansı zaman boyunca sabit kalıyorsa (veya istatistiksel olarak çok küçük farklılıklar gösteriyorsa), serinin durağan olduğu kabul edilir. Bu kavramları tespit etmek için çeşitli istatistiksel testler kullanılmakla birlikte, veri bilimcileri bazı durumlarda yalnızca görsel inceleme ile de bu kavramlar hakkında yorum yapabilmektedir. Zaman serisi verilerinin belirli bir örüntüye sahip olduğu durumlarda, bu veriler kolayca tahmin edilebilir olarak nitelendirilir. Bu bağlamda,

zaman serisinin istatistiksel özellikleri değişmediğinde, yani serinin durağan olduğu durumlarda, farklı zaman periyotlarındaki değerler daha kolay tahmin edilebilir.[67] Eğer bir zaman serisinde durağanlık gözlemlenmiyorsa, genellikle serinin belirli zaman dilimlerinde fark alınarak durağan hale getirilmesi amaçlanır. Trend (Trend), bir zaman serisinin uzun vadede artış veya azalış gösterdiği yapıdır. Trend gözlemlenen zaman serilerinde durağanlık olmadığı söylenebilir. Zaman serisinin belirli bir davranışının belirli periyotlarla tekrar etmesine mevsimsellik denir. Döngüsellik ise mevsimselliğe benzer şekilde, tekrar eden düzenler içermektedir. Ancak mevsimsellik, daha belirgin, kısa vadeli ve düzenli aralıklarla (gün, hafta, mevsim, yıl gibi zaman dilimleriyle örtüşecek şekilde) gerçekleşir. Aşı uygulamaları gibi örneklerde önemlidir.[68] Mevsimsellik (Seasonality), verilerin belirli mevsimsel hareketlerle örüntülü olması durumudur. Döngüsellik (Cycle), daha uzun vadeli ve belirsiz yapılarda, gün/hafta/yıl gibi zaman aralıklarıyla örtüşmeyecek şekilde, daha çok yapısal nedenler ve konjonktürel değişimlere bağlıdır. Örneğin, politikacıların ve iş dünyasındaki belirli kişilerin demeçleri şekillendirebilmektedir.[69] ARIMA(p,d,q) ifadesinde, p değeri geçmiş gerçek değer gecikmelerinin sayısını (otoregresif derece), d değeri farkların sayısını (farklandırma derecesi) ve q değeri kalıntılardaki gecikmelerin sayısını, yani hata gecikmelerinin sayısını (hareketli ortalama derecesi) belirtmektedir. Burada p, otoregresif kısmın derecesini; d, ilk farklandırma derecesini; q ise hareketli ortalama kısmının derecesini ifade eder. Yumuşatma veya düzeltme yöntemi, basit üstel düzeltme kullanarak tahmin yapmaktır. Gelecek, yakın geçmişle daha fazla ilişkilidir varsayımıyla geçmişin etkilerini ağırlıklandırmaktadır. Tahmin, geçmiş gerçek değerler ve geçmiş tahmin edilen değerlerin üssel olarak ağırlıklandırılmasıyla yapılmaktadır. Her bir gözlem için ağırlık, alpha düzeltme parametresi kullanılarak hesaplanır ve bu değer 0 ile 1 arasında değişir. Alpha değeri 1'e yakın olduğunda daha fazla ağırlık verilirken, 0'a yakın olduğunda daha eski gözlemlere ağırlık verilmektedir. Sonuç olarak, alpha yüksek olduğunda öğrenme becerisi artar, hatırlama becerisi ise azalır; bu durum, gerçek değerlere daha yakın sonuçlar elde edilmesini sağlar.[70] ARIMA modeli değişkenler ile esnek kullanımı AR, MA ve ARMA modellerinin kombinasyonu olarak düşünülebilir. Tekrar eden verileri belirli zaman diliminde gözlemlenmesi ve kayıt altına alınması işlemi zaman serileri olarak adlandırılmaktadır.



Şekil 2.6: Sarı Humma Aşılarının Zamana Bağlı En Yüksek ve Düşük Kullanımı.

Zamana bağlı sarıhumma aşı kullanımı ile ilgili değerler verinin kalitesini önemli düzeyde etkilemektedir. Veri akışını bozan sistemsel ve altyapısal hatalar nedeniyle gönderilemeyen bilgilerin kesintiye uğraması ve sistemin yeniden başlaması ile zamansal bozulmalar ya da veri girişlerindeki hatalardan, yazılım kaynaklı sorunlardan olabilir. Ayrıca tamamen konjoktürel olaylar nedeniyle ani şoklar yada stok eksikliği gibi sorunlardan kaynaklanabilir. Tüm bu olasılıklar haricinde tamamen yapısal iş süreçleri nedeniyle olabilir. Verinin frekansını etkileyen tüm olasılıkların göz önünde bulundurulması ve analizi için en düşük yada en yüksek aşılama yapılan günlerin belirlenmesi önem arz etmektedir. COVID-19 pandemisi gibi olaylar mevsimsel modellerde ani değişimlere yol açabilir, bu da SARIMA'nın performansını düşürebilir ve ARIMA'nın varsayımlarını geçersiz kılabilir. RMSE aykırı değerlere karşı hassas değildir ve veri kümesinin merkezi değerlerine odaklanır. MAE ise aykırı değerlere duyarlıdır ve veri kümesinin orta noktasının merkezini belirler. İkisini birlikte değerlendirdiğimizde, COVID-19 hariç tutulduğunda model başarıları izlenecektir. Modern bir dijital kuruluştaki bilgisayar araçları ile performansında hayati bir rol oynayan insan aktörleri arasında bir denge bulunmaktadır. Öngörülebilirlik önemli olduğundan, genel olarak, insan aktörleri öngörülemeyen olayları gerçek zamanlı olarak ele almaktadırlar. Öngörülebilir olaylar için araçlar çok daha iyidir modelleme ve simülasyon ile desteklenmektedir.




Şekil 2.7: Single Entitiy Annual Distribution (SMA).

Basit Hareketli Ortalama zaman serilerinde, ham veri kümesinin farklı seçimlerinin bir dizi ortalamasını oluşturarak veri noktalarını analiz etmek için yapılan bir hesaplama. Bir dizi sayı ve sabit bir alt küme boyutu verildiğinde, hareketli ortalamanın ilk elemanı sayı serisinin başlangıçtaki sabit alt kümesinin ortalaması alınarak elde edilmektedir. Daha sonra alt küme "ileri kaydırılarak" değiştirilmektedir; yani serinin ilk sayısı hariç tutulur ve alt kümedeki bir sonraki değer dahil edilmektedir. Hareketli ortalama, genellikle kısa vadeli dalgalanmaları yumuşatmak ve uzun vadeli eğilimleri veya döngüleri vurgulamak için zaman serisi verileriyle kullanılmaktadır. Kısa vadeli ve uzun vadeli arasındaki eşik uygulamaya bağlıdır ve hareketli ortalamanın parametreleri buna göre ayarlanmaktadır. Basit hareketli ortalama zaman serilerinde temel olarak uygulanan formüldür.

Simple Moving Average Formula

$$SMA = \frac{(A_1 + A_2 + A_3 + \dots + A_n)}{N} \quad (2.1)$$




Şekil 2.8: Cumulative Entitiy Annual Distribution (CMA).

Kümülatif Hareketli Ortalamada, veriler sıralı bir veri akışında gelir ve kullanıcı geçerli veriye kadar tüm verilerin ortalamasını alınmaktadır. Aşılarda 21 yıllık geçerli zamana kadar tüm akış hareket ve işlemlerinin ortalama kullanımı alınmaktadır. Her yeni akış gerçekleştiğinde, işlem anındaki ortalama aşırı kullanımı, o noktaya kadarki tüm işlemler için kümülatif ortalama kullanılarak hesaplanabilmektedir. Bir yıllık aşırı kullanımlarını örnek görüntüsü aşağıda gösterilmektedir. Yeni bir veri için geçerli kümülatif ortalama, önceki kümülatif ortalamasının çarpı n 'ye, artı en son veriye, şimdiye kadar alınan nokta sayısına, $n + 1$ 'e bölünmesine eşittir. Tüm veriler geldiğinde ($n = N$), kümülatif ortalama son ortalamaya eşit olmaktadır. Ayrıca, verilerin toplamını ve nokta sayısını depolamak ve her yeni veri geldiğinde kümülatif ortalamayı elde etmek için toplamı nokta sayısına bölmek mümkündür.

Cumulative Moving Average

$$CMA = \frac{x_1 + x_2 + x_3 + \dots + x_n}{N} \quad (2.2)$$




Şekil 2.9: Weightage Entitiy Annual Distribution (WMA).

Ağırlıklandırılmış Hareketli Ortalama, yakın tarihli verilere daha fazla, geçmiş verilere ise daha az ağırlık vermektedir. Bu, her çubuğun fiyatının bir ağırlıklandırma faktörüyle çarpılmasıyla yapılmaktadır. Benzersiz hesaplaması nedeniyle, WMA grafiği karşılık gelen Basit Hareketli Ortalamadan daha yakından takip etmektedir. Ağırlıklı olarak son dönemi öncelemektedir. Veriler eskidikçe ağırlıkları değişmektedir. Sarıhumma aşısı grafiğinde ilk on yıl otomasyona yeni başladığı, eksik veri girildiği ya da merkez ile internet bağlantısı giden birimlerin zaman zaman eksik veri gönderimi yaptığı belirtilmektedir. Bu nedenle son dönemi ağırlıklandırmak amacıyla aşısı tahmin çalışmalarında WMA önem arz etmektedir. Özellikle konjktürel olaylar, salgın hastalıklar, ulusal ya da uluslararası siyasi olaylar son dönem verilerinin etkileyebilmektedir.

Weightage Moving Average

$$WMA = (A_n w_1 + A_{n-1} w_2 + \dots + A_1) / n + (n-1) + \dots + 2 + 1 \quad (2.3)$$



Şekil 2.10: Exponential Annual Distribution (EMA).

Exponential Moving Average

$$EMA = C - Px \frac{2}{(n+1)} + P \quad (2.4)$$

EMA (Exponential Moving Average - Üstel Hareketli Ortalama), aşılama grafiğinde son periyotlarda yer alan değerlerin ağırlıklarının hesaplamalarda yüksek olduğu, bir hareketli ortalama türüdür. En son yapılan aşılardan öncekilere daha fazla ağırlıklandırılır. EMA, basit hareketli ortalama ile karşılaştırılabilir. EMA belirli bir süre boyunca bir varlığın ortalama kullanım sayısını gösteren kullanım tabanlı, gecikmeli bir göstergedir. Geciken bir gösterge olduğundan ve daha önce gerçekleşmiş olan olaylara tepki gösterdiğinden, tek başına maliyet tahmin göstergesi olarak kullanılmaz, onaylama ve analiz için kullanılmaktadır.

2.4.5 SARIMA

SARIMA modeli, ARIMA modelinin mevsimsel etkilere göre sonuç vermesi amacıyla geliştirilmiş bir yöntemdir. ARIMA’da kullanılan 3 değişkene ek olarak 4 yeni değişkenlere sahiptir. SARIMAX, (p,d,q)(P,D,Q,m) şeklinde gösterilir. Burada, P mevsimsel otoregresif

, Q ise mevsimsel hareketli ortalama terimlerini temsil etmektedir. Python kütüphanesi içerisinde bu yöntem SARIMAX olarak adlandırılmaktadır. SARIMAX yönteminde kullanılan parametreler, SARIMAX (p,d,q)(P,D,Q)m sembolü ile ifade edilmektedir. Kısaca, (p,d,q) terimleri, ARIMA modelinden gelen ifadeler olup, trend bileşenlerini temsil eder. ARIMA, trendleri modelleyebilme yeteneğine sahipken, mevsimsellik konusunda zayıf kalmaktadır. (P,D,Q) ise SARIMA modeline ait mevsimsel gecikme sayılarıdır ve başka bir deyişle mevsimsel bileşenler olarak tanımlanır. m değeri, tek bir mevsimlik dönem için zaman adımı sayısını ifade eder ve mevsimselliğin gözlemlenme yapısını belirtir. Semboldeki d değeri modelin durağan olması için kaçınıcı dereceden farkının alınacağını göstermektedir.[71]

] Serinin durağan olmaması serideki değerlerin zaman aralığında çok farklı olmasından kaynaklanmaktadır. Zaman serilerinin durağan olmadığı durumlarda, serinin farkı alınarak durağan duruma getirilmektedir.[17] SARIMA modellerinin temel varsayımı, ARIMA'ya benzer. SARIMA'da hata terimlerinin ortalaması sıfır, varyansı ise sabit olan rastgele değişkenler olduğu ve hata terimleri arasında korelasyon bulunmadığı şeklinde bir ana tema bulunmaktadır.

Seasonal Auto-Regressive Component

$$SAR = \Phi_1 Y_{t-m} + \Phi_2 Y_{t-2m} + \dots + \Phi_P Y_{t-Pm} \quad (2.5)$$

Seasonal Differencing

$$Seasonal\ Difference = Y_t - Y_{t-m} \quad (2.6)$$

Seasonal Auto Regressive Integrated Moving Average

$$SARIMA = SARIMA(p,d,q)(P,D,Q,m) \quad (2.7)$$

Özetle, SARIMA modeli üç ana bileşenden oluşur. İlk olarak, mevsimsel otoregresif bileşen (SAR), verinin mevsimsel geçmiş değerlerini kullanarak değerleri tahmin etmektedir. İkinci olarak, Mevsimsel Farklandırma, mevsimsel farkları dikkate alarak veriden mevsimsellik kaldırılmaktadır. Son olarak, Mevsimsel Ototregresif Entegre Hareketli Ortalama (SARIMA), SAR ve Mevsimsel Farklandırma bileşenlerini birleştirerek mevsimsel ARIMA modelini oluşturmaktadır ve bu model SARIMA(p,d,q) (P,D,Q,m) olarak gösterilmektedir. Bu bileşenler, SARIMA modelinin mevsimsel verileri etkili bir şekilde ele almasını ve modellemesini sağlamaktadır.[72]

2.4.6 Lineer Regresyon

Basit bir doğrusal regresyon modeli, tek bir açıklayıcı (bağımsız) değişken ile açıklanan (bağımlı) değişken arasındaki doğrusal ilişkiyi ifade eder. Açıklayıcı (bağımsız) değişkenin yardımıyla açıklanan (bağımlı) değişkenin tahmin edilmesi (öngörülmesi) amacıyla kullanılmaktadır. [73]

$$Y = B_0 + B_1x + \varepsilon \quad (2.8)$$

Bu modelde kesim noktası, doğrunun eğimi ve hata terimidir.

Errors

$$e_i = y_i - \hat{y}_i \quad (2.9)$$

Residual Sumo Squares

Örnek regresyon fonksiyonu kullanılarak elde edilen tahmin edilen ve gerçek değerler arasındaki farka kalıntı denilmektedir. Bu formülde yalnız bırakıldığında, kalıntı kareler toplamı olarak adlandırılmaktadır.

$$RSS = e_1^2 + e_2^2 + \dots + e_n^2 = (y_1 - \hat{B}_0 - \hat{B}_1x_1)^2 + (y_2 - \hat{B}_0 - \hat{B}_1x_2)^2 + (y_n - \hat{B}_0 - \hat{B}_1x_n)^2 \quad (2.10)$$

Least Squares Method

En küçük kareler yöntemi hata karelerini minimize eder. Kareler toplamı hatası, konveks bir fonksiyondur. Bu nedenle, hataları minimize etmek için kareler toplamından hata türetilmiştir. Bu yöntem sayesinde katsayılar tahmin edilmektedir. ($B_0 \wedge B_1$)

Estimation Of Coefficient

$$\hat{x} = \frac{1}{n} \sum_{i=1}^n y_i, \hat{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (2.11)$$

Coefficients Variance

Katsayıların varyansı aşağıdaki formüllerle hesaplanabilir.

$$SE(\hat{B}_0)^2 = Q^2 \left[\frac{1}{n} + \frac{x^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right] \quad (2.12)$$

$$SE(\hat{B}_1)^2 = Q^2 \left[\frac{1}{n} + \frac{Q^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right] \quad (2.13)$$

Variance Of Residuals

Artıkların varyansı mevcut veriler kullanılarak tahmin edilmiştir. Bu tahmine artıkların standart hatası denir.

$$RSE = \sqrt{RSS - (n - 2)} \quad (2.14)$$

Value at Risk Confidence Intervals

$$B_1, \%95; \hat{B}_1 \pm 2 \cdot SE(\hat{B}_1) \quad (2.15)$$

$$B_0, \%95; \hat{B}_0 \pm 2 \cdot SE(\hat{B}_0) \quad (2.16)$$

Significance Of The Coefficient Confidence

Oluşturulan modelde, katsayıların ve modelin genel önemi test edilmektedir. Katsayıların anlamlı olup olmadığını test etmek için hipotez testleri kullanılmaktadır. Hipotezler aşağıdaki gibi belirlenmektedir.

H_0 : if there is no relationship between x and y ,

H_A : if there is a relationship between x and y ,

$$H_0: \beta_1 = 0 \text{ or } H_A: \beta_1 \neq 0 \quad (2.17)$$

Bu hipotezle, parametrelerimizin eşit olup olmadığı kontrol edilmektedir. Hipotezi test etmek için t, aşağıdaki formülle hesaplanabilir.

$$t_c = (\hat{B}_1 - 0) / SE(\hat{B}_1) \quad (2.18)$$

$$|t_c| > t_{\alpha/2, n - (k + 1)} \quad (2.19)$$

Çalışmada, t değerini hesaplanmaktadır, tabloda t değeri hipotezden büyükse H_0 hipotez reddedilmektedir. Hipotez reddedildiğinde, test edilen katsayının anlamlı olduğu söylenmektedir.

$$F_c = \frac{SS_{Reg}/k}{SS_{Reg}/n - (k + 1)} \quad (2.20)$$

Burada k, bağımsız değişkenlerin sayısını ifade etmektedir. Basit doğrusal regresyonda yalnızca bir bağımsız değişken bulunduğundan, değeri 1'dir. F tablosu değeri, 0,05 anlamlılık düzeyinde aşağıdaki şekilde belirlenmiştir.

$$F_t = F_{0.05, k, n - (k + 1)} \quad (2.21)$$

$F_c > F_t$ Yukarıdaki eşitlik sağlanırsa, H_0 hipotezi reddedilir ve model anlamlı olur. F değeri 60-70 gibi değerlerden yüksek olduğunda ise modelin anlamlı olamayabileceği sonucuna ulaşılabilir, ancak bu tamamen reddedilebileceği anlamına da gelmeyebilir. Toplanan veriler

regresyon yoluyla işlenmekte ve böylece mevcut kayıp veya maliyet riskinin hesaplanması için tanımlanan dağılıma girdi sağlamaktadır.[67]

2.4.7 XGBoost

Tüm Öğrenme süreçleri genel olarak iki aşamadan oluşmaktadır. İlk aşama veri kümesi içerisinde bilinmeyen ilişkiler tahmin edilmektedir. İkinci aşama tahmin edilen ilişkiler doğrultusunda yeni çıktılar ön görülmektedir. Bu aşamalar öncesi, Denetimli Öğrenme ve Denetimsiz Öğrenme olarak iki temel öğrenme metodunu oluşturulmaktadır. Makine öğrenmesi alanında tahmin çalışmalarında uzun zamandır kullanılan lineer regresyon, polinomal regresyon, karar ağaçları gibi eski algoritmalar ile bu algoritmaların temel çalışma prensipleri iyileştirerek çalışan yeni yöntemler geliştirilmektedir. Adaboost (Adaptive Boosting) ve Gradyan Artırma (Gradient Boosting) algoritmaları karar ağaçları mantığı ile çalışan, fakat her adımda çalışma prensiplerini iyileştirerek karma yöntemler uygulayan ve başarılı sonuçlar veren yöntemler olarak ortaya çıkmıştır. İşlemci hızlarının arttırılmasıyla, dağıtık sistemler kullanılarak hızlı hesaplamaların yapılması ve Artırma (Boosting) algoritmalarının kullanılmasına engelleyen kısıtlar azaltılmaktadır. 2016 yılında Gradyan Artırma Algoritmasını güncel teknolojiler ile verimli çalışmasını sağlayan XGBoost algoritması geliştirilmiştir. Hızlı çalışması ve başarılı sonuçlar vermesi özellikleri ile çalışmalarda tercih edilen bir algoritmadır. XGBoost yöntemi tahmin alanında da tercih edilmekte ve satış tahmin alanında fazlaca kullanılmaktadır. Bu bölümde Boosting ve XGBoost yönteminin literatürde gelişimi anlatılmış ve tahmin alanında başarılı sonuç alınan örnek çalışmalar hakkında bilgi verilmektedir.[53]

2.4.8 Denetimli Öğrenme

Denetimli öğrenme belirli veri kümesi içerisinde ilişkisi olduğu düşünülen verilerin ilişkisinin bulunması yöntemidir. İlişki kurulmak istenen veriler içerisinde örnek bir küme ile çalışma yapılmaktadır. Örnek kümenin algoritmanın yeterli tahmin performansı ile sonuç üretmesine yetecek seviyede büyük olması beklenmektedir. Örnek küme kullanılarak iki veri grubu arasında ilişki kurulmaktadır. Verilerden birinden (bağımsız değişken) diğer verinin (bağımlı değişken) değeri belirlenmektedir.

2.4.9 Denetimsiz Öğrenme

Denetimsiz öğrenme yönteminde denetimli öğrenme yönteminden farklı olarak öğrenme yöntemini gösteren bir model yoktur. Veri kümesi içerisinde ilişkisi bilinmeyen veriler arasında sonuç bulma çalışmasıdır. Kümeleme çalışmaları denetimsiz öğrenme alanına girmektedir. Veriler arasındaki sınıflar makineye öğretilmemektedir. Algoritmanın veriler arasındaki ilişkiyi kendisinin bulması, verileri kümelere ayırarak sınıflandırması beklenmektedir.[74]

2.4.10 Takviyeli Öğrenme

Denetimli ve Denetimsiz öğrenme yöntemlerinden farklı olarak ödül ve ceza sistemine dayanan öğrenme yöntemidir. Makine karşılaştığı problemin çözümüne yönelik kararlar vermektedir. Daha önce verdiği kararlar sonucunda aldığı ödül sayısını en yüksek değere çıkararak bulmaya çalışmaktadır. Verilen kararların doğruluğu tek başına hesaplanamamaktadır. Örneğin bir satranç oyununda verilen kararın doğruluğu, takip eden kararlara bağlıdır.

2.4.11 Arttırma Karar ağaçları

Topluluk teknikleri olarak bilinen algortimalar son yıllarda geliştirilmeye devam etmektedir. Temel mantık tek bir algortimadan alınan sonuç yerine birden çok algortimanın kararlarını işlemekten geçmektedir.

2.4.12 Aşırı Arttırma Karar ağaçları

XGBoost olarak bilinen makine öğrenmesi algoritması günümüzde sınıflandırma ve regresyon işlemlerinde kullanılan ve farklı problemlerde başarılı çalışan bir yöntem olması nedeniyle popüler hale gelen bir algoritmadır.[75] Gradyan artırma ağaçları ilk olarak Friedman tarafından 1999 yılında ortaya atılmıştır. Friedman 2002 yılında modelini sabit boyutlu karar ağaçları kullanarak iyileştirmeler yaparak tekrar düzenlemiştir. Gradyan artırma ağaçları kavramı içerisinde geçen artırmadır. Boosting olarak bilinen yöntem düşük performanslı öğrenme yöntemlerini birleştirerek, daha iyi performanslı öğrenme yöntemi oluşturmayı amaçlamaktadır. Bu yöntem içerisinde ilk modeller sırayla oluşturulmaktadır. Tahmin başarısı yeni modeller oluşturulurken iyileştirilmektedir. Her yeni model bir önceki modelin hatalarını düzeltmeyi amaçlanmaktadır. Chen and Guestrin (2016), tarafından geliştiril-

len Aşırı Gradyan Artırma (XGBoost), Gradyan Artırma algoritmasının temel prensiplerini kullanarak geliştirilmiş denetimli makine öğrenme yöntemidir. XGBoost algoritması sınıflandırma ve regresyon karar ağaçlarından oluşmaktadır. Çok sayıda zayıf öğrenme modelini birleştirerek güçlü öğrenme algoritması üretmeyi amaçlamaktadır. Zayıf öğrenme modelleri regresyon ağaçlarını oluşturmaktadır, algoritmanın başarısı hesaplanmaktadır ve residual (hata skoru) iterasyon yöntemi ile bir sonraki ağacın oluşması için kullanılmaktadır. Sonuç olarak kullanılan yöntem karmaşık problemlerin çözümünde başarılı sonuçlar vermektedir. XGBoost ve Gradyan Artırma algoritmalarının çalışma yöntemi aynıdır. Fakat XGBoost algoritmasının, Gradyan Artırma ve diğer tahmin algoritmalarına göre performanslı ve başarılı çalışmasını sağlayan özellikleri bulunmaktadır. Regülerizasyon, XGBoost algoritmasının karmaşık modelleri cezalandırmak için kullanılan bir özelliktir. Gama parametresi, iterasyon adımıda kullanılan residual değerini ölçeklendirmektedir. Bu özellik, algoritmanın aşırı öğrenmesini engellemek amacıyla kullanılmaktadır. XGBoost algoritmasının bir diğer önemli özelliği, boş değerlerle çalışabilmesidir. Boş değerlerin doldurulması veya kaldırılması, veri ön işleme adımıda yapılması gereken bir işlemdir. Ancak XGBoost algoritması, ağacın boş değerlerle karşılaştığı her adımda yeni bir yön oluşturarak çözüm üretmektedir. XGBoost algoritmasının tercih edilmesinin en önemli sebeplerinden biri, hızlı olmasıdır. Gradyan artırma ve diğer tahmin yöntemleri ile sonuç elde etmek zaman alırken, XGBoost algoritması Windows ve Linux işletim sistemlerinde paralel işlemlerle çalışarak gradyan artırma yöntemine göre 10 kat daha hızlı performans göstermektedir. Ayrıca, hafıza kullanımı daha düşüktür ve daha az donanım ihtiyacı duyarak hızlı ve başarılı sonuçlar elde etmektedir. Boosting algoritmalarının ortaya çıkış tarihleri şu şekilde özetlenebilir: AdaBoost (1995, Y. Freund), Gradient Boosting (2001, Friedman), XGBoost (2016, Washington Üniversitesi), LightGBM (2017, Microsoft) ve CatBoost (2018, Yandex). [76] İlk boosting algoritması AdaBoost'tur ve daha kolay anlaşılabilir olduğu için çalışma mantığı açıklanmaktadır. Boosting, bir topluluk tekniği olup, ilişkilendirme algoritmalarının temeli ni oluşturur. Zayıf sınıflandırıcılar, güçlü bir sınıflandırıcı oluşturmak amacıyla bir araya getirilir. XGBoost, zayıf öğrenme algoritmalarını bir arada çalıştırarak (doğrusal bölmeleri yineleyerek ve en az hata(ları) ağırlıklandırarak) daha başarılı sınıflandırma sonuçları üreten özelleştirilmiş bir boosting versiyonudur. XGBoost, kısa karar ağaçları ile çalışır ve bir yapı oluşturmak için entropi belirsizlik ölçüsünü kullanır.[77]

Kümeleme

$$\hat{F}_{bag} = \hat{f}_{1(x)} + \hat{f}_{2(x)} + \dots + \hat{f}_{b(x)} \quad (2.22)$$

Entropi Formülü

$$H(P) = - \sum_{k=1}^n p_k \log_2 p_k \quad (2.23)$$

Boost Main Logic Formülü

- Gözlem ağırlığını eşit sayıya bölerek $w_i = \frac{1}{N}, i = 1, 2, \dots, N$.
- for m=1 to M:
 - Sınıflandırıcıları eğit $G_m(x)$ ağırlık verilerini kullanarak eğitime devam et w_i .
 - Compute

$$err_m = \frac{\sum_{i=1}^N w_i I(y_i \neq G_m(x_i))}{\sum_{i=1}^N w_i} \quad (2.24)$$


- Çalıştır $\alpha_m = \log((1 - err_m) / err_m)$. (2.25)

- Set $w_i \leftarrow w_i \cdot \exp[\alpha_m \cdot I(W_i \neq G_m(x_i))]$,


$$i = 1, 2, \dots, N. \quad (2.26)$$

- Çıktı $G_{(i)} = \text{sign} \left[\sum_{k=1}^n \alpha_m G_m(x) \right]$. (2.27)

Boost, ikili sınıflandırma için geliştirilen ilk gerçekten başarılı boosting algoritmasıdır. Bu, güçlendirmeyi anlamak için en iyi başlangıç noktasıdır. Modern boosting yöntemleri, özellikle stokastik gradyan boosting makineleri üzerine kurulu olan XGBoost'a dayanmaktadır. [55]



Şekil 2.11: Single, Bagging, Boosting Çalışma Mantığı.



Şekil 2.12: Boosting Çalışma Mantığı.

Özetle, "iyi" ve "zayıf" sınıflandırıcılar bir araya gelerek çalışan XGBoost, boosting'in özelleştirilmiş bir versiyonudur ve zayıf öğrenme algoritmalarını bir arada çalıştırarak daha başarılı sınıflandırma sonuçları üretir. Bu süreç, doğrusal bölümleri yineleyerek ve en az hata/ları ağırlıklandırarak gerçekleştirilir. Boosting, kısa karar ağaçları ile çalışır. Yapıyı oluşturmak için entropi belirsizlik ölçüsü kullanılır. Arttırma öğrenmesi, makine öğrenmesinin dördüncü modelidir.[78] Algoritmaların başarılarının hesaplanması için belirli ölçüm yöntemleri geliştirilmektedir. Tahmin süreçlerindeki başarıyı ölçmek için yaygın olarak kullanılan yöntemler bu bölümde özetlenmektedir. Yöntemlerin anlaşılabilmesi için formüller kullanılmaktadır. Formüllerdeki sembollerin açıklamaları aşağıda belirtilmiştir: A: Gerçek değer, B: Tahmin edilen değer, T: Zaman periyodu, N: Veri setinin büyüklüğü. Formül içerisinde A ve B değerlerinin üst çizgi ile kullanımı, bu değerlerin ortalamasını ifade etmektedir. Ortalama sapmayı ölçmek için iki popüler teknik bulunmaktadır. Ortalama Karekök Hata (RMSE) ve Ortalama Mutlak Hata (MAE). Bu çalışmada, her iki tekniği karşılaştırmak amacıyla kullanılmaktadır. RMSE, istatistikçiler arasında daha popüler olma eğilimindedir. Sonraki alt bölümde MSE ve RMSE için denklemler sunulacaktır.

2.4.13 Karekök Ortalama Hata

Toplanan veriler regresyon analizi ile işlenmekte, böylece tanımlanan dağılıma bir girdi sağlanarak mevcut kayıp veya başarısızlık riski hesaplanmaktadır. Modellerin performansı, kök ortalama kare hata (RMSE) kriterine göre değerlendirilmektedir. Bu modellerin beklenen başarısı, düşük hata oranı ve yüksek doğrulukla sonuçlar üretmektir. Bu çalışmada, performans kriteri olarak RMSE seçilmektedir. Tahmin modellerinin amacı, RMSE değerlerini minimize etmektir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N [y(i) - \hat{y}(i)]^2}{N}} \quad (2.28)$$

2.4.14 Ortalama Mutlak Hata

Burada, y_j gerçek değer, $\hat{y}_j$ tahmin değeridir ve n veri sayısını temsil eder. Bu, bir modelin tahmin edilen değerleri ile gerçek gözlemlenen değerler arasındaki farkın yaygın olarak kullanılan bir tahminidir. Tüm tahmin edilen değerlerin pozitif olması gerektiği durumlarda, beklenen hata değerlerinin toplamı olarak ölçülmektedir. Ortalama Mutlak Hata formülü;

$$MAE = \frac{\sum_{i=1}^N |y_i - x_i|}{n} \quad (2.29)$$

Veri setinin boyutuna bağılı olarak, Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) kullanılmaktadır. Düşük hacimli veriler genellikle asimetric bir dağılım sergileyebilir. MAE için optimize edilmiş koşullar altında, optimal değerin düz bir sıfır tahmini gözlemlenir. RMSE, koşullu ortalama ile minimize edilirken, MAE koşullu medyan ile minimize edilir. MAE minimize edildiğinde, uyum medyana daha yakın ve yanlı olabilir. Ayrıca, RMSE, birkaç büyük hata yapan bir modelin gerçek performansını, birçok küçük hata yapan bir modele kıyasla daha iyi yansıtabilir. Kök Ortalama Kare Hata (RMSE), birkaç önemli hata üreten bir modelin gerçek performansını, birçok küçük hata üreten bir modele kıyasla etkili bir şekilde yansıtabilir. RMSE, MAE gibi metriklere göre aykırı değerlere daha duyarlıdır. Kök Ortalama Kare Hata değerleri, hedef değişkenin ölçeğinden etkilenir. Bu nedenle, farklı veri setleri arasında RMSE değerlerini karşılaştırmak yanıltıcı sonuçlar verebilir. RMSE değerli bir metrik olmasına rağmen, aşağıdaki uyarıları akılda tutmak önemlidir. Aykırı Değerlere Duyarlılık: Artıkların kare alınması nedeniyle, RMSE (Kök Ortalama Kare Hata) ve MAE (Ortalama Mutlak Hata) gibi metrikler, aykırı değerlere daha fazla duyarlılık göstermektedir. Ölçek Bağımlılığı: RMSE değerleri, hedef değişkenin ölçeğinden etkilenir. Bu nedenle, farklı veri setleri arasında RMSE değerlerini karşılaştırmak yanıltıcı sonuçlara yol açabilir. Özetle, kök ortalama kare hata, çeşitli alanlarda yaygın olarak kullanılan bir metriktir ve sezgisel bir yorum sunarak tahmin doğruluğunu doğrudan değerlendirir. Ancak, aykırı değerlere duyarlıdır, aşırı uyuma neden olabilir ve verinin ölçeğinden etkilenir. Şu ana kadar tamamlanan çalışmalar, veri setini anlama düzeyimizi artırmaktadır.

2.4.15 Uygulama

Veri seti, Ocak 2003'ten Aralık 2023'e kadar 252 aylık gözlemden oluşmaktadır. Veri seti, sırasıyla 202 ay ve 50 ay için eğitim ve test veri setlerine (%80/%20) ayrılmaktadır. ARIMA, SARIMA, Doğrusal Regresyon ve XGBoost kullanıldı. [25]

Trend Analizi Öncelikle, verileri incelemek ve gözlemlemek iyi bir başlangıçtır. Verilerin özelliklerini anlamak için eğilimler ve mevsimsel değişiklikler görselleştirilmektedir. Mann-Kendall Eğilim Testi ve Kendall Tau Testi, zaman serisinde bir eğilim olup olmadığını belirlemek için kullanılmaktadır.

Durağanlık Testi Zaman serisinin durağan olup olmadığını test etmek için ADF ve KPSS testleri kullanılmaktadır. Bu aşamada, ADF test sonuçlarına göre d derecesi (fark derecesi) belirlenmektedir. ADF ve KPSS test sonuçları durağan değilse, seriyi durağan hale getirmek için fark alınmaktadır. İkinci ACF ve PACF Analizi: Seriyi durağan hale getirdikten sonra, ACF ve PACF grafiklerine bakarak p ve q için başlangıç tahminleri yapılabilmektedir. ACF ve PACF grafiklerini inceledikten sonra p ve q için başlangıç değerleri elde edilmektedir. Burada tahmin ettiğimiz parametre değerleri, ARIMA veya SARIMA modelini kurarken kullanacağımız Grid Search süreci için bir başlangıç noktası sağlamaktadır.

Beyaz Kutu Testi (Ljung-Box Testi) En uygun model Akaike Bilgi Kriteri (AIC) ile belirlendikten sonra, model kalıntılarının rastgele olup olmadığını doğrulamak için Ljung-Box testi uygulanır. Bu, modelin veriye uyumunu değerlendirme sürecinin bir parçasıdır.

AIC Değerleri ile Uygun (p, d, q) Değerlerinin Seçimi AIC (Akaike Bilgi Kriteri), en uygun model parametrelerini belirlemek için kullanılır. SARIMA için (p, d, q) ve $(P, D, Q)m$ farklı kombinasyonları deneyerek en düşük AIC değerini veren parametreler seçilmektedir.

Aşırı Öğrenme Eliminasyonu Çapraz Doğrulama Zaman Serisi Çapraz Doğrulaması, SARIMA modelinin eğitim ve test sonuçları ile ortalama MAE'yi değerlendirirken, verileri kaydırmalı veya genişleyen pencereler kullanarak kronolojik bir sırayla eğitim ve test setlerine ayırmaktadır. Model, geçmiş verilere dayanarak eğitilir ve bölme noktasına bağlı olarak gelecekteki veriler üzerinde test edilir.

Value at Risk, bu model, aşı sayılarıyla ilgili gerçek ve tahmin edilen verilerin yanı sıra %95 ve %99 güven aralıklarının hesaplanmasında ve stoklanan aşılardan maliyet kayıplarının belirlenmesinde kullanılmaktadır. Varlık kaybı maliyetlerine göre risk önceliklendirmesi organizasyon stratejilerine göre düzenlenir. Düşük, yaygın ve yüksek aralıklar kayıp maliyet aralıklarına göre numaralandırılmıştır.

H - Organizasyon için Yüksek Etki

M - Organizasyon için Orta Etki


L - Organizasyon için Düşük Etki

Model, ürettiği tahminlerle kayıp riski ve ekonomik olarak risk altında olan varlıklar hakkında bilgi sunmakta ve sonuçları açıklamaktadır. Bu çalışmayı mümkün kılan teknoloji, ham verileri kaydeden Microsoft Excel 2019'dur. Verilerin ön işlenmesi, veri setinin ilk kontrolü ve araştırmanın amacına ulaşmak için uygulanan metodoloji ile birlikte CSV formatı sağlanmıştır. Tahmin modelleri, Anaconda Desktop ve Jupyter Notebook IDE kullanılarak geliştirilmiştir. Güvenli veri işleme için Pandas, NumPy, Matplotlib ve Seaborn kütüphaneleri tercih edilmiştir. Bu kütüphaneler, çeşitli tahmin paketlerine sahip oldukları için bu çalışmanın verimliliğini artırmak amacıyla seçilmiştir. Modeli kodlamak ve verileri görselleştirmek için Python programlama dili kullanılmaktadır. Yukarıda bahsedilen tüm yazılımlar, bir Microsoft Windows 10 Pro makinesinde çalıştırılmaktadır.

2.4.16 Veri Manüplasyonu

Denetimli öğrenmede, model bir dizi girdi verisi ve buna karşılık gelen etiketli çıktı veri seti kullanılarak eğitilmektedir. Bu yöntem, bilinen girdilere dayanarak tahminler yapmayı sağlar. Denetimsiz öğrenmede ise model, etiketlenmemiş verilerdeki gizli kalıpları ortaya çıkarmak ve girdi veri noktaları arasındaki değerli ilişkileri tanımlamak için eğitilmektedir. Bu yaklaşım, benzer içgörüler elde etmek amacıyla yeni girdilere uygulanabilmektedir. Bu çalışmada, tahmin edilen ve gerçek etiketler arasındaki hatayı en aza indirmek için denetimli bir öğrenme yöntemi kullanılmaktadır. Makine öğreniminde denetimli ve denetimsiz öğrenme, problemin türüne ve verilerin durumuna bağlı olarak seçilmektedir.[79] Farklı veri setleri arasında karşılaştırmalar yapmak için ölçek bağımlılığı nedeniyle, MAE ve RMSE, farklı ölçekler veya birimlere sahip veri setleri arasında tahmin doğruluğunu karşılaştırmak amacıyla birlikte kullanılabilir. Bu çalışmada, ham veri seti üzerinde veri manipülasyonu gerçekleştirilmektedir. ARIMA, SARIMA, Doğrusal Regresyon ve XGBoost modellerinin performansı, veri varyansını etkileyen 2018 ve 2022 yıllarının hariç tutulmasıyla iyileştirilerek gözlemlenmektedir. Diğer yandan, COVID-19 pandemisinden etkilenen yılların hariç tutulması, XGBoost modelinin etkinliğini artırmaktadır. Bu karşılaştırma, modellerin veri setindeki şoklara nasıl tepki verdiğine dair içgörüler sağlamaktadır; ancak tahmin doğruluğunu artırmak ve ilk sonuçları kıyaslamak amacıyla veri seti temizlenmektedir. Makine

öğreniminde denetimli ve denetimsiz öğrenme arasındaki seçim, problemin doğasına ve verilerin özelliklerine bağlıdır. [80] Bu nedenle, mevcut literatüre uygun olarak tüm veri setini temizlenmektedir.



Şekil 2.13: ARIMA(1,1,1) Sarı Humma Artık Değeri ve Gözlem Sırası Grafiği.

Şekil 2.13, Artıklar ve Veri Sırası: Artıkların sıralama grafiği, artıkların birbirleriyle ilişkili olmadığı varsayımını doğrulamak için kullanılmaktadır. Sarıhumma aşısı verilerinin analizi, artıkların sıfır etrafında rastgele dağıldığını göstermektedir; bu durum, hata terimleri arasında bazı ilişkilerin olabileceğini önermektedir. Varyans, veri görselleştirmede kritik bir rol oynamaktadır; varyans arttıkça, artıkların da artma eğiliminde olduğu açıktır. Ancak, bu durum yalnızca veri setimizin bir özelliği olabilir. Bu nedenle, çalışmanın ikinci paragrafında veri setimizde yüksek artıkların bulunduğu yıllar (2018 ve 2022) hariç tutulmakta ve modelin performansı yeniden değerlendirilmektedir. Bu yıllarda Türkiye ve hastalığın ev sahibi ülkelerle yapılan ziyaretlerin etkili olduğu gözlemlenmektedir. Ayrıca, yapının merkezi olarak yönetildiği ve ihale edildiği hususlar bulunmaktadır. Yöneticiler, kurum içi stok hareketlerinin organizasyon için daha uygun olduğunu ve toplu alım ve kuruma bağlı alt birimlere dağıtım yapıldığını belirtmektedir. Sonuç olarak, yalnızca sarıhumma üzerine odak-

lanarak tek bir merkezden toplu alımları tahmin etmeye karar verilmiş ve veriler yeniden işlenmiştir. COVID-19 pandemisi, veri setinde son on yılda gözlemlenen eğilimlerin bozulmasına yol açmaktadır. Bu dönemin hariç tutulmasının sonuçları analiz edilmekte ve veri setinin temel yapısı hakkında ön bilgiler sağlanmaktadır.[81] Varyans, farklı eğitim setleri kullanarak yapılan tahminlerin tutarsızlığını ölçme yeteneğine sahiptir. Varyans, farklı eğitim verileri kullanıldığında hedef fonksiyonun tahmininin ne kadar değişeceğini gösterir. Varyans, rastgele bir değişkenin beklenen değerinden ne kadar saptığını tanımlar. Bu nedenle, bir makine öğrenimi modelinde yanlılık ve varyansı dengelemek, verimli performans için kritik öneme sahiptir. Bir modeli karmaşık hale getirmek, varyansı artırarak yanlılığı azaltır; bu durum aşırı uyum riskini artırır. Öte yandan, varyansı azaltmak için modelinizi basitleştirmek, yüksek yanlılık nedeniyle düşük uyum ile sonuçlanabilir. Burada uyum, doğru tahmin aralığını ifade eder. Ancak, bu her zaman aşırı öğrenme anlamına gelmez; çünkü veri setinde ani değişiklikler ve farklı nedenlerle tarihsel verilerle örtüşen kalıplar bulunabilir. Aşı stok oranının kritik önemi göz önüne alındığında, bu gizli ilişkileri ve farklılıkları daha tarafsız bir şekilde yakalayan bir model seçmek son derece önemlidir. Yanlılık ve varyans, bir modelin genel tahmin hatasına katkıda bulunur. Yanlılık, bir modelin tahmin yaparken yaptığı varsayımlardaki hatayı ifade eder. Yüksek yanlılık gösteren bir model, verilerdeki temel kalıpları yakalamak için çok basit kalır ve bu da yanlış tahminlere yol açar. Ancak, karmaşık bir model, karmaşık veri kalıplarını yakalayabilir ve yanlılığı azaltabilir. Ayrıca, varyans, modelinizin tahminlerinin farklı bir veri setinde eğitildiğinde ne kadar değişeceğini gösterebilir. Yüksek varyanslı modeller, eğitim verilerine çok yakın bir şekilde uyum sağlama eğilimindedir ve bu da aşırı uyuma yol açar. Sonuç olarak, bu modeller test veri setinde başarılı olamazlar. Bu ön çalışmalar, varyans-yanlılık dengesinin model başarısını nasıl tekilediğini kabaca göstermek amacıyla yapılmaktadır.[82]

Aşağıdaki tablo, aşı sayılarının toplamını (Count), ortalamasını (MEAN), standart sapmasını (STD), minimum (MIN) ve maksimum (MAX) aşı sayılarını, ayrıca 0,25 çeyrek, 0,5 medyan ve 0,75 çeyrek değerlerini içermektedir. Tanımlayıcı istatistikler veri setimizi daha iyi anlamamıza ve analiz etmemize yardımcı olmaktadır. Ayrıca, bütün-parça mantığının kurulmasına olanak tanımaktadır. Bu nedenle, her çalışma öncesinde veri setinin tanımlayıcı istatistik tablosunun incelenmesi önerilmektedir.

Tablo 2.5: Tüm Veri Setinin Tanımlayıcı İstatistiği.


Name	Year	Month	Numb Used
COUNT	75.806,000000	75.806,000000	75.806,000000
MEAN	2.016,042305	6.605,625	4.816,927
STD	4.973,276	.463,499	7.253,488
MIN	2003,00000	1000,00	1000,00
MAX	2023,000	120,0000	340,00000
0,25	2013,00000	400,000	1000,00
0,5	2017,00000	700,000	2000,00
0,75	2020,00000	1000,000	5000,00

Tablo 2.5, bu çalışmada kullanılan 21 yıllık aş tüketim verileri ile makine öğrenimi kütüphaneleri kullanılarak oluşturulan tanımlayıcı istatistikleri göstermektedir. Bu tablo, 'veri hazırlama' bölümünde açıklandığı gibi veri setimizle uyumludur.

Tablo 2.6: Tüm Veri Setinde Eğitilen Modellerin Başarı Sıralaması.

Prediction Success Ranking	Name	RMSE	MAE
1	ARIMA	5.235830	3.326563
2	SARIMA	5.645231	3.536450
3	Linear Regresyon	7.299186	4.444227
4	XGBoost	7.325176	4.457684


Tablo 2.6, tüm ham veri seti üzerinde modellerin tahmin performanslarını göstermektedir. Veri setimiz üzerinde mevsimsellik sorgusu, durağanlık testi ve gerekiyorsa durağanlaştırma yapılmamıştır. ARIMA modeli en iyi performansı gösteren modeldir; ancak yukarıda belirtilen bilgiler ışığında, araştırmalara devam edilerek varyans-önyargı dengesinin sonuçları nasıl etkileyebileceği incelenmektedir. Bu nedenle, işlenen veri seti üzerinde model başarılarının tepkisi ve ayrıca varsa gizli örüntüler ile veri frekansının durumu araştırılmaktadır. Bu öğrenme süreci, veri işleme hızı ve ön hazırlık gereksinimleri, dengeli öğrenme kriterlerinin kurumsal stratejilere göre stok yönetimi için kullanılacak model seçimini etkilemektedir.



Şekil 2.14: Sarı Humma Aşısı Yoğunluk.


Tablo 2.5’te sunulan tanımlayıcı istatistiklerdeki veriler, çekirdek pik noktaları ile birlikte Şekil 2.13’de kutu grafiği şeklinde gösterilmektedir. Şekil 2.14, verilerden tahmin edilen bir histogramın düzenlenmiş halini göstermektedir. Bu yöntemde, her bir veri dağılımı için sürekli bir eğri (çekirdek) çizilir ve ardından bu eğriler, tek bir düzgün dağılım tahmini yapmak amacıyla birleştirilir. Kutu grafiği, beş temel istatistiksel özet (minimum, birinci çeyrek (Q1), medyan, üçüncü çeyrek (Q3) ve maksimum) temelinde verilerin dağılımını göstermenin standart bir yöntemidir. Medyan (%50 çeyrek), bir veri setindeki kayıtların ortasında bulunan değeri ifade eder. Birinci çeyrek (%25), medyan ile minimum değer arasındaki noktayı belirtir. Üçüncü çeyrek (%75) ise, medyan ile maksimum değer arasındaki konumu gösterir. Çeyrekler arası aralık (IQR), birinci ve üçüncü çeyrek arasındaki değerleri kapsar. Maksimum değer, üçüncü çeyrek artı IQR'nin 1,5 katı ile hesaplanır. Üçüncü çeyrek + IQR * 1,5 = maksimum değer. Minimum değer ise, birinci çeyrek eksi IQR'nin 1,5 katı ile belirlenir. Birinci çeyrek - IQR * 1,5 = minimum değerdir. Testin ayırt edici gücünün belirlenmesine, çeşitli testlerin etkinliğinin arttırılması, karşılaştırılmasına ve uygun pozitiflik eşiğinin belirlenmesine olanak tanırken veri seti yoğunluğu önemlidir. Verinin ortalamaya ve sabit değere varyansın yaklaşması, geçmişi ile şimdiki arasındaki kovaryansı, birbirleri ile ilişkisi, dalgalanmalar, rassallık araştırmaları devam etmektedir.

Aykırı değerler, hesaplanan minimum ve maksimum değerlerin dışında kalan veriler olarak tanımlanır.[67]




Şekil 2.15: ARIMA Modeli Gerçek Verilere Karşı Model Tarafından Tahmin Edilen Aşı Verilerinin Grafiği.

Şekil 2.15’te, ilk yapılan ham veri model karşılaştırmasında, ARIMA modeli en başarılı tahmin üreten model olarak belirlenmiştir. Gerçek veri mavi, ARIMA tarafından tahmin edilen ise kırmızı çizgi ile gösterilmektedir. Dengeli, güvenilir, hızlı ve ön işlem gerektirmeyen, mikro hizmetlere uyumlu modelin araştırılmasına devam edilmektedir. Diğer yandan, veri varyansı, model varyansı ve uyumu ele alınmaktadır. Bu amaçla, modellerin tahmin güven aralıkları da ayrıca incelenmektedir. İlk incelemede, Kök Ortalama Kare Hatası 5.223 olarak bulunan ARIMA, elimizdeki işlem tesis edilmeyen sete uygulanmaktadır. Sonraki aşamalarda, veri setine durağanlık, mevsimsellik ve döngüsellik araştırması yapılmaktadır. Çünkü uygulanan bir çözümün ömrünün uzatılması, bir çözümün sürekliliğinin artırılması, yeni hizmet türlerinde esneklik ve çevikliğin sağlanması, sistem kabiliyet ve kapasitesinde esnekliğin düşük maliyetle sağlanması, sistem, donanım ve yazılım sürekliliğinin garanti altına alınması, insanın sürekliliğinin sağlanması için göstergeler tasarlanırken hizmet sağlayıcılar tarafından alternative tüm optimal çözümlerin ele alınması gerekmektedir.



Şekil 2.16: SARIMA Öncesi RMSE Sonuçları.



Şekil 2.17: Tüm Ham Veri RMSE and MAE Scorlar Grafiği.

(Mevsimsellik ve Durağanlık Test Öncesi)

Ham veriler üzerinde yapılan ilk çalışma sonuçları ve görsel karşılaştırmalarda ARIMA modelinin başarılı olduğunu göstermektedir. Ancak ARIMA modelinin başarılı olup SARIMA modelinin başarısının düşük olması sezgisel olarak mevsimsellik içerebileceği ve veri setinin durağan olmağı izlenimi yaratmaktadır. Ayrıca bu ön çalışma veri frekansı hakkında bilgiler vermektedir. Örneğin 2018 ve 2022 yıllarda günlük ani dalgalanmalar olduğu görülebilmektedir. Diğer yandan COVID-19 dönem, seyahat kısıtları ve sonrası görülen günlük negative ve pozitif ani aşılama sayıları veri setinin daha fazla araştırılmasına yönelik ip uçları vermektedir.

Tablo 2.7: COVID-19 Salgın Hariç Tanımlayıcı İstatistikler.

Name	Year	Month	Numb Used
COUNT	64.053,000000	64.053,000000	64.053,000000
MEAN	2.01,032676	6.597,099	5.042,496
STD	4.759,360	3.469,617	7.554,339
MIN	2003,00000	1000,00	1000,00
MAX	2023,000	120,0000	3400,00000
0,25	2012,00000	4000,00	1000,00
0,5	2016,00000	7000,00	2000,00
0,75	2018,00000	1000,000	5000,00


Tablo 2.7, 19 yıllık makine öğrenimi kütüphaneleri kullanılarak oluşturulmuş tanımlayıcı istatistikler tablosu. (Dışlanmış yıllar 2021-2022)

Tablo 2.8: COVID-19 Hariç Tutulduğunda Modellerin Başarı Sıralaması.

Prediction Success Ranking	Name	RMSE	MAE
1	XGBoost	7.470880	4.484898
2	Linear Regresyon	7499567	4.504220
3	ARIMA	13.625819	13.234018
4	SARIMA	15.501631	15.079305

Tablo 2.8, 2021-2022 döneminde tüm veriler hariç tutularak yapılan modellerin karşılaştırma sonuçlarını göstermektedir. COVID-19 döneminin sona ermesinin ardından model tahmin başarısındaki sıralamanın değişimi, verilerimizin zaman serisi özellikleri gösterebileceğini ortaya koymaktadır. Zaman serisi analizinde veri setinin azalmasıyla birlikte modellerin tahmin doğruluğunun düşebileceği bilinmektedir. Çalışmanın ilk bölümündeki amaç, örüntü değişimini, bilginin içinde barındırdığı korelasyonları ve nihayetinde varyansı, yani

farklı veri setlerine olan tepkisini ölçmektir. Modelin gücü, farklı veri setlerindeki tahmin sayılarının, ilişkisel ya da rastgele olaylar ve gürültüye bağlı olarak adaptasyonu ile değerlendirilmektedir. Modellerin verimli ve etkin, optimal tahminleme yapabilmesi için ön koşullar ve bileşenleri çözümlenerek uyarlanmaktadır. Model değerlendirmelerinde en iyi uyum, aşırı öğrenme ile sonuçlanabilmektedir. Bu durum, kritik sistemlerde nadir görülen ve esas tespit edilmesi gereken olgunun gözden kaçırılması şeklinde sonuçlanabilmektedir.



Şekil 2.18: COVID-19 Hariç Veri RMSE and MAE Scorlar Grafiği.
(Mevsimsellik ve Durağanlık Test Öncesi)

Şekil 2.18’de, ARIMA ve SARIMA modellerinin tahmin yetenekleri olumsuz etkilenmektedir. Araştırmanın bu aşaması yalnızca ön bir içgörü sağlamaktadır. Bu nedenle, verilerin durağanlık testi ve trend analizi daha sağlam kanıtlar ve uygun metodolojiler kullanılarak gerçekleştirilmelidir. Ayrıca hem ARIMA hem de SARIMA modelleri optimize edilmediğinde önemli ölçüde yüksek tahmin hataları verebilmektedir. Veri setinin geliştirilmesinin ve ya genişletilmesinin XGBoost’un tahmin başarısı üzerindeki etkisi neredeyse ihmal edilebilir düzeyde olduğu gözlemlense de MAE değerleri ARIMA için düşüktür. XGBoost yöntemi ile sonuçları etkileyen verilerin artırılması ile başarılı sonuçlar vermesinin mümkün olduğu tahmin edilmiştir. Sonuç olarak, XGBoost daha dengeli bir yaklaşım sergilese de araştırılmaya devam edilmektedir.

Tablo 2.9: Veri Varyansını Bozan Günlük Atak Dönemleri Hariç İstatistikler.

Name	Year	Month	Numb Used
COUNT	63.618000000	63.618000000	63.618000000
MEAN	2.015,264721	6.607,721	4.921,956
STD	4.994687	3.471,794	7.428,063
MIN	2003,00000	1000,00	1000,00
MAX	2023,000	1200,000	3400,00000
0,25	2012,00000	4000,00	1000,00
0,5	2016,00000	7000,00	2000,00
0,75	2019,00000	1000,000	5000,00

Tablo 2.9, 19 yıl boyunca makine öğrenimi kütüphaneleri kullanılarak oluşturulan tanımlayıcı istatistikler tablosu gösterilmektedir. (2018-2022'yi hariç tutun)

Tablo 2.10: Varyansın Etkisi Elimine Edilince Modellerin Başarı Sıralaması.

Prediction Success Ranking	Name	RMSE	MAE
1	ARIMA	4.484905	2.808609
2	SARIMA	4.495663	2.948647
3	Linear Regresyon	6.857869	4.265423
4	XGBoost	6.889378	4.284786

Tablo 2.10, 2018-2022 yıllarını veri setinden hariç tutan model karşılaştırmasını sunmaktadır. Bu tablo, belirtilen yıllar hariç tutulduğunda modellerin tahmin doğruluğunun arttığını göstermektedir. 2018 ve 2022 yıllarındaki toplam aşı kullanımı, son on yılda gözlemlenen kalıplarla uyum içindedir. Ana ayırım, Şekil 6'da gösterilen sezgisel sonuçlarda belirgin bir şekilde ortaya çıkmaktadır; bu şekil, ARIMA modelinin tahmin varyansını illüstre etmektedir. 2018 ve 2022 verileri, artıklar nedeniyle meydana gelen ani günlük dalgalanmalar göstermekte olup, bu durum başlangıç tahminlerindeki varyansı bozmaktadır. Sonuç olarak, bu yıllar hariç tutulduğunda hem ARIMA hem de SARIMA modelleri geliştirilmiş bir performans sergilemektedir. COVID-19'dan etkilenen yıllar için zaman serisi modelleri, önceki on yıldan gelen veri kalıplarına dayanabilir ve verilerdeki dalgalanmalara daha duyarlı hale gelebilir. Ayrıca, veri setindeki azalmalar veya veri toplama işlemini durduran sistemik kesintiler de zaman serisi tahminlerini etkileyebilmektedir. Bu zorluklarla karşılaşan sistemler

de, dengeli yaklaşımları nedeniyle XGBoost tercih edilebilir. Kullanılan model ne olursa olsun, onu optimize etmek kritik öneme sahiptir. Çalışmanın devamında, durağanlık, mevsimsellik ve beyaz gürültü için tüm verilerin temizlenmesiyle en iyi tahmin modeli tekrar belirlenmektedir.[58]


2.4.17 Sarı Humma Aşılama Kapsamı Zaman Serisi Analizleri

Şu ana kadar yapılan ön çalışmalarda ARIMA(1,1,1) modeli kullanılmaktadır. Otoregresif Entegre Hareketli Ortalama (ARIMA), bir zaman serisinin gelecekteki değerlerini geçmiş değerlerinin lineer kombinasyonu ve bir hata terimi kullanarak tahmin etmektedir. Tahmin analizleri kapsamında, ARIMA modelinin veri setine uygulanıp uygulanamayacağını belirlemek, verilerin durağan veya durağan olmayan ve tek değişkenli olduğu durumlarda, her türlü veri modeli ile, yani trend, mevsimsellik ve döngü ile uygun bir durumdur. ARIMA modeli, kısa vadeli tahminler için önerilmektedir ve yalnızca tek değişkenli veri tahmini için kullanılmaktadır. AR, MA ve ARMA modelleri hakkında kısaca bilgi vermek gerekirse, AR ve MA, doğrusal durağan stokastik ARMA modelinin özel halleridir ve bu modeller, durağan zaman serilerinin analizinde kullanılmaktadır. Ancak, gerçek dünya verileri çoğunlukla durağan değildir. Bu durumda, eğer seri (örneğin, farkı alınarak) durağan hale getirilebiliyorsa, ARIMA gibi yöntemler uygulanabilir. Bir diğer Box-Jenkins yöntemi ise mevsimsel eğilimleri modellememizi sağlayan SARIMA (Mevsimsel Otoregresif Entegre Hareketli Ortalama) modelidir; bu model, ARIMA modelinin mevsimselliğe karşı dirençli bir versiyonudur.[70] Akaike Bilgi Kriteri'nin önerdiği ilk çalışma sonuçları ile ARIMA (5,1,0) için Ljung-Box ve JB değerleri gösterilmektedir. Başlangıçta önerilen p, d, q değerleri, veri setinin zaman serisi gereksinimlerine göre hazırlanmadan gösterimidir ve bu gösterim, uygun p, q, d değerlerinin belirlenemediğini ve bu nedenle yeniden tanımlanması gerektiğini ortaya koymaktadır. Ayrıca, modelin ARIMA ile başarılı sonuçlar vermesine rağmen, eğitilmeye devam edilmesi gerektiğini göstermektedir. Modellerin tek seferde işleme alınması veya ilk araştırmanın çeşitli senaryoları ele alınarak konumlandırılması, çalışma sonunda atıl kapasite veya kaynak kullanım kapasitesinin artması gibi olumsuz durumları ortadan kaldırılabılır. Veri setimizin analizi için bir dizi grafiklerle görselleştirilmesi ve sezgisel olarak izlenen değişimin çeşitli istatistiksel hipotezlerle kanıta dayalı olarak incelenmesi gerekmektedir. Zaman serisinde trend, durağanlık ve verideki yapısal ya da yapısal olmayan gürültü modeli önemlidir. Gürültü ile başa çıkabilmek için dönem atlama, sinyal aralığı belirleme, veri

frekansını küçültme, temel bileşen analizi ve birliktelik modelleri gibi yöntemler tercih edilebilir. Artık değerlerin birbirleriyle ilişkisi yapısal olabilir; yapısal olmayan konjonktürel olaylar ise veri kalitesini ve modelin başarı sonuçlarını etkileyebilir. Kütüphane isimlendirilmesinde SARIMA modeli, SARIMAX olarak isimlendirilmişim ve tablonun ekran görüntüsü aşağıda yer almakta olup çalışmaya devam edilmektedir.

SARIMAX Results						
Dep. Variable:		NumbUsed		No. Observations:		112656
Model:		ARIMA(5, 1, 0)		Log Likelihood		388455.596
Date:	Mon, 08 Apr 2024			AIC		776923.192
Time:	22:00:50			BIC		776980.985
Sample:		0		HQIC		776940.637
		- 112656				
Covariance Type:		opg				
	coef	std err	z	P> z	[0.025	0.975]
ar.L1	-0.7017	0.000	-3540.234	0.000	-0.702	-0.701
ar.L2	-0.4915	0.000	-1515.420	0.000	-0.492	-0.491
ar.L3	-0.3420	0.000	-916.804	0.000	-0.343	-0.341
ar.L4	-0.2294	0.000	-544.506	0.000	-0.230	-0.229
ar.L5	-0.1222	0.000	-346.280	0.000	-0.123	-0.121
sigma2	57.8895	0.006	8956.749	0.000	57.877	57.902
Ljung-Box (L1) (Q):			22.23		Jarque-Bera (JB):	38609025998.32
Prob(Q):			0.00		Prob (JB):	0.00
Heteroskedasticity (H):			1.38		Skew:	30.68
Prob(H) (two-sided):			0.00		Kurtosis:	2870.31

Şekil 2.19: İlk SARIMA Sonuçları. (Mevsimsellik Etkisi ve Durağanlaştırılmadan)



Şekil 2.20: Mevsimsel Aşıların Sayısının Zamanla Değişimi.

Ancak, diğer p, d ve q değerleri aşağıda kontrol edilmektedir. Öncelikle, Mann-Kendall testi ile trend ve mevsimsellik analizi gerçekleştirilmektedir. Trend analizi, verileri incelemek ve gözlemlemek iyi bir başlangıçtır. Trendler ve mevsimsel değişiklikler, veri özelliklerini anlamak için görselleştirilir. Mann-Kendall Trend Testi ve Kendall Tau Testi, zaman serisinde bir trend olup olmadığını belirlemek amacıyla trend analizi yapılmaktadır.


Tablo 2.11: Mann-Kendal ve Tau Test Sonuçları.

Tau Value	2.5323317975242465
p value	2,55437E-36
Annual Total	1728

Tablo 2.11, Mann-Kendall testi sonuçlarına dayanarak, Tau Değeri'nin (2.532) pozitif bir eğilim gösterdiğini, yani zamanla aşı sayısında genel bir artış eğilimi olduğunu belirtmektedir. p-değeri (2.55e-36) oldukça küçük bir değerdir; bu da bu eğilimin istatistiksel olarak anlamlı olduğu anlamına gelir. Diğer bir deyişle, zaman serisinde gözlemlediğimiz artan eğilim rastgele değildir ve istatistiksel olarak anlamlı bir artış eğilimini yansıtmaktadır. Bu sonuçlara dayanarak, seride belirgin bir eğilim olduğu sonucuna varabiliriz. Bu nedenle, modelleme işlemine geçmeden önce trend bileşenini ortadan kaldırmak için dönüşümler ve ya fark alma işlemleri gerekebilir.

Durağanlık Testi

Serinin ilk farkını alarak gerçekleştirdiğimiz istasyonlaştırma süreci, seriyi trend etkisinden arındırmakta ve durağan hale getirmektedir. Burada yaptığımız işlem, mevsimsel olmayan bir fark alma işlemidir. Ancak, seri hâlâ mevsimsellik etkisi altındadır. Bu nedenle, ARIMA A modelinin mevsimsellikten arındırılması gerekmektedir. Önemli bir konu, 'p' ve 'q' değerlerinin nasıl belirleneceğidir. Bu değerleri belirlemek için iki grafik kullanılmaktadır. Artık kalıntı verilerini Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF) ile analiz ederek ve buradan elde edilen değerler doğrultusunda SARIMA modeline yerleştirilerek, verilere uygun bir tahmin modeli oluşturmak mümkündür.



Şekil 2.21: Mevsimsel Fark Alınmış ADF ve PACF Grafiği.

Şekil 2.21, serinin ilk farkını alarak gerçekleştirdiğimiz durağanlaştırma süreci, seriyi trend etkisinden arındırır ve durağan hale getirir. Zaman serisi analizlerinde durağanlığı kontrol etmek için, birim kök testleri olan Genişletilmiş Dickey-Fuller ve KPSS (Kwiatkowski-Phillips-Schmidt-Shin) testleri uygulanmaktadır.[67] Burada yaptığımız işlem, mevsimsel olmayan bir fark alma işlemidir. Ancak, seri hâlâ mevsimsellik etkisi altındadır. Bu durumda, kuracağınız ARIMA modeli muhtemelen iyi performans göstermeyecektir. SARIMA modeli, ARIMA modelindeki mevsimsel olmayan bileşenlere (p, d, q) ek olarak mevsimsel bileşenler (P, D, Q) içerir. Mevsimsel bileşenler; otoregresif sırası, fark alma sırası, hareketli ortalama sırası ve dönem sayısını temsil etmektedir.

Tablo 2.12: İlk ADF ve KPSS Sonuçları.

ADF Test	-2,42402E+15
ADF p-value	0.13507092854242148
KPSS Test	1.5653769655963758
KPSS p-value	0.01

Tablo 2.12, ADF ve KPSS test sonuçlarını göstermektedir. ADF Test Sonuçları ve Test İstatistiği: -2.424, p-değeri: 0.135. ADF testinde p-değerinin 0.05'ten büyük olması nedeniyle, serinin durağan olmadığını söyleyebiliriz. KPSS Test Sonuçları: Test İstatistiği: 1.565, p değeri: 0.01. KPSS testinde p-değerinin 0.05'ten küçük olması, serinin durağan olduğunu göstermektedir. Her iki testin sonuçları, serinin durağan olmadığını ortaya koymaktadır. Bu

nedenle, seriyi durağan hale getirmek için birinci dereceden fark alma işlemi uygulanmaktadır.[71] Tablo 2.12 den sonra fark alma işlemi uygulanmaktadır. Aşağıdaki Tablo 2.13, ADF Test Sonuçları ve Test İstatistikleri: ADF test istatistiği -5.306'dır, p-değeri ise 5.31e-06'dır. Bu p-değeri, 0.05'ten küçük olduğu için incelenen birinci farkın durağan olduğunu göstermektedir. KPSS Test Sonuçları ve Test İstatistikleri: KPSS test istatistiği 0.130'dir, p değeri 0.1'dir. KPSS testinde p-değerinin 0.05'ten büyük olması, serinin durağan olduğunu göstermektedir. Bu sonuçlar, birinci fark serisinin durağan olduğunu doğrulamaktadır.

Tablo 2.13: Fark Alma İşlemi Sonrası ADF ve KPSS Sonuçları.

ADF Test	-2,42402E+15
ADF p-value	0.13507092854242148
KPSS Test	1.5653769655963758
KPSS p-value	0.01

Tablo 2.13, fark alma işlemi sonrası sonuçları göstermektedir. Modellemeye geçmeden önce veride beyaz gürültü olup olmadığı araştırılmaktadır.[73]

Beyaz Kutu Testi

Beyaz gürültü zaman serisi modellerinde, özellikle ARIMA gibi modellerde önemli kavramdır. Güvenilir tahminler yapmak için modelin kalitesini değerlendirmek ve beyaz gürültü varsayımının geçerliliğini kontrol etmek önemlidir. Bunun için Ljung-Box testi kullanılmaktadır. Bu test, bir dizi gözlem değeri arasındaki otokorelasyonun istatistiksel olarak anlamlı olup olmadığını değerlendiren bir yöntemdir. SARIMA (0,1,2)(0,1,2,12) en iyi uyum sağlayan p, q, d değerleri olduğundan beyaz gürültü testine tabi tutulmaktadır.

Tablo 2.14: Beyaz Gürültü Ljung-Box Test Sonuçları.

lb_stat	lb_value
4451665	0.92468

Tablo 14'e baktığımızda, p-değerlerinin anlamlılık seviyesinden (0.05) büyük olması nedeniyle hatalar arasında önemli bir otokorelasyon olmadığı kabul edilmektedir. AIC ve BIC değerleri, modelin uyumunu değerlendirmemize yardımcı olurken, Ljung-Box testi artıkları

n beyaz gürültü olup olmadığını test etmektedir. Burada, Ljung-Box testi sonuçlarına göre, p-değerinin (0.89) büyük olması, artıkların rastgele dağıldığını ve modelin verilere iyi uyduğunu göstermektedir. Bir sonraki adımda, Ljung-Box Testi daha ayrıntılı bir şekilde tartışılacak ve modelin performansını daha iyi değerlendirmek için analiz edilecektir. Ayrıca, SARIMA ve ARIMA modellerini karşılaştırmak için RMSE ve MAE gibi performans metrikleri de kullanılabilecektir.

AIC Değerleri ile Uygun (p, d, q) Değerlerinin Seçimi

Tablo 2.15: AIC Sonuçları.

SARIMA(1,1,1)(1,1,1,12)	3,46362E+14
SARIMA(0,1,2)(0,0,0,12)	3,66223E+15
SARIMA(0,1,2)(0,1,2,12)	3,45862E+15
SARIMA(0,1,1)(1,1,0,12)	3,67516E+14
SARIMA(1,1,1)(0,1,1,12)	3,64829E+13
SARIMA(1,1,0)(0,1,1,12)	3,66757E+14
ARIMA (0,0,1)	3,75351E+14
ARIMA (0,1,2)	3,61223E+15
ARIMA (1,1,1)	3,84287E+15
ARIMA (1,1,2)	4,05351E+15
ARIMA (1,0,2)	3,96588E+15
ARIMA (2,0,2)	4,05388E+15

Tablo 2.15, SARIMA ve ARIMA için AIC değerlerini göstermektedir. BIC (Bayesian Information Criterion) değeri, AIC (Akaike Information Criterion) gibi alt modellerin belirlenmesi amacıyla kullanılırken, aynı zamanda modelin adaptasyonu, uyumu ve karmaşıklığı arasındaki dengeyi anlamamıza yardımcı olmaktadır. Modellerin karmaşıklığı arttıkça, genelleme yapma olasılıkları da artabilmektedir. Ortalama mutlak hata veya kök ortalama kare hatası değerlerinin düşmesi, modelin başarılı olduğu yönünde bir karar alınmasına neden olabilmektedir. Ancak aşırı uyum, nadir görülen durumlar ve yapısal olmayan durumlarda, bu tür olayların yakalanmasını engelleyebilir. Örneğin, nadir görülen hastalıklarda aşırı genelleme yapan bir model, hastalığın tespit edilememesine yol açabilir. Gizli kalıpların veya örüntülerin, etiketsiz bir dizi ilişkiyi yakalayamaması, kullanılan sistemde ciddi sorunlara neden olabilir. Bu nedenle, modellerin başarı kıyaslamasında tahmin hata oranı bir avantaj

haline dönüştürülmektedir. Ortalama mutlak hata, tahminin ortalama değere olan pozitif farkının uzaklığını göstermektedir. Uzaklıklar arasındaki aralığın alt ve üst sınırlarının eksen etrafında dağılımından yola çıkarak, tahmin değerlerinin varyansı ve varyansın dağılımı diğer matematiksel modellere girdi oluşturabilmektedir. Malzeme veya hizmetin kritiklik derecesi ve risk öncelikleri, kurumun stratejilerine göre farklılık göstermektedir. Bu aralığın tahmin değerlerine uzaklığı, yine seçilen ve kuruma uygun bir dağılım eğrisine göre, kurumun stratejilerine bağlı olarak kullanılabilir.

SARIMAX Results						
=====						
Dep. Variable:	Numbers		No. Observations:		252	
Model:	SARIMAX(1, 1, 1)x(1, 1, 1, 12)		Log Likelihood		-1726.554	
Date:	Mon, 11 Nov 2024		AIC		3463.107	
Time:	11:39:09		BIC		3480.490	
Sample:	01-01-2003		HQIC		3470.112	
	- 12-01-2023					
Covariance Type:	opg					
=====						
	coef	std err	z	P> z	[0.025	0.975]

ar.L1	0.1441	0.115	1.254	0.210	-0.081	0.369
ma.L1	-0.6192	0.096	-6.454	0.000	-0.807	-0.431
ar.S.L12	0.1328	0.067	1.993	0.046	0.002	0.263
ma.S.L12	-0.9900	0.544	-1.820	0.069	-2.056	0.076
sigma2	9.733e+04	4.96e+04	1.962	0.050	85.840	1.95e+05
=====						
Ljung-Box (L1) (Q):	0.02	Jarque-Bera (JB):		53.30		
Prob(Q):	0.89	Prob(JB):		0.00		
Heteroskedasticity (H):	2.24	Skew:		-0.08		
Prob(H) (two-sided):	0.00	Kurtosis:		5.31		
=====						

Şekil 2.22: SARIMAX(1,1,1)(1,1,1,12) Sonuçları.

Tablo 2.16: SARIMA ve ARIMA'nın Ham Veri ve İşlenmiş Veri Seti Üzerindeki Başarıları.

Prediction Success Ranking	Name	RMSE	MAE
1	Processed Data Data ARIMA(0.1.2)	5,67082E+15	2,64466E+13
2	Processed Data SARIMA(0,1,2)(0,1,2,12)	5,62821E+15	2,67061E+13
3	Processed Data SARIMA(1,1,1)(1,1,1,12)	3,44863E+15	2,95412E+13
4	Processed Data ARIMA(1,1,1)	4,97443E+15	4,12795E+13
5	Raw Data ARIMA(1,1,1)	5,6587E+15	3,32656E+13
6	Raw Data SARIMA(1,1,1)(1,1,1,12)	5,64523E+15	3,53645E+13


Tablo 2.16, hem veri temizleme öncesi hem de sonrası ARIMA ve SARIMA modellerinin tahmin sonuçlarını sunmaktadır. Bu tablo, ham verilerin herhangi bir durağanlaştırma işlemi yapılmadan ve yapıldıktan sonraki modellerdeki iyileşmeyi göstermektedir. Tüm modellerin MAE (Ortalama Mutlak Hata) değerleri düşmektedir. Ancak, MAE değerinin aşırı düşmesi her zaman modelin doğru tahminlerde bulunduğu anlamına gelmemektedir; bu durum aşırı uyum problemini beraberinde getirebilir. Aşırı genelleme yapan bir model, verinin kendine has örüntülerini gözden kaçırmamıza ve asıl bulunmak istenen desenin kaybolmasına neden olabilir. Örneğin, aşı komplikasyonlarına bağlı nadir görülen bir hastalığın araştırılmasında bu durum sakıncalı olabilir.

Tablo 2.17: Mevsimsellikten Arındırılan ve Durağanlaştırılan Veri Setindeki Modellerin Başarı Sıralaması.

Prediction Success Ranking	Name	RMSE	MAE
1	ARIMA(0.1.2)	5,67082E+15	2,64466E+15
2	SARIMA(0.1.2)(0,1,2,12)	5,62821E+15	2,67061E+15
3	XGBoost	6,84441E+16	4,214E+15
4	Linear Regresion	6,85687E+15	4,224E+15

Tablo 2.17'de, MAE minimize edildiğinde, uyum medyana daha yakın ve yanlı olabilir. SARIMA(0.1.2)(0,1,2,12) için MAE 2,6'dır. MAE'nin düşük olması aşırı uyumun sorgulanması gerektiğini göstermektedir. Bu nedenle çalışma için en uygun alt model, RMSE'yi minimize eden SARIMA(1,1,1)(1,1,1,12) olarak belirlenmektedir.

Kök Ortalama Kare Hatası (RMSE), birkaç önemli hata üreten bir modelin gerçek performansını etkili bir şekilde yansıtabilir; bu, birçok küçük hata üreten bir modelle karşılaştırıldığında geçerlidir. Yanlılık ve yanlılık dengesi ile çapraz doğrulama sonuçları dikkate alındığında, hem MAE hem de RMSE değerleri nedeniyle model SARIMA (1,1,1)(1,1,1,12) olarak belirlenmektedir. Öte yandan, aynı modelin veri seti bölünerek çapraz doğrulama yapılmaktadır. Bu yöntemle modelin aşırı öğrenmesi önlenmeye çalışılmaktadır. Yukarıdaki örnek göstergeler ve daha fazlası işletmenin operasyonel ve finansal tablolarından elde edilen verilerle hesaplanarak kurumsal karne, kalite ve verimlilik çalışmalarında ilgili personel grubunun yetkisine göre kullanılmaktadır.



Şekil 2.23: SARIMA(1,1,1)(1,1,1,12) Sarı Humma Artık Değeri ve Gözlem Sırası Grafiği.

Şekil 2.23, lb_stat: 4.451665, p-değeri (lb_pvalue): 0.92468. Bu sonuçlar, kalıntıların rastgele dağıldığını ve modelin verilere iyi uyduğunu göstermektedir.

Ljung-Box testindeki yüksek p-değeri (0.92), kalıntıların beyaz gürültü olarak kabul edilebileceğini ortaya koymaktadır. Bu durum, modelimizin iyi bir uyum sağladığını göstermektedir. Kalıntılar ile veri sırası arasındaki ilişkiyi incelemek için kalıntı ile sıralama grafiği kullanılmaktadır; bu grafik, kalıntıların birbirleriyle ilişkisiz olduğu varsayımını doğrulamak amacıyla tasarlanmıştır. Sarıhumma aşı verileri için kalıntıların sıfır etrafında rastgele dağıldığı gözlemlenmektedir. Hata terimlerinin birbirleriyle ilişkili olduğuna dair bir kanıt bulunmamaktadır.

Bu adımdan sonra, oluşturulan SARIMA modeli kullanılarak tahminler yapılabilir ve modelin performansı değerlendirilebilir. Varyans, veri grafiklerinde önemli bir rol oynamaktadır; varyans arttıkça kalıntıların da arttığı gözlemlenmektedir.

Aşırı Öğrenme Eliminasyonu - Çapraz Doğrulama

Zaman Serisi Çapraz Doğrulama, zaman serisi verileri üzerinde modelin performansını değerlendirmek için gereklidir. Zaman serileri, kronolojik olarak sıralanmış verilerdir ve tarihsel verilerin tahmin edilmesinde kullanılır. Bu nedenle, veri sızıntısı riskini azaltmak önemlidir. Modelin geçmişi, verilerin ne kadar iyi uyum sağladığı ve tahmin edebilme yeteneği açısından kritik bir öneme sahiptir. Zaman Serisi Çapraz Doğrulama, modelin aşırı uyum sağlama (overfitting) riskini değerlendirmeyi gerektirir. Eğer model, eğitim verilerine çok iyi uyum sağlıyorsa, test aşamasında da bu uyumun devam edip etmediği incelenmektedir.

Tablo 2.18: SARIMA Aşırı Öğrenme Eğilimi Nedeniyle Modele Çapraz Doğrulama Uygulanması.

Split-1 MSE	3,10077E+15
Split-2 MSE	2,64069E+15
Split-3 MSE	3,12043E+16
Split-4 MSE	2,91059E+15
Split-5 MSE	2,9605E+15
Avarage MAE	2,9518E+15

Tablo 2.18, MAE'yi minimize eden bir tahmin yönteminin medyan tahminlere, RMSE'yi minimize eden bir yönteminin ise ortalama tahminlere yol açtığını göstermektedir. [52]

Tüm veri seti beş parçaya bölünmüş ve artan iterasyonlarla çapraz doğrulama gerçekleştirilmiştir. Bu veri setimizin beşe bölünmesi ile başlanmış, ilk yıllardan itibaren kalıplar ortaya çıkarılmaktadır. Birinci iterasyonun sonunda, ayrıştırılmadan ikinci iterasyon birinci bölüm ile birleştirilerek devam edilmektedir. Veri setinin bölümler halinde bloklanması, bütünleşik bir şekilde ele alınmasını sağlamaktadır.

SARIMA modelinin çapraz doğrulama sonuçları, ortalama MAE değerinin 2,9 olduğunu göstermektedir. Veri setinin ilk yıllarda ikinci on yıla göre görece modeldeki uyumun az olduğu ve verinin artan bir trende sahip olduğu bilinmektedir. Çapraz doğrulamada gözlemlenen yüksek MAE değeri bu durumu açıklamaktadır. Ancak yalnızca MAE değerinin minimize edilmesi yeterli değildir; desen uyumuna da dikkat edilmesi kaçınılmazdır.

Alt Modellerin Sarıhumma Aşı Talep Tahmin Sayıları

Tablo 2.19: SARIMA (1,1,1)(1,1,1,12) Tahmin Sayıları.

2024 January	3193
2024 Feruary	2655
2024 March	2451
2024 April	1640
2024 May	2624
2024 Jun	3176
2024 July	3176
2024 August	3387
2024 September	3712
2024 October	3143
2024 November	3002
2024 December	2589
Avarage Prediction	2895

Tablo 2.19, veri seti durağan hale getirildikten ve mevsimsel olarak temizlendikten sonra en başarılı SARIMA modelinin tahmin sonuçları gösterilmektedir.

Tablo 2.20: ARIMA (0,1,2) Tahmin Sayıları.


2024 January	1965
2024 Feruary	2002
2024 March	2002
2024 April	2002
2024 May	2002
2024 Jun	2002
2024 July	2002
2024 August	2002
2024 September	2002
2024 October	2002
2024 November	2002
2024 December	2002
Avarage Prediction	1999

Tablo 2.20, veri seti durağan hale getirildikten ve mevsimsel olarak temizlendikten sonra en başarılı ARIMA modelinin tahmin sonuçları gösterilmektedir. Ancak tablo on bir ay için 2002 aşı talebi tahmin edildiğini göstermektedir. Özellikle dördüncü aydaki ani aşılama düşüşünün tespit edilemediği ve genlleme yaptığı görülebilmektedir.

Tablo 2.21: SARIMA (0,1,2)(0,1,2,12) Tahmin Sayıları.


2024 January	2099
2024 Feruary	1869
2024 March	1877
2024 April	1559
2024 May	1876
2024 Jun	2073
2024 July	2047
2024 August	2038
2024 September	2181
2024 October	2130
2024 November	2055
2024 December	1930
Avarage Prediction	1978

Tablo 2.21, veri seti durağan hale getirildikten ve mevsimsel olarak temizlendikten sonra en başarılı SARIMA modelinin tahmin sonuçları gösterilmektedir. Tahmin sayıları incelendiğinde, alt modellerden ARIMA'nın tahmin sayılarının düşük ve benzer olduğu görülmektedir. Gerçek veri setinde dördüncü ayda ani bir düşüş yaşanması, modelin örüntüyü anlamlandırabilmesi için basitleşerek kötü performans gösterebileceği şeklinde yorumlanabilir. Ancak SARIMA için ham veriler işlendiğinde, alt modellerde sürecin görece karmaşıklaşması ve dördüncü aydaki rastgele dalgalanmaların ele alınabilmesi, bu gürültünün genelleme yapma potansiyelini artırdığı gözlemlenmektedir. Ayrıca, ARIMA ve SARIMA alt modellerinde tahminlerin gerçek aşı kullanımına göre alt ve üst sınırlara ulaştığı tespit edilmiştir. Hedeflenen modellerin alt ve üst sınırlarının gerçek veri setindeki eksene yakın olması, bu sayede yanlılık ve varyans açısından en aza indirilmiş bir performans sergilediğini göstermektedir. Diğer bir deyişle, varyans farklı veri setleri için önem arz ederken, yanlılık, gerçek değer eksenine ne kadar yaklaşabildiğinin göstergesidir. Bu nedenle, modellemede yapılan tahminler için tek bir sayı vermek yerine, bu eksene olan mesafenin daha net anlaşılabilmesi amacıyla güven aralıkları kullanılmaktadır. Tahminlemede güven aralıkları, bize nokta değer yerine hesaplanmak istenen aralığı ve bu aralığın belirlenen sınırları ile olasılıksal tablosunu sunmaktadır. Bu tablo, aynı zamanda tahmine bağlı risklerin görülebileceği ve bu risklere yönelik kurumsal stratejilere uygun önlemler alınabilecek fırsatların yakalanmasına olanak tanımaktadır.



Şekil 2.24: SARIMA İlk Tahmin Sonucu.

Şekil 2.24, veri seti durağan hale getirildikten ve mevsimsel olarak temizlendikten sonra en başarılı SARIMA modelinin tahmin sonuçlarını göstermektedir. Aşağıda, test verilerini ortalama MAE değeri ile birlikte gösteren bir grafik bulunmaktadır. Modellerin eğitim sürelerinin kısaltılması veya iterasyon sayısının azaltılması, hızın artırılması ve kaynak maliyeti açısından fayda sağlarken, aynı zamanda karmaşıklığı azaltmaya yönelik bu eylemler, olası aşırı öğrenme sorunlarının önüne geçebilir. Veride birbiriyle ilişkili olguların tespiti, diğer bir deyişle, birbirine bağlı olmayan bilgi içermeleri ve eğer içeriyorlarsa bu bağlantıların tespiti, çalışmalarda dikkat edilmesi gereken önemli bir unsurdur. Burada önemli olan, bağıl değişkenlerden hangisinin veya hangilerinin ne kadar değiştiğinde, onlara bağlı hareket eden değişkenin bir birim değişikliğinin oluştuğunun örüntüsüdür. Bu sayede, korelasyonun ne kadar aynı bilgiyi taşıdığı ve model üzerinde etkili olduğu görülebilmektedir. Gerçek veri setinde gerekli karmaşıklıklaştırma işlemine tabi tutulduğunda, aşağıda bu yorumların ne anlama geldiği gözle görülebilmektedir. Özetle, karmaşıklığı artırmak aşırı öğrenmeye, azaltmak ise değişkenler arasındaki desenin model tarafından yakalanamamasına, dolayısıyla performans üzerinde olumsuz etkilere yol açmaktadır.



Şekil 2.25: SARIMA ve ARIMA Tahminleri Karşılaştırması.

Şekil 2.25, 2024 yılına ait gerçek verileri mavi renkte, ARIMA tahminini kırmızı renkte ve SARIMA tahminini yeşil renkte göstermektedir. Verilerdeki son trendlerin modelin başarısını nasıl etkilediği gözlemlenebilmektedir. Bu çalışmanın ilk aşaması olan ARIMA modeli ne ait düşük RMSE ve MAE değerleri, güncel literatürdeki yaygın kullanımını açıklamaktadır. [83] 2018 ve 2022 yıllarında veri frekansının ani günlük şoklar yaşadığı yılları hariç tuttuğumuzda, bu çalışmadaki Mevsimsel Otoresif Entegre Hareketli Ortalama modelinin Ortalama Mutlak Hata (MAE) sonucu, tam veri setinden elde edilen MAE ile tutarlıdır. Ancak, budanmış SARIMA modelinin Kök Ortalama Kare Hatası (RMSE), değiştirilmemiş veri setinin RMSE'sinden daha yüksektir. Sonuç olarak, analiz tüm veri seti üzerinde tekrarlanmakta ve bu sefer 5 katlı çapraz doğrulama yaklaşımı kullanılmaktadır. Özetle, veri akışını etkileyen ve bu çalışmada daha sonra tartışılacak olan Değer Risk (VaR) analizine girdi olarak hizmet eden değişken ortamlardaki modeller için güven aralıklarının genişliği, aşılarda elde bulundurma maliyetlerini artırabilir ve bu da önemli mali kayıplara yol açabilir. Ayrıca, son beş yıldaki araştırmalar, çeşitli makine öğrenimi tekniklerinin uygulanmasına giderek daha fazla odaklanmıştır. [84] Bu nedenle, veri budama veya temizleme gerektirmeyen kaynak maliyetini düşüren yeni yöntemlerin dengeli yaklaşımına katkıda bulunan faktörler, olasılık tablosunu kullanarak araştırılmaktadır.

2.5 EKONOMİ UYGULAMASI

Sağlık ekosistemi "verilerle doludur." Hastaneler ve doktor muayenehaneleri, sigortacılara fatura kesmek için masaüstü bilgisayarlar ve bilgi yazılımları benimsemektedir. Hastaneler ayrıca, klinik bilgileri toplamak ve analiz etmek amacıyla eczane, radyoloji ve klinik laboratuvarlar gibi uzmanlaşmış alanlara sağlık bilgi teknolojisi uygulamaya başlamıştır. Sağlık ekosisteminde iki ana akış bulunmaktadır, bunlar para ve hizmetlerdir. Birincisi geri ödeme akışını içerirken; ikincisi, hizmetler ve hizmete konu olan tedarik zinciri boyunca ürün akışını kapsamaktadır. İlaç tedarik risk yönetimi alanı, hastalık maliyetini tahmin etme konusunda önemli bir yer tutmamaktadır; ancak bu çalışmalar mutlaka yapılmalıdır. Bu değerlendirme, gelecekteki kararlar için bir temel oluşturur.[85] Aaron C. Brown, "Tek bir şube bankasının soyulma olasılığı yaklaşık %0.0004'tür. Dolayısıyla, soygun riski günlük %1'lik bir Değer Riski (VaR) hesaplamasına dahil edilmez. Aslında, risk bu rakamın büyüklüğünün dışındadır. Bunun yerine, kurumlar bu tür risklere karşı sigorta yaptırmalı ve önleyici tedbirler konusunda sigorta şirketlerinden rehberlik almalıdır. Sigortanın temel amacı, bireysel VaR limitlerini aşan riskleri bir araya getirip, istatistiksel öngörülebilirliği sağlamak için yeterince büyük bir portföyde birleştirmektir." Bu çalışma, Değer Riski (VaR) ile birlikte, aşılardan depolanması, soğuk zincir koruması ve imhası ile ilgili giderlerin yönetimi açısından önemlidir. VaR kullanmak, belirli eylemleri yönlendirmek ve diğerlerinden kaçınmak gibi stratejiler geliştirmede avantajlar sağlayabilir.[86] Maliyet, tüm teknoloji yatırımlarında önemli bir faktördür. Tüm varlıkların iletişim kurabildiği altyapılarda maliyet ve risk yönetiminin dinamik olarak gerçekleştirilmesi, maliyet kayıplarının gösterilmesi ve risk yönetimi metodolojisinin eklenmesi, kontrol edilebilirlik açısından sistemi yönetenlere kolaylık sağlayabilmektedir. Güven aralıkları, bir parametrenin gerçek değerinin belirli bir güven seviyesiyle, tipik olarak %95 ile içinde yer almasını beklediğimiz bir aralık sağlamaktadır. Çalışmamızı birden fazla kez tekrarlırsak, bu çalışmalardan hesaplanan güven aralıklarının %95'inin gerçek parametre değerini içereceği anlamına gelmektedir. Makine öğrenimi modellerinde bir tahminin veya parametre tahmininin belirsizliğini incelemede önemli bir rol oynamaktadır. Bu inceleme, uygulayıcıların modellerinin istikrarını ve güvenilirliğini değerlendirmeleri için hayati önem taşımaktadır. Güven aralıklarını anlamak, bir makine öğrenimi modelinin yeni, görülmemiş verilere genelleştirilebilirliğini değerlendirmek için esastır. Bu içgörü, özellikle kararların makine öğrenimi modellerinden türetilen tahminlere veya kestirimlere dayandığı senaryolarda paha biçilmezdir. Güven aralıklarının hesaplanmasının

temel taşı birkaç temel bileşeni içerir: Tahmini Parametre: Bu, veri kümenizden türetilen ortalama veya medyan gibi herhangi bir istatistik olabilir. Kritik Değer: Seçilen güven düzeyine bağlı olarak bu değer (z-puanı veya t-puanı), tahmin edilen parametrenin gerçek popülasyon parametresinden ne ölçüde farklılaşabileceğini niceliksel olarak belirtir. Tahminin Standart Hatası: Bu, örneklem ortalamasının popülasyon ortalamasından dağılımını ölçer. Formül: Güven Aralığı = Tahmini Parametre $\pm$ (Kritik Değer * Standart Hata) Bu formül, çeşitli istatistiksel ve makine öğrenimi uygulamalarında güven aralıklarının oluşturulmasının temelini oluşturur ve belirsizliği ölçmek için temel bir araç görevi görür. Aşağıda gerçekleştirilen sarı huma aşısı sayıları, tahmin edilen aşı değerleri, seçilen güven düzeylerinin z puanı, tahminin standart hatası olarak modelin MAE değeri belirtilmektedir. Bu değerler aynı zamanda Riske Maruz Değer hesaplamalarına girdi olarak kullanılacaktır. Bir risk önceliği sayısı, olasılık, etki, tespit ve sürdürülebilirlik derecelendirmelerinin çarpılmasıyla hesaplanabilir. Yüksek bir puan, iş değişikliğini gerçekleştirememeye riskinin yüksek olduğunu gösterir ve bu nedenle uygun bir azaltma planı geliştirme açısından yüksek bir öncelik olarak kabul edilmelidir.


Tablo 2.22: SARIMA(0,1,2)(0,1,2,12) Gerçek ve Tahmin Güven Aralıkları.

Month	Act 2023	Pred. 2023	%95 Low Limit	%95 Upper Limit	%99 Low Limit	%99 Upper Limit
January	2278	2079	1453	2704	1257	2901
February	1740	1827	1124	2550	900	2774
March	1536	1842	1066	2618	822	2862
April	725	1513	678	2347	416	2609
May	1709	1841	952	2730	673	3009
Jun	2261	2046	1106	2986	810	3281
July	2261	2017	1028	3006	718	3317
August	2472	2003	968	3039	643	3364
September	2797	2150	1070	3229	731	3569
October	2228	2099	976	3221	624	3574
November	2087	2018	855	3182	489	3548
December	1674	1893	690	3096	312	3474
Avarage	1980	1945	997	2892	700	3190

Tablo 2.22, bir yıl boyunca SARIMA(0,1,2)(0,1,2,12) modeli tarafından belirlenen gerçek aşı kullanımını, tahmin edilen rakamlarla ve tahmin güven aralıklarına dayanan aşı sayılarını göstermektedir.


Güven aralıkları, makine öğrenimi uygulayıcılarının araç setinde kritik bir rol oynayarak, model tahmini ve parametre kestirimi gibi genellikle belirsiz görevler için istatistiksel bir temel sağlar. Modelin gerçek veri ile tahmin edilen veri arasındaki desen uyumunu değerlendirmek, tablo oluşturulduğunda gizli kalıpların ne kadar iyi işlenebildiğini gösterecektir. Ayrıca, modelin tahmin güven aralıkları alt ve üst limitler sağlayarak, stokların hangi aralıklarda olabileceğini belirlemeye yardımcı olacaktır.

Yukarıdaki tablo incelendiğinde gerçek veri setinde nisan ayında aşılama sayılarında ani bir düşüş görülmektedir. %95 aralığı, % 99 aralığına göre, gerçek ve tahmin aşılalarını daha dar kapsama aldığı, kısaca sinyal aralığını daralttığı görülmektedir. Tahmin sinyal aralığının durumu diğer alt modellerde incelenmeye devam etmektedir.



Şekil 2.26: SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralığının Gerçek Veri Seti Grafiği.

Şekil 2.26, SARIMA(0,1,2)(0,1,2,12) tahmin güven aralığını göstermektedir. Sarı humma aşısı talep tahmin çalışmasında, SARIMA'nın finansal riskine ilişkin güven aralığı (ayda 2000'in altın-da veya 2700'ün üzerinde aşılamar) bulunmaktadır. Yukarıdaki şekilde güven aralığı gri renkte gösterilmektedir. Modelin tahmin çizgisi turuncu renkte olup gri alanın turuncu çizgiyi dar atralıkta takip edebiliyor olması gerekmektedir.




Şekil 2.27: SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralığı.

Şekil 2.27, SARIMA için güven aralığı. Aaron Brown'ın vurguladığı gibi, modellerin ön-görücü güçlü ve zayıf yönleri her iki yönde de kullanılabilir. Bu nedenle, Risk Değeri (VaR) çerçevesinde en başarılı modelin zayıf yönleri de kullanılabilir. Standart sapma, bir veri setinin yayılmasını ölçmek için en yaygın yöntemlerden biridir ve Ortalama Mutlak Hata (MAE) hesaplamalarında benzer bir amaç taşımaktadır. Her iki metrik de aşırı uç değerler mevcut olmadıkça karşılaştırılabilir sonuçlar vermektedir.

Tablo 2.23: SARIMA(1,1,1)(1,1,1,12) Gerçek ve Tahmin Güven Aralıkları.


Month	Act. 2023	Pred. 2023	%95 Low Limit	%95 Upper Limit	%99 Low Limit	%99 Upper Limit
January	2278	3193	662	5723	-133	6518
February	1740	2655	-546	5855	-1552	6861
March	1536	2451	-750	5651	-1756	6657
April	725	1640	-1561	4840	-2567	5846
May	1709	2624	-577	5824	-1583	6830
Jun	2261	3176	-25	6376	-1031	7382
July	2261	3176	25	6376	-1031	7382
August	2472	3387	186	6587	-820	7593
September	2797	3212	511	6912	-495	7918
October	2228	3143	-58	6343	-1064	7349
November	2087	3002	-199	6202	-1205	7208
December	1674	2589	-612	5789	-1618	6795
Avarage	1980	2895	-249	6039	4113	7028

Tablo 2.23, tüm yıllar, SARIMA(1,1,1)(1,1,1,12) modeli tarafından belirlenen gerçek aşı kullanımını, tahmin edilen rakamlarla ve tahmin güven aralıklarına dayanan aşı sayılarını birlikte göstermektedir. SARIMA(0,1,2) kullanarak 2023 için yapılan aşı tahmini, gerçek sayıdan daha düşüktür. Buna karşılık, SARIMA(1,1,1) modelinden elde edilen 2023 tahmini, gerçek rakamdan üçte bir daha yüksektir. Bu durum, modellerin yalnızca Ortalama Mutlak Hata (MAE) değerlerine dayanarak değerlendirilmesinin yerine, kararların kurumun stratejisi doğrultusunda ve güven aralıklarını dikkate alarak verilmesi gerektiğini göstermektedir. Gerçek dünya verileriyle uyumlu ve gerçek aşı tüketimine en yakın güven aralıkları içinde kalan modellerin kullanımı, bu kurumda envanter yönetimi için daha uygundur. Güven aralıkları, bir tahminin belirsizliğini nicelemenin bir yoludur. Bir populasyon parametresine, örneğin popülasyondan bağımsız gözlemlerden oluşan bir örneklemden tahmin edilen bir ortalamaya sınır veya olasılık eklemek için kullanılabilirler. Güven aralıkları, tahmin istatistikleri alanından gelir. Güven aralıklarının önemi, salt istatistiksel ölçümlerin ötesine uzanır; makine öğrenimi modellerinin istikrarı ve güvenilirliği hakkında içgörüler sunmaktadır. Bu, uygulayıcıların modellerinin performansı ile ilgili bilinçli kararlar ve yorumlar yapmalarını sağlar.



Şekil 2.28: SARIMA(1,1,1)(1,1,1,12) Tahmin Güven Aralığı.

Şekil 2.28’de, SARIMA modelinin güven aralığı ile gerçek veri seti mavi çizgi ile gösterilmektedir. Alt sınır, %95 güven aralığı ile modelin tahmin edilen değerleri arasında yer almaktadır. Üst sınır ise tahmin edilen değerlerin ardından gelen %95 güven aralığını temsil etmektedir. Ancak bu durum, tahmin aralığının genişleme olasılığını gözler önüne sermektedir. Modelin tahmin aralığının dar olması, veri setine olabildiğince uyumlu olması ve hata değerinin bu sınırlara göre gerçekçi bir şekilde belirlenmesi gerekmektedir. Veri setinde aşırı uyum sağlayan bir model, tahmin hatasının düşüklüğü, yani RMSE ve MAE değerlerinin en iyi durumu, güven aralığının genişlemesi riskini beraberinde getirmektedir. Bu durum, olağandışı stok hareketlerini yakalayamama veya kritik stok seviyelerinin hatalı değerlendirilmesi riskini oluşturur. Ayrıca, bu durumu nadir hastalıkları tespit etmede ve gizli örüntüleri sergilemesi beklenen olay dizilerinde aşırı öğrenme sonucu genelleme yapan modelin riskleri olarak da tanımlamak mümkündür. Gerçek veri setimde 2278 ile başlayan sarıhumma aşılama sayıları, Nisan ayında 725’e düşmektedir. Ortalama aylık 1980 aşılama yapılmaktadır. Nisan ayındaki ani düşüş, verimimizin yapısalıdır. Ancak SARIMA güven aralıkları oldukça geniştir. Modelin hata MAE oranına göre stoklar yapılandırıldığında, -249 ile 4113 arası seçilen aralığa göre stok sayıları belirlenebilir. Bu güven aralıkları, stoklama açısından oldukça geniş bir yelpaze sunmakta, ancak kurumsal olarak aşırı stoklama ya da stok azlığına neden olabilmektedir.



Şekil 2.29: Lineer Regresyon Tahmin Doğrusunun Gerçek Verilerle Gösterimi.

Şekil 2.29, Doğrusal Regresyon tahminini göstermektedir. Aşağıda, tablo 24’te, tüm yıllar için Doğrusal Regresyon modeli tarafından belirlenen gerçek aşı kullanımını, tahmin edilen rakamlar ve tahmin güven aralıklarına dayanan aşı sayıları ile birlikte gösterilmektedir.


Tablo 2.24: Lineer Regresyon Gerçek ve Tahmin Güven Aralıkları.

Month	Act. 2023	Pred. 2023	%95 Low Limit	%95 Upper Limit	%99 Low Limit	%99 Upper Limit
January	2278	5988	5475	6501	5312	6664
February	1740	5980	5470	6490	5308	6652
March	1536	5973	5466	6480	5304	6641
April	725	5965	5461	6469	5300	6629
May	1709	5957	5456	6458	5297	6617
Jun	2261	2261	5400	2843	4500	6600
July	2261	2261	5230	2843	5000	3027
August	2472	2471	3741	3053	4200	3027
September	2797	4043	3539	4547	3378	4707
October	2228	4035	3528	4542	3367	4703
November	2087	4027	3517	4537	3355	4699
December	1674	4019	3506	4532	3343	4695
Avarage	1980	5004	4648	5359	4536	5472



Şekil 2.30: Lineer Regresyon Tahmin Güven Aralığı.

Şekil 2.30, Lineer regresyon tahmin güven aralıklarını göstermekte olup, gerçek veri setinden olabildiğince uzaklaştığını ve hatta ciddi derecede stok fazlalığı yaratabileceğini ortaya koymaktadır.




Şekil 2.31: 2003-2023 Yılları Arasında Aylık Aşı Verilerinin Yıllık Akışları.

Şekil 2.31, 2000 ile yaklaşık 3000 aşı arasında aylık olarak kullanıldığını göstermektedir. Tablo 24 ve Şekil 30'daki çapraz karşılaştırmada, uyum göstermeyen Doğrusal Regresyon belirlenmektedir. Ayrıca, güven aralıkları oldukça geniş olduğundan, güvenlik stoğunun artırılması riski bulunmaktadır. Aşağıda aşı maliyetleriyle ilgili XGBoost tahminlerindeki hatalardan kaynaklanan riskler incelemeye devam edilmektedir.

Tablo 2.25: XGBoost Tahmin Güven Aralıkları.

Month	Act. 2023	Pred. 2023	%95 Low Limit	%95 Upper Limit	%99 Low Limit	%99 Upper Limit
January	2278	1740	1158	2322	973	2506
February	1740	1740	1158	2322	973	2506
March	1536	1537	955	2119	771	2303
April	725	733	151	1315	-33	1499
May	1709	1710	1128	2292	944	1718
Jun	2261	2261	1679	2843	1495	2476
July	2261	2261	1679	2843	1495	3027
August	2472	2471	1889	3053	1704	3027
September	2797	2791	2209	3373	2025	3557
October	2228	2791	2209	3373	2025	3557
November	2087	2791	2209	3373	2025	3557
December	1674	1675	1093	2257	909	2442
Avarage	1980	2041	2113	2623	3777	2681

Tablo 2.25, XGBoost aralıklarını gerçek veri desenine olan uyumunu göstermektedir.




Şekil 2.32: XGBoost Tahmin Güven Aralıkları.

Şekil 2.32, XGBoost aralıklarını gerçek veri desenine olan uyumunu göstermektedir ve MAE ye bağlı güven aralıklarına göre aşılama sayıları ortalama 2041 ile 3777 arasındadır.

Tablo 2.26: SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralıkları. (Daraltılmış Aralıklar)


Month	Act 2023	Pred	Diff.	%95 Low Limit	Low Stock Inter	%95 Upper Limit	Over Stock Inter
January	2278	2079	199	1453	-825	2704	426
February	1740	1827	-87	1124	-616	2550	810
March	1536	1842	-306	1066	-470	2618	1082
April	725	1513	-788	678	-47	2347	1622
May	1709	1841	-132	952	-757	2730	1021
Jun	2261	2046	215	1106	-1155	2986	725
July	2261	2017	244	1028	-1233	3006	745
August	2472	2003	469	968	-1504	3039	567
September	2797	2150	647	1070	-1727	3229	432
October	2228	2099	129	976	-1252	3221	993
November	2087	2018	69	855	-1232	3182	1095
December	1674	1893	-219	690	-984	3096	1422
Avarage	1980	1945	36,7	997	-983,5	2892	911

Tablo 2.26’da görüldüğü gibi, SARIMA güvenli aralığında stok riski daha fazladır. Ayrıca, tahmin tablosu gerçek veri tablosundaki ani desen değişimlerine olan uyumu azaldığı gözlemlenmektedir. Aşağıda şekil 34’te bu durum daha net gözlemlenebilmektedir. Aşılama sayıları ortalama -983 ile 2892 arasında olup stok eksikliği riski bulunmaktadır.



Şekil 2.33: Sadeleştirilen SARIMA(0,1,2)(0,1,2,12) Tahmin Güven Aralıkları.

Tablo 2.26 ve Şekil 2.33, organizasyonun stratejisiyle uyumlu olarak geliştirilebilmektedir. Ancak, XGBoost, tahmin doğruluğunu artırarak stok maliyetlerini düşürme potansiyeline sahiptir. Sadece RMSE ve MAE değerlerine dayanarak işlem tesis etmenin oluşturacağı risklerin gözlemlenebildiği bir modeli incelemek açısından, model başarılarını bu yönde değerlendirmenin doğruluğu net bir şekilde gözlemlenmektedir. Model değerlendirmesi, veri setini eğitim ve test kümelerine bölerek çapraz doğrulama yapmayı ve model performansını birden fazla veri alt kümesi arasında değerlendirmeyi mümkün kılmaktadır. Güven aralığı tahmini, tekrarlanan örnekleme ve testler aracılığıyla model doğruluğu için güven aralıkları türetebilir; bu da modelin genelleştirilebilirliği ve kararlılığı hakkında bilgi verebilir.



Şekil 2.34: Sadeleştirilen XGboost Tahmin Güven Aralıkları.

Tablo 2.27: XGBoost Tahmin Güven Aralıkları. (Daraltılmış Aralıklar)


Month	Act. 2023	Pred2023	Diff	%95 Up- per Limit	Over Stoc In- ter	%99 Up- per Limit	Over Stoc In- ter
January	2278	1740	-538	2322	44	2506	228
February	1740	1740	0	2322	582	2506	766
March	1536	1537	1	2119	583	2303	767
April	725	733	8	1315	590	1499	774
May	1709	1710	1	2292	583	1718	9
Jun	2261	2261	0	2843	582	2476	215
July	2261	2261	0	2843	582	3027	766
August	2472	2471	1	3053	581	3027	555
Septem	2797	2791	6	3373	576	3557	760
October	2228	2791	563	3373	1145	3557	1329
November	2087	2791	704	3373	1286	3557	1470
December	1674	1675	1	2257	583	2442	768
Avarage	1980	2041	61	2623	643	2681	700

Tablo 2.27 görüldüğü gibi, tahmin güven aralıklarına göre XGboost güvenli aralığında stok kaybı riski daha azdır. Ayrıca, tahmin tablosu gerçek tabloyla tam uyumludur. Tablo 2.27 ve Şekil 2.35, XGBoost tahmin güven aralığını göstermektedir. Bu, organizasyonun stratejisine uygun olarak geliştirilebilir. XGBoost, tahmin doğruluğunu artırarak müşteri elde tutma maliyetlerini azaltma potansiyeline sahiptir. SARIMA veya Doğrusal Regresyon'un stok sıkıntılarına yol açabileceği için XGBoost tercih edilmektedir; bu durum, organizasyonun envanter seviyelerini minimize etme stratejisiyle çalışmaktadır. Aksine, stok sıkıntıları kabul edilemez olduğundan, bu sıkıntılarla ilişkili potansiyel maliyetler araştırılmaktadır. 2023'te ortalama aylık aşı kullanımını sürdürebilecek aralık kritik öneme sahiptir. Eğer bu aralık dar ise, tedarik taleplerini karşılayamayabilir; eğer geniş ise, elde bulundurma maliyetleri ve stok fazlasının imha edilmesi gibi maliyetlerin artışına neden olabilmektedir. Bu durumda, her bir aşının maliyet bileşenleri satın alma fiyatını aşmaktadır. Diğer bir deyişle, yalnızca aşı alım maliyetleri olarak değerlendirilmesi doğru bir yaklaşım değildir. Diğer maliyetler, kritik envanter seviyeleri ve beraberinde gelen diğer maliyetleri de içermektedir; ekonomik ömür, lojistik maliyetler, tedarik alternatifleri (yoğunlaşma riski) gibi kayıplar, elektrik, soğutulmuş taşımacılık ve soğutma sistemlerinin bakım ve onarımı gibi faktörler bulunmaktadır. Tahmin rakamlarını ve bunların karşılık gelen kayıp risklerini olasılıksal bir dağılım içinde değerlendirmek için güven aralıkları, fonksiyonlar ve Risk Değeri (VaR)

kullanılmaktadır.[87] Güvenilirlik fonksiyonu ve regresif kayıp ölçüsünün yüzdesi ile birlikte Risk Değeri (VaR), maliyet riskini değerlendirmek için kullanılmaktadır.[88]


2.5.1 Riske Maruz Değer (VAR)

Elde tuttuğumuz portföyün %x olasılıkla maksimum ne kadar zarar edeceğini para birimi cinsinden ortaya koyan bir finansal risk ölçüm yöntemidir.[86] Kapsamlı ve detaylı bir çalışmanın temeli, gelecekte kullanılabilecek potansiyel aşı sayısının optimal ve kesin bir şekilde tahmin edilmesinde yatmaktadır. Daha önce de belirtildiği gibi, her aşı ile ilişkili maliyet bileşenleri, yalnızca satın alma fiyatının ötesine geçmektedir. Bu faktörlerle ilişkili risk değerlerini hesaplayarak, risk altındaki varlıkların potansiyel kayıp maliyeti belirlenebilir. Varlık kayıp maliyetlerine göre risk önceliklendirmesi, organizasyonel stratejilere göre düzenlenmektedir. Bu çalışmada, 'Risk Değeri' (Value at Risk - VaR) standart sapma yerine Ortalama Mutlak Hata (MAE) kullanılarak hesaplanmaktadır. Bu yaklaşım, aşı stoğu için ortaya çıkan maliyetlere dayanan geleceğe yönelik zaman bağımlı bir risk tablosu oluşturmaktadır. Riske maruz değer, parametreler yardımıyla hesaplama yapılan parametrik yöntemler (varyans-kovaryans) ve parametrik olmayan yöntemler olarak iki başlık altında incelenir.[87] Varyans-kovaryans yöntemine göre normal dağılıma sahip bir getiri serisi için, bir günlük risk yönetimi değeri (rmd) şu şekilde hesaplanır: portföy değeri (pv) * standart sapma * karekök (t (zaman=1 gün)) * güven aralığına isabet eden z tablo değeri (%95 - 1.96).



Şekil 2.35: Standart Sapma Güven Aralıkları.

Şekil 2.35, model karşılaştırmasında sonuçları özetlersek; karşılaştırmanın istatistiksel temeli, güven aralıkları ve performans ölçütlerinin basit nokta tahminlerinin ötesinde, modeller arasında titiz bir istatistiksel karşılaştırmayı kolaylaştırmaktadır. Popülasyon Parametresi: ** Bu, ortalama veya oran gibi bir popülasyonu tanımlar. Örnek İstatistikleri: ** Örnek ortalaması, örnek oranı ve örnek standart sapması dahil olmak üzere, popülasyon parametrelerini tahmin etmek için örnek verilerinden hesaplanan sayısal ölçülerdir. Örneklem Dağılımı: ** Popülasyondan tekrarlanan rastgele örneklem yapıldığı varsayımıyla, bir örnek istatistiğinin olasılık dağılımıdır. Standart Hata: Bir örnek istatistiğinin farklı örneklem arasındaki değişkenliğini ölçer. Kritik Değerler: İstenilen güven düzeyine bağlı olarak güven aralığının sınırlarını tanımlayan olasılık dağılımından belirli değerlerdir. Güven Düzeyi: Bir güven aralığının gerçek popülasyon parametresini içerme olasılığıdır. Hata Payı: Örneklem istatistiğinin güven aralığı içinde popülasyon parametresinden ne kadar farklı olabileceği miktarıdır. Bilinçli karar alma, model performans ölçütleri etrafındaki belirsizliği ölçerek, paydaşların üretim ortamlarında hangi modelin dağıtılacağı konusunda daha bilinçli seçimler yapabilmesine yardımcı olmaktadır. Bu araştırma, geleneksel ile yeni geliştirilen makine öğrenimi modellerini karşılaştırırken doğruluk ölçütleri etrafındaki güven aralıklarının, model üstünlüğü iddialarının güvenilirliğine ilişkin içgörüler sağladığını göstermektedir. [73]



Şekil 2.36: XGboost Binde Tahmin Hata/RPN İle Güvenli Stok Aralığı Dengesi.

Şekil 2.36, hata aralıklarının kurumun stratejisine dayalı olarak belirlendiğini göstermektedir. Daha yüksek hata oranları sergileyen, ancak veri akışı kesintileri gibi çeşitli koşullar altında dengeyi koruyabilen bir model, aşırı uyumlu bir modelden daha fazla tercih edilebilir. Bu araştırma sırasında uygulanan aşı sayısına bakıldığında, XGBoost'un %95 ve %99 üst güven aralıklarının bir güvenlik stoğu oluşturmak için uygun olduğu görülmektedir. Modellerden elde edilen Ortalama Mutlak Hata (MAE) sonuçları, daha önce bahsedilen sistemle ilgili veri akışı kesintileri, salgınlar ve tedarik zinciri kesintileri gibi riskleri ele almaktır. Bu durum, risk spektrumunun daha geniş bir perspektiften değerlendirilmesi gerektiğini göstermektedir. MAE, ortamları düşük, orta veya yüksek risk olarak kategorize ederek, ilgili hata oranlarıyla birlikte Değer Riski (VaR) modeline katkıda bulunmaktadır. Düzensiz veri akışı veya taşma durumlarında, XGBoost tercih edilebilir çünkü zaman serisi akışından sapmaları daha iyi yönetebilir.

Q(t): Sistem Güvenilirlik Fonksiyonu, belirli bir süre boyunca sarıhumma aşısının maliyeti ile ilişkili minimum potansiyel kaybı gösteren %95 veya %99 güven aralığı sağlar ve x% (Ortalama Mutlak Hata, MAE) olasılığı ile gelir. Ayrıca, aynı dönemdeki maksimum potansiyel kaybı, 1 - x% olasılığı ile temsil eder. Proaktif hesaplama süresi (t), günlük Değer Riski (VaR) değerini gelecekteki gün sayısı ile çarparak yıllık bir rakama dönüştürmek için kullanılır.

Standart sapma (Std), analizde çeşitli dağıtımlar arasında değerlendirilebilecek bir kayıp riski ölçüsü olarak hizmet eder. Gerçek sonuçlar ile beklenen sonuçlar arasındaki tutarsızlıklar belirlendiğinde, karar verici aşırıya yapılan yatırım ile ilişkili finansal riskleri hesaplayabilir. Bu çalışmayı 2024'ün başında yapılandırmaya başladığımızdan beri, 10 aylık veri akışı devam etmiştir. Sonuç olarak, modellerin başarılarını ve ilişkili risk aralıklarını bir kez daha gerçek verilerle karşılaştırma fırsatımız olmuştur. Gelen veriler, SARIMA modelinin ürettiği tahmin aralıklarının oldukça geniş olduğunu ve bu durumun fazla güvenlik stoğu ile ilişkili maliyet kayıplarına yol açtığını göstermektedir. Bu nedenle, bu veri seti için Değer Riski (VaR) analizi için XGBoost'u girdi olarak kullanmayı tercih edilmektedir. [88]

Riske maruz değer (Value at Risk);

$$VaR = T_m \cdot Q.Std \cdot \sqrt{t} \quad (2.30)$$

Tablo 2.28: VaR Parametreleri.

No	Parameter	Value	Confidence Level
1	Asset Value	855,681,000.00	/
2	Average Return	80,002,000.00	/
3	XGBoost MAE	0.0041 ($\approx$)	/
4	Risk Prioritization Number	1.51	/

Tablo 2.29: VaR Değerleri.

No	Parameter	Value	Confidence Level
1	Value of Asset	927,718,562.60	Min. return with 99% = 0.08
2	VaR	72,038,562.60	/
3	Value of Asset	930,051,126.59	Min. return with 95% = 0.09
4	VaR	74,371,126.59	/

$$T_m = \$1,000,000; Q = 0.04\%; Std = 2.33; \sqrt{t} = \sqrt{10};$$

$$ValueatRisk = \$1,000,000 * 0.04\% * 2.33 * \sqrt{10} = \$2947.$$

Tablo 2.28 ve 2.29, organizasyondaki değer kaybı parametreleri ve tablo 10 değer kaybı hesaplanmaktadır. [89]

2.33, Z tablosundaki güven aralığının değeridir.[90] Depodaki aşı stoğundan kaynaklanan kayıplar, güncel aşı stok maliyetleri ağırlıkları dikkate alınarak geçmiş maliyet serileri üzerinden varsayımsal değerler üretilmesiyle belirlenir.[91] Varsayımsal zarar değeri ile gerçek kayıp değeri arasındaki kar-zarar farkı ortaya konur ve güven aralığındaki maliyet zararı tespit edilir. Giderler arasında kira, teknoloji altyapısı, küresel ve siyasi riskler, gümrük ücretleri ve ev sahibi ülkedeki artan salgınların etkileri ile savaş, kıtlık, doğal afetler ve mücbir sebeplerden kaynaklanan olası kesintiler yer almaktadır. Aşı dağıtımında "herkes için tek tip" bir yaklaşım mevcut değildir. Ülkenin ana stratejileri ve yöntemleri, ortak bir

platform üzerinden işlenebilir. Bu yaklaşım, aşı kapsamı ve talep tahmin araçlarına entegre edilebilir. [92] Optimum stok seviyeleri ve bunları etkileyen faktörler arasında tedarik yoğunluğu (tedarikçi tekilliği), soğutma sistemlerinin ekonomik ömrü, bakım ve onarım süreçleri, taşıma seçenekleri ve alınan yollar bulunmaktadır. Ayrıca, soğuk zincir kayıpları, personel tahsisi ve aşı hazırlama hataları da bu faktörlere katkıda bulunmaktadır. Diğer önemli hususlar, merkeze bağlı kurumlarla ilişkili elektrik, kira ve barındırma maliyetlerini kapsamaktadır. Dijital aşı ve lojistik takip sistemindeki hatalar da önemli maliyet faktörlerini temsil etmektedir. Aşı stok seviyeleri düzgün bir şekilde yönetilmediğinde, aşılarda süresi dolabilir ve atılmak zorunda kalınabilir; bu durum ekonomik kayıplara yol açabilir. Ayrıca, stok yetersizlikleri nedeniyle yaşanan itibar kaybı ve aşılanamayan, sonrasında hastalanan bireylerden kaynaklanan birikimli maliyet kayıpları, kritik stok seviyesi stratejilerini etkilemektedir. Tüm bu giderler, aşı başına fiyatlandırmayı etkiler ve stok ile tutma maliyetlerini artırır. Politikalar, bütünsel yönetim ve kontrolü, sağlam web hizmetlerini, dijital entegrasyonu ve merkezi sistemler ile bilimsel disiplinler arasında köprü kuran hibrit teknolojinin optimizasyonunu teşvik edecek şekilde yapılandırılmalıdır. Ayrıca, dijital entegrasyon hatalarının ve veri girişlerinin izlenmesi de önemlidir. Bu çalışmada gösterildiği gibi, web hizmetlerine kurum için uygun bir tahmin modeli olan XGBoost'un entegre edilmesi, aşı lojistiğinin verimliliğini artırmada ve ilişkili riskleri en aza indirmede hayati bir rol oynamaktadır.

Olgunluk düzeyi yüksek olan sağlık kuruluşları, risk yönetiminde etkili bir performans sergilemektedir. Potansiyel riskleri erken aşamada belirleyebilir, uygun azaltma stratejilerini uygulayabilir ve sorunları proaktif bir şekilde ele alarak risklerin sunulan hizmetler üzerindeki etkisini azaltabilirler. Süreçler daha düzenli ve öngörülebilir hale geldikçe, hizmet verenler ve hizmet alanlar daha az hayal kırıklığı ve stres yaşamaktadır. Çalışanlar, önlenemez sorunlarla uğraşmak yerine katma değerli görevlere odaklanabildikleri için bu durum, moralin iyileşmesine ve üretkenliğin artmasına yol açmaktadır. Kısacası, bu modeller sağlık kuruluşlarının süreçlerini ve uygulamalarını sürekli olarak değerlendirmeleri ve iyileştirmeleri için yapılandırılmış bir yaklaşım sunmaktadır. Başlangıçtan optimizasyona kadar olan olgunluk düzeyi, sağlık kuruluşlarının daha yüksek süreç olgunluğuna doğru ilerlemesi ve daha iyi sağlık hizmeti sonuçları elde etmesi için net bir yol haritası sağlamaktadır. Kuruluşlar, stratejilerine uygun modeller benimseyerek genel performanslarını artırabilir,

yüksek kaliteli ürün ve hizmetleri tutarlı bir şekilde sunabilir ve günümüzün dinamik iş ortamında rekabet gücünü koruyabilirler.

Fayda-maliyet swap analizi çalışmaları bilgi teknolojisi risklerini ortadan kaldırmak için yapılan harcamalara yönelik modellerin etkinliği ve verimliliği finansal sonuçlar üzerinde olumlu etkiler yaratmaktadır. [90] Model kriterleri, farklı süreçler ve gruplar için farklı raporlamalar gerektirmektedir. Ortak parçaların kesişim noktaları vardır ve bunların bileşimi zaman, bütünlük ve aynı yönde yönelimi sağlar. Varlıkların ve dinamik operasyonların performans ölçümleri, standart bir değerlendirme mekanizması aracılığıyla yapılır. Ayrıca, bilgi aktarımını sağlayan donanım, yazılım, kullanıcılar vb. sürekli ölçümleri, sistemin mevcut durumunu dinamik olarak yansıtır. Mevcut durum dikkate alınarak, riske maruz değer ve riskin ortadan kaldırılması gibi alınması gereken önlem veya değişikliklerin planlanmasında kullanılmaktadır. Bu şekilde, bilgi teknolojileri yönetimine daha bütünleşmiş bir yaklaşım oluşturulabilir. Finansal ve finansal olmayan kriterlerin birleştirilmesiyle, varlık ve risk yönetimi, operasyonlar ve finansal performans gibi unsurların birbirine göre eksiklikleri tamamlanabilmektedir. Finansal maliyetlerin risk analizi çalışmalarına yeterince dahil edilmemesi, mevcut yöntemlerin uygulanabilirliği açısından dezavantaj oluşturmaktadır. Kısaca tahminleme, sağlık kuruluşlarında mevcut yapı ve kurum kültürüne uyumlu, benzersiz varlık yaşam döngüsünü, varlığın sistemde ortaya çıkışından itibaren zamana bağlı değişikliklere dinamik olarak içgörü kazandırarak gelecekteki davranışının modellenmesidir. Varlığın dinamik olarak izlenmesi ve maliyet unsuru içeren risklerin dinamik olarak ortaya konulması, atıl kapasitelerin belirlenmesi ve objektif, kanıta dayalı verilerin sunulması amaçlanmaktadır. Tahminleme çalışmaları, sistemdeki her varlığın ortaya çıktığı anda analizi yapıldıktan sonra izleme ve analiz kontrol panelleriyle, model ve yöntem gereksinimlerine göre sistematize edilmesidir. Ortaya çıkma zamanına göre karşılaştırma, kurulan sistem içerisinde çeşitli araçlar yardımıyla yapılır. Bu yöntemler sayesinde hata düzeltme, eksik veri tamamlama, tahmin ve aykırı veri çıkarma işlemleri yapılmaktadır. Sistemin dinamik işleyişi, finansal ve güvenlik göstergeleri ile web tabanlı yazılımlara tahminleme çalışmaları eklenmeye devam edilmektedir. Bu sayede standartlara uygun, dijital üretim ölçeğinde analizler gerçekleştirilebilir ve proaktif bir yaklaşım sergilenebilmektedir. Hem gerçek zamanlı operasyon yönetimi hem de uzun vadeli finansal, operasyonel, güvenlik ve risk yönetimi sağlanabilmektedir. Bu amaçla uygulamadaki bilgi teknolojileri tahminleme model parçaları, ihtiyaçlara yönelik iş zekâsı uygulamalarına yönlendirilmektedir ve ihtiyaçlar

doğrultusunda sistem geliştirmeye devam edilmektedir. Varlık kaybı maliyetlerine göre risk önceliklendirmesi, organizasyonel stratejilere göre düzenlenmektedir. Sağlık 4.0 çerçevesinde varlıkları dört ana grup içerisinde tanımlayabiliriz: insan kaynakları, taşınır varlıklar, taşınmaz varlıklar ve bilgi içeren ortamlar. Bilgi içeren ortamlar, bilişim altyapısı varlıklarını kapsar; bunlar arasında insan kaynakları, yazılım, donanım ve iletişim altyapısı bulunmaktadır. Ayrı ve detaylı çalışma konusunun başlangıcı, kullanılan aşılardan gelecekte kullanılabilecek potansiyel sayının optimum ve doğru tahmin edilmesidir. Aşı başına maliyet kalemleri yalnızca alım fiyatı ile sınırlı değildir.[91] Daha önce de bahsedilen, kritik stok seviyesi, amortisman maliyeti, fireler, genel giderler, sağlık personeli, elektrik, vergiler, frigorifik taşıma ve soğutma sistemlerinin bakım onarımı, ekonomik ömürleri, amortisman ve hurda değerleri, stok maliyetleri, uluslararası siyasi, ekonomik ve öngörülemeyen durumlar, lojistik maliyetler, yasal otorite ve paylar, zorunluluklar, tedarik alternatifleri ve alternatif değişim maliyetleri (yoğunlaşma riski), kiralar, teknoloji altyapı ve giderleri, global ve siyasi riskler, gümrük giderleri, konakçı ülkede salgının artışı, savaş, kıtlık, doğal afetler ve mücbir sebepler gibi unsurlar da dikkate alınmalıdır. Kurumun bahsi geçen risk faktörlerini, risk değerleri hesaplanarak, risk altındaki varlığın kayıp maliyeti belirlenmektedir.[92] Çalışma sonuçları, gelişen teknoloji varlıkları; birliktelik, güvenlik, işbirliği, hareketlilik, veri merkezleri, ulaşım bağlamında real time boşluk analizi yapılabileceğini ve kurumun takip sisteminin geliştirilebileceğini göstermektedir. Sürekli değişen parametrelere adapte olabilen, dinamik dijital dönüşüm planı oluşturulabilen, klinik hedefler önerebilen yapay zeka çalışmalarına katkı sağlayabilir. Mevcut geleneksel yöntemler yerine yeni makine öğrenimi modellerini kullanarak aşılardan üretimden tüketime yaşam döngüsünü oluşturan unsurlar, özellikle atıl kapasite sorunlarına yapay zeka ve makine öğrenimi modellerinin destek olabileceği kanıtı güçlenmektedir. Araştırma boyunca, modellerin etkili bir şekilde öğrenmeye devam edebilmesi için uygun koşullar oluşturulmaktadır. Özetle, modeller, geleneksel bir yaklaşımı takip etmek yerine, belirli gereksinimler ve amaçlanan uygulamalara göre seçilebilmektedir. Sistem, çeşitli aşılardan ilaçlar ve tıbbi malzemeler için uyarlanabilmektedir. Bu çalışmanın tahmin sonuçları, politika yapıcıların stratejilerini oluştururken bilinçli kararlar almalarına yardımcı olabilir.

3. TARTIŞMA VE LİMİTLER

Bugün, Aerts ve Bogdan-Martin'in bulguları, dijital ve yapay zekâ (YZ) teknolojilerinin sağlık ve bakım hizmetlerinin sunumunu köklü bir şekilde değiştireceğini göstermektedir. Özetle, YZ'nin bu hizmetleri dönüştürme potansiyeli, ülkelerin veri yönetimi ve dijital altyapı için YZ tabanlı çözümler sunan teknolojilere yatırım yapma gerekliliğini vurgulamaktadır.[93] Bu çalışmanın sınırlılığı, yalnızca tek bir tür organizasyon içinde ve bir ülkede gerçekleştirilmiş olmasıdır. Gelecek araştırmalar, zaman serisi verilerinden elde edilen parametrelerin ötesinde dışsal faktörleri dahil ederek makine öğrenimi modellerinin karşılaştırmasını geliştirebilir. Bir hastalığın yaygın olduğu bölgelerde, epidemik modelleme, ev sahibi ve çevreyi kontrol etme, hastalık belirtileri, çevresel koşullar, meteorolojik etkiler, sosyo-ekonomik durum, hareketlilik ve epidemiyolojik ile demografik dağılımlar gibi stratejilerle entegre edilebilir. Daha önce belirtildiği gibi, aşı dağıtımında her yöntemin avantajları ve dezavantajları, tarihsel verilerin mevcudiyetine ve epidemilerin yaygınlığı, küresel ekonomi ve hareketlilik kalıpları gibi diğer kuruma özgü faktörlere bağlıdır.[94] Öte yandan, bu çalışma, stok eksikliğinden kaynaklanan yüksek maliyetler nedeniyle çapraz doğrulamaya tabi olabilir. Günlük dalgalanmalar, siyasi olaylar ve epidemiler toplam aşı sayısını etkilemese de modellerin veri akışını etkilemektedir. Veri hacmi arttıkça, veri işlemeye için gereken kaynaklar da genişler ve doğruluk ile hız arasında bir denge sağlamak, aşı türü, ulusal strateji ve kuruma özgü hususlar gibi faktörlere bağlı olarak değişir. Sonuç olarak, tek bir sistem veya model önermek yerine, bilgiye katkıda bulunan değişkenlere odaklanmak önemlidir. Kurumlar, stratejilerine ve risk değerlendirmelerine göre aşı stoklarını planlamalıdır. Örneğin, dinamik değişken sistemleri, bir ülkenin ev sahibi mi yoksa pasif mi olduğu ve ziyaretlerin niteliği zorunlu veya turistik gibi temel faktörler, risk öncelik katsayısını değiştirebilir. Her kuruma özgü olan risk öncelik katsayısı, bu bilgiyi şekillendiren değişkenlerin etkisi ve modelde ortaya çıkardıkları tepkilerle birlikte, kritik stok alternatiflerinin kapsamlı bir analizini gerektirmektedir. Sistem, gerçek dünyada sağlam bir risk değerlendirmesi ve dijital altyapı talep etmekte olup pratikte zorluklar yaratabilir.

4. SONUÇ

Amacımız aşı talep tahmini yapılırken, seçilen modelin hata tahmin aralığını kullanarak, tüm olası senaryoları kapsayan ve aşı talebindeki değişen parametrelere hızla uyum sağlayabilen bir model geliştirmektir. Veri seti, yirmi bir yıl boyunca iki farklı dönemi kapsamaktadır. Dijitalleşmenin ilk on yılında, veriler çeşitli merkezlerden manuel olarak toplanmış için veri girişi eksikti. İkinci on yılda ise otomasyon sayesinde veri seti daha tutarlı hale gelmiştir. Ancak, COVID-19 pandemisi nedeniyle uygulanan seyahat kısıtlamaları bu tutarlılığı olumsuz etkilemiştir. COVID-19 pandemisi gibi olaylar, mevsimsel kalıplarda ani değişikliklere neden olabilir; bu da modellerin etkinliğini azaltabilir ve varsayımlarını zayıflatabilir. Çalışmamıza, literatürde yaygın olarak kullanılan ARIMA yöntemi ile başlanmaktadır. Bu nedenle, mevsimselliği ele alma konusundaki etkinliği nedeniyle SARIMA modeli tercih edilmektedir. Farklı değişkenler arasındaki ilişkileri ortaya çıkarmak için doğrusal regresyon kullanılmaktadır; örneğin, seyahat kısıtlamalarının aşı etkinliği üzerindeki etkisi incelenmektedir. Son olarak, gizli ve öngörülemeyen kalıpları yakalama yeteneği ile bilinen XGBoost modeli tercih edilmektedir. En doğru tahminleri veren yöntem, Kök Ortalama Kare Hatası ve Ortalama Mutlak Hata metriklerine dayanarak seçilmektedir. Analiz, üç aşamalı bir veri işleme yaklaşımı ile başlamaktadır. Veri seti dengelendiğinde, modellerin tahmin başarısının nasıl değiştiği gözlemlenmektedir. Veri setindeki kalıntıların etkisi ortadan kaldırıldığında, tüm modellerin performansında bir artış gözlemlenmektedir. Doğrusal Regresyon ve XGBoost'un tahmin başarısı, 2018 ve 2022 verileri ile manipüle edildiğinde iyileşmektedir. Zaman serisi analizi (Bölüm I. ZAMAN SERİSİ ANALİZİ) sırasında ARIMA modelinin performansı düşerken, SARIMA modelinin performansı artmaktadır. Ham veri temizleme sonrası, SARIMA modeli, ARIMA'ya kıyasla daha yüksek bir verimlilik göstermektedir. Ardından, modeller tarihsel tahmin performansı ve dengeli güven aralıklarına göre değerlendirilmektedir. Kurumsal stratejiler, güvenlik stok seviyelerini azaltmaya odaklanmaktadır; ancak SARIMA için güven aralıkları oldukça geniştir. Buna karşılık, XGBoost'tan elde edilen hata metrikleri, 2023 tahmini ile aşı miktarları için daha dengeli kritik stok aralıkları sağlamaktadır. Güven düzeyi seçimlerinin etkisi, güven düzeyinin seçimi (örneğin, %95 veya %99) ile güven aralığının genişliğini önemli ölçüde etkilemektedir. Daha yüksek güven düzeyi, daha geniş bir güven aralığı ile sonuçlanmakta ve bu da daha fazla belirsizliği göstermektedir. Daha düşük güven düzeyi ise daha dar bir güven

aralığına yol açmakta, daha fazla hassasiyet önermekte; ancak gerçek parametre değerini göz ardı etme olasılığını da beraberinde getirmektedir. Uygun güven düzeyinin seçilmesi, makine öğrenimi görevlerinin özel bağlamına ve gereksinimlerine, hassasiyet ile güvenilirlik arasındaki dengeye bağlıdır. Bu yön-tem ve değerlendirmeleri bir araya getirerek, makine öğrenimi uygulayıcıları güven aralıklarını etkili bir şekilde hesaplayabilir ve böylece modellerinin güvenilirliği ve geliştirilebilirliği hakkında bilgi sağlayabilirler. Bu temel anlayış, yalnızca model değerlendirmesi-ni geliştirmekle kalmayıp, aynı zamanda makine öğreniminin sürekli gelişen manzarasında karar alma süreçlerini de güçlendirmektedir. Sonuç olarak, model seçiminin düşük, orta ve yüksek riskli ortamlar için önerildiği görülmektedir. Ayrıca, çalışma, önümüzdeki günlerde ortaya çıkabilecek güvenlik aşısı stoğu ile ilgili mali riskleri Değer Riski (VaR) modeli kullanılarak değerlendirmektedir. Veri temizlendiğinde, SARIMA, ARIMA'ya tercih edilmektedir. XGBoost, aşırı stoklama eğilimi nedeniyle SARIMA veya Doğrusal Regresyon'a tercih edilmektedir. Özellikle, Doğrusal Regresyon'un güven aralıkları gerçek veri setinden oldukça uzaktır. SARIMA ise stok fazlalığına neden olmaktadır. Ayrıca, nedeni bilinmeyen ani hareketlerde, örneğin 2023 yılının Nisan ayındaki ani düşüş örüntüsünü, XGBoost daha iyi tespit edebilmektedir. XGBoost'un tahmin aralıkları, 2023'e kadar uzanan öngörü yetenekleri nedeniyle tercih edilmektedir. XGBoost'un işleme hızı, SARIMA'nın ön işleme maliyetine göre de avantaj sağlamaktadır. Veri eksikliği veya sistemin bozulması gibi olağan dışı durumlarda, XGBoost'un eksik verilerle başa çıkabilme yeteneği, literatürde en çok tercih edilmesine neden olan bir özelliktir. XGBoost seçimi, organizasyonun envanter seviyelerini minimize etme stratejisi ile uyumludur. Bu çalışmada ayrıca, kurumsal aşısı stok stratejilerine uygun olarak modellerin seçilmesi ve güvenli envanter aralıklarının belirlenmesi sonucunda ortaya çıkabilecek potansiyel mali kayıpların riskleri de incelenmektedir. VaR modeli üzerinden kurumun stok için toplam yatırdığı maliyete karşılık tahmin modelinin binde hatası ve RPN üzerinden kurumun kayıp riski hesaplanmaktadır. Digital olgunluk seviyesini arttıran başarı faktörü insan kaynağı, teknoloji, zaman ve iletişimdir. İnsan kaynağı başta olmak üzere teknoloji seçimi sürdürülebilirlik açısından önemlidir. Her ne kadar istekli, inançlı ve birlikte çalışma azmi olan ekip olsa da teknoloji yetersizliği yada optimal seçim hataları sürdürülebilir seviyelerin önüne engeldir. Bu bağlamda kurum stratejilerine uygun teknoloji seçimi önemlidir.

REFERANSLAR

- [1] R. C. Siagian and J. E. Osorio, “Novel approaches to vaccine development in lower-middle income countries,” *International Journal of Health Governance*, vol. 23, no. 4, pp. 288–300, 2018, doi: 10.1108/IJHG-03-2018-0011.
- [2] R. T. Alegado and G. M. Tumibay, “Statistical and Machine Learning Methods for Vaccine Demand Forecasting: A Comparative Analysis,” *J. Comput. Commun.*, vol. 08, no. 10, pp. 37–49, 2020, doi: 10.4236/jcc.2020.810005.
- [3] D. Chandra and D. Kumar, “Prioritizing the vaccine supply chain issues of developing countries using an integrated ISM-fuzzy ANP framework,” *J. Model. Manag.*, vol. 15, no. 1, pp. 112–165, 2020, doi: 10.1108/JM2-08-2018-0111.
- [4] A. Amarasinghe, O. Wichmann, H. S. Margolis, and R. T. Mahoney, “Forecasting dengue vaccine demand in disease endemic and non-endemic countries,” *Hum. Vaccin.*, vol. 6, no. 9, pp. 745–753, 2010, doi: 10.4161/hv.6.9.12587.
- [5] R. K. Chiu, C. M. Chang, and Y. C. Chang, “A forecasting model for deciding annual vaccine demand,” *Proc. - 4th Int. Conf. Nat. Comput. ICNC 2008*, vol. 7, pp. 107–111, 2008, doi: 10.1109/ICNC.2008.862.
- [6] M. Barajas, S. Bhatkande, P. Baskaran, H. Gohel, and B. Pandey, “Advancing deep learning for supply chain optimization of covid-19 vaccination in rural communities,” *Proc. - 2021 IEEE 10th Int. Conf. Commun. Syst. Netw. Technol. CSNT 2021*, pp. 690–695, 2021, doi: 10.1109/CSNT51715.2021.9509710.
- [7] E. Andiç-Mortan and C. Gonul Kochan, “Modeling a closed-loop vaccine supply chain with transshipments to minimize wastage and threats to the public: a system dynamics approach,” *J. Humanit. Logist. Supply Chain Manag.*, vol. 13, no. 2, pp. 216–234, 2023, doi: 10.1108/JHLSCM-10-2021-0102.
- [8] P. L. Fri, S. E. Higgins, D. P. Zgarrick, S. P. Desselle, L. R. Moczygamba, G. Alston and R. Sullivan, “Supply chain management,” *PPI Pulp and Paper International*, vol. 44, no. 10, p. 38, 2002.

- [9] D. Chandra and D. Kumar, "Two-way assessment of key performance indicators to vaccine supply chain system in India," *Int. J. Product. Perform. Manag.*, vol. 68, no. 1, pp. 194–230, 2019, doi: 10.1108/IJPPM-02-2018-0078.
- [10] T. Zou, H., & Hastie, "Regularization and variable selection via the elastic net.," [Online]. Available: <https://doi.org/10.1111/j.1467-9868.2005.00503.x>.
- [11] M. I. Jordan and T. M. Mitchell, "Machine learning: Trends, perspectives, and prospects," *Science (80-.)*, vol. 349, no. 6245, pp. 255–260, 2015, doi: 10.1126/science.aaa8415.
- [12] W. Siau, K., & Wang, "Building Trust in Artificial Intelligence, Machine learning, and Robotics.," [Online]. Available: <https://www.researchgate.net/publication/324006061>.
- [13] D. Rubin, "Inference and Missing Data," [Online]. Available: <https://doi.org/10.1093/biomet/63.3.581>.
- [14] A. A. Grigorev, "Introduction to Machine Learning" in *Machine Learning Bookcamp MEAP V06*, USA: Manning, October 2021, pp. 472.
- [15] J. Kaplan, "Exploratory data analysis," *A Criminologist's Guide to R*. pp. 161–182, 2022, doi: 10.1201/9781003279211-11.
- [16] Deka, Partha Pritam, and Joyce Weiner, "XGBoost for Regression Predictive Modeling and Time Series Analysis : Learn How to Build, Evaluate, and Deploy Predictive Models with Expert Guidance", in *ProQuest Ebook Central Book*, USA, Packt Publishing, Limited, 2024., <https://ebookcentral.proquest.com/lib/ikbu-ebooks/detail.action?docID=31786060>.
- [17] W. A. Kendre VV, Mumbare SS, Dixit JV, "Estimation of vaccine requirement by using time series analysis." *MedPulse International Journal of Community Medicine*, vol. 9(3), pp. 56-59, 2019.
- [18] K. C. Sahisnu JS, Natalia FR, Ferdinand FV, Sudirman S, "Vaccine prediction system using ARIMA method.," *ICIC Express Lett. Part B Appl.*, pp. 567–75, 2020, [Online]. Available: <http://dx.doi.org/10.24507/icicelb.11.06.567>.

- [19] E. A. Antipov and E. B. Pokryshevskaya, "Interpretable machine learning for demand modeling with high-dimensional data using Gradient Boosting Machines and Shapley values," *Journal of Revenue and Pricing Management*, vol. 19, no. 5. pp. 355–364, 2020, doi: 10.1057/s41272-020-00236-4.
- [20] R. Tibshirani, "Regression Shrinkage and Selection via the Lasso," *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 58, no. 1. pp. 267–288, 1996.
- [21] L. Burns, "Healthcare Information Technology. The U.S. Healthcare Ecosystem: Payers, Providers, Producers Ed. Lawton Robert Burns." *McGraw-Hill*, 2021. <https://accesspharmacy.mhmedical.com/content.aspx?bookid=3027§ionid=254562197>.
- [22] V. Kumar *et al.*, "Forecasting malaria cases using climatic factors in Delhi, India: A time series analysis," *Malaria Research and Treatment*, vol. 2014. 2014, doi: 10.1155/2014/482851.
- [23] S. Helmini, S., Jihan, N., Jayasinghe, M., & Perera, "Sales forecasting using multivariate long short term memory network models.," *PeerJ Prepr.*, vol. 7, p. e27712v1., 2019, [Online]. Available: <https://doi.org/10.7287/peerj.preprints.27712>.
- [24] A. Catal, C., Ece, K., Arslan, B., & Akbulut, "Benchmarking of Regression Algorithms and Time Series Analysis Techniques for Sales Forecasting.," *Balk. J. Electr. Comput. Eng.*, no. 7(1), pp. 20–26., 2019, [Online]. Available: <https://doi.org/10.17694/bajece.494920>.
- [25] T. Bodenheimer and C. Sinsky, "From triple to Quadruple Aim: Care of the patient requires care of the provider," *Annals of Family Medicine*, vol. 12, no. 6. pp. 573–576, 2014, doi: 10.1370/afm.1713.
- [26] D. Bevere and N. Faccilongo, "Shaping the Future of Healthcare: Integrating Ecology and Digital Innovation," *Sustainability (Switzerland)*, vol. 16, no. 9. 2024, doi: 10.3390/su16093835.
- [27] K. Theodos and S. Sittig, "Health Information Privacy Laws in the Digital Age:

- HIPAA Doesn't Apply," *Perspectives in health information management*, vol. 18, no. Winter. 2021.
- [28] K. Flott, R. Callahan, A. Darzi, and E. Mayer, "A patient-Centered framework for fvaluating digital maturity of health services: A systematic review," *Journal of Medical Internet Research*, vol. 18, no. 4. 2016, doi: 10.2196/jmir.5047.
 - [29] K. Cresswell *et al.*, "Reconceptualising the digital maturity of health systems," *The Lancet Digital Health*, vol. 1, no. 5. pp. e200–e201, 2019, doi: 10.1016/S2589-7500(19)30083-4.
 - [30] R. Pereira and J. Serrano, "A review of methods used on IT maturity models development: A systematic literature review and a critical analysis," *Journal of Information Technology*, vol. 35, no. 2. pp. 161–178, 2020, doi: 10.1177/0268396219886874.
 - [31] D. K. Sreekantha, A. Koujalagi, T. M. Girish, and K. V. S. S. S. Sairam, "Fog Computingfor Healthcare 4.0Environments," *Advances in Intelligent Systems and Computing*, vol. 1133. pp. 1425–1442, 2021.
 - [32] L. M. Kern and R. Kaushal, "Health information technology and health information exchange in New York State: New initiatives in implementation and evaluation," *Journal of Biomedical Informatics*, vol. 40, no. 6 SUPPL. 2007, doi: 10.1016/j.jbi.2007.08.010.
 - [33] K. H. Abdulkareem *et al.*, "A review of fog computing and machine learning: Concepts, applications, challenges, and open issues," *IEEE Access*, vol. 7. pp. 153123–153140, 2019, doi: 10.1109/ACCESS.2019.2947542.
 - [34] Ravi Pratap Sigh, Rajiv Suman, Abid Haleem, and Mohd Javaid, "Telemedicine for healthcare: Capabilities, features, barriers, and applications ," *Sensors International*, vol. 2, no. pp. 100–117, 2021.
 - [35] Qingqingchang, I. Ahmad, X. Liao, and S. Nazir, "Evaluation and Quality Assurance of Fog Computing-Based IoT for Health Monitoring System," *Wireless Communications and Mobile Computing*, vol. 2021. 2021, doi:

10.1155/2021/5599907.

- [36] V. K. Quy, N. Van Hau, D. Van Anh, and L. A. Ngoc, “Smart healthcare IoT applications based on fog computing: architecture, applications and challenges,” *Complex and Intelligent Systems*, vol. 8, no. 5. pp. 3805–3815, 2022, doi: 10.1007/s40747-021-00582-9.
- [37] Y. Xiao and M. Krunz, “AdaptiveFog: A Modelling and Optimization Framework for Fog Computing in Intelligent Transportation Systems,” *IEEE Transactions on Mobile Computing*, vol. 21, no. 12. pp. 4187–4200, 2022, doi: 10.1109/TMC.2021.3080397.
- [38] W. Yanez, R. Mahmud, R. Bahsoon, Y. Zhang, and R. Buyya, “Data Allocation Mechanism for Internet-of-Things Systems With Blockchain,” *IEEE Internet of Things Journal*, vol. 7, no. 4. pp. 3509–3522, 2020, doi: 10.1109/JIOT.2020.2972776.
- [39] A. H. Mayer, V. F. Rodrigues, C. A. Da Costa, R. Da Rosa Righi, A. Roehrs, and R. S. Antunes, “FogChain: A Fog Computing Architecture Integrating Blockchain and Internet of Things for Personal Health Records,” *IEEE Access*, vol. 9, pp. 122723–122737, 2021, doi: 10.1109/ACCESS.2021.3109822.
- [40] Y. I. Alzoubi and A. Aljaafreh, “Blockchain-Fog Computing Integration Applications: A Systematic Review,” *Cybernetics and Information Technologies*, vol. 23, no. 1. pp. 3–37, 2023, doi: 10.2478/cait-2023-0001.
- [41] C. Yapa, C. de Alwis, M. Liyanage, and J. Ekanayake, “Survey on blockchain for future smart grids: Technical aspects, applications, integration challenges and future research,” *Energy Reports*, vol. 7, pp. 6530–6564, 2021, doi: 10.1016/j.egyr.2021.09.112.
- [42] J. J. Hathaliya and S. Tanwar, “An exhaustive survey on security and privacy issues in Healthcare 4.0,” *Comput. Commun.*, vol. 153, no. February, pp. 311–335, 2020, doi: 10.1016/j.comcom.2020.02.018.
- [43] A. Haleem, M. Javaid, R. Pratap Singh, and R. Suman, “Medical 4.0 technologies for healthcare: Features, capabilities, and applications,” *Internet Things Cyber-Physical Syst.*, vol. 2, no. February, pp. 12–30, 2022, doi: 10.1016/j.iotcps.2022.04.001.

- [44] S. Al-Sofi, S. M. Astrojery, I. A. Ali, (2024). "IEEE 802.15.6 and LoRaWAN for WBAN in healthcare: A comparative study on communication efficiency and energy optimization." *Computers*, 13(12), 313. doi:<https://doi.org/10.3390/computers13120313>.
- [45] M. Bani Yassein, L. Al-Smadi, and L. Mryan, "A survey of mobile health applications in context of internet of things," *Proc. - 2019 Int. Conf. Futur. Internet Things Cloud, FiCloud 2019*, pp. 351–357, 2019, doi: 10.1109/FiCloud.2019.00058.
- [46] M. Abdel-basset, G. Manogaran, A. Gamal, and V. Chang, "Model Based on Soft Computing and IoT," *Ieee Internet Things J.*, vol. 7, no. 5, pp. 4160–4170, 2020.
- [47] A. Moubayed, "A Complete EDA and DL Pipeline for Softwarized 5G Network Intrusion Detection," *Future Internet*, vol. 16, no. 9. 2024, doi: 10.3390/fi16090331.
- [48] J. Lloret, L. Parra, M. Taha, and J. Tomás, "An architecture and protocol for smart continuous eHealth monitoring using 5G," *Comput. Networks*, vol. 129, pp. 340–351, Dec. 2017, doi: 10.1016/J.COMNET.2017.05.018.
- [49] X. Yan and X. Ren, "5G Edge Computing Enabled Directional Data Collection for Medical Community Electronic Health Records," *Journal of Healthcare Engineering*, vol. 2021. 2021, doi: 10.1155/2021/5598077.
- [50] F. Y. Wang, "Parallel Healthcare: Robotic Medical and Health Process Automation for Secured and Smart Social Healthcares," *IEEE Transactions on Computational Social Systems*, vol. 7, no. 3. pp. 581–586, 2020, doi: 10.1109/TCSS.2020.2995282.
- [51] A. A. Qawi Obaid, A. Selmi and A. A. Obaid (2022). "The reality of the awareness of the workers in the national health information center of the importance of big data: A survey study." in *Communications in Mathematics and Applications*, 13(2), 753-774. doi:<https://doi.org/10.26713/cma.v13i2.2031>
- [52] R. Rodríguez-Aguilar and J. A. Marmolejo-Saucedo, "Conceptual framework of digital health public emergency system: Digital twins and multiparadigm simulation," *EAI Endorsed Transactions on Pervasive Health and Technology*, vol. 6, no. 21. 2020, doi: 10.4108/eai.13-7-2018.164261.

- [53] D. Bernstein, “Containers and Cloud: From LXC to Docker to Kubernetes,” *IEEE Cloud Computing*, vol. 1, no. 3, pp. 81–84, 2014.
- [54] F. Bulut, “Determining Heart Attack Risk Ration Through AdaBoost / AdaBoost ile Kalp Krizi Risk Tespiti,” *Celal Bayar Üniversitesi Fen Bilim. Derg.*, vol. 12, no. 3, pp. 459–472, 2016, doi: 10.18466/cbayarfbe.280652.
- [55] F. Bulut, “Örnek Tabanlı Sınıflandırıcı Topluluklarıyla Yeni Bir Klinik Karar Destek Sistemi,” *J. Fac. Eng. Archit. Gazi Univ.*, vol. 32, no. 1, pp. 65–76, 2017, doi: 10.17341/gazimmfd.300595.
- [56] C. E. Ribeiro, L. H. S. Brito, C. N. Nobre, A. A. Freitas, and L. E. Zárata, “A revision and analysis of the comprehensiveness of the main longitudinal studies of human aging for data mining research,” *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 7, no. 3, Wiley-Blackwell, May 2017, doi: 10.1002/widm.1202.
- [57] L. Ivonin, H. M. Chang, M. Díaz, A. Català, W. Chen, and M. Rauterberg, “Beyond cognition and affect: Sensing the unconscious,” *Behav. Inf. Technol.*, vol. 34, no. 3, pp. 220–238, Mar. 2015, doi: 10.1080/0144929X.2014.912353.
- [58] Y. Huang, P. McCullagh, N. Black, and R. Harper, “Feature selection and classification model construction on type 2 diabetic patients’ data,” *Artif. Intell. Med.*, vol. 41, no. 3, pp. 251–262, Nov. 2007, doi: 10.1016/j.artmed.2007.07.002.
- [59] Y. Zhang, G. Chen, H. Du, X. Yuan, M. Cheriet, and M. Kadoch, “Real-time remote health monitoring system driven by 5G MEC-IOT,” *Electronics (Switzerland)*, vol. 9, no. 11, pp. 1–17, 2020, doi: 10.3390/electronics9111753.
- [60] M. Mahmeen, M. R. Melconian, S. Haider, M. Friebe, and M. Pech, “Next Generation 5G Mobile Health Network for User Interfacing in Radiology Workflows,” *IEEE Access*, vol. 9, pp. 102899–102907, 2021, doi: 10.1109/ACCESS.2021.3097303.
- [61] E. Mbunge, B. Muchemwa, S. Jiyane, J. Batani, “Sensors and healthcare 5.0: transformative shift in virtual care through emerging digital health technologies”, *Global Health Journal journal*, Kasım 2021.

- [62] H. Tokola, C. Gröger, E. Järvenpää, and E. Niemi, “Designing Manufacturing Dashboards on the Basis of a Key Performance Indicator Survey,” *Procedia CIRP*, vol. 57. pp. 619–624, 2016, doi: 10.1016/j.procir.2016.11.107.
- [63] A. Ivaschenko, A. R. Diyazitdinova, and T. Nikiforova, “Optimisation of the rational proportion of intelligent technologies application in service organisations,” *Organizacija*, vol. 54, no. 2. pp. 162–177, 2021, doi: 10.2478/orga-2021-0011.
- [64] Hossin M. and Sulaiman M.N, “ A review on evaluation metrics for data classification evaluations,” *International Journal of Data Mining & Knowledge Management Process*, vol. 5, no. 2. pp. 1–11, 2015.
- [65] J. Shi, G. He, and X. Liu, “Anomaly Detection for Key Performance Indicators Through Machine Learning,” *Proc. 2018 6th IEEE Int. Conf. Netw. Infrastruct. Digit. Content, IC-NIDC 2018*, pp. 1–5, 2018, doi: 10.1109/ICNIDC.2018.8525714.
- [66] R. J. Hyndman and Y. Khandakar, “Automatic time series forecasting: The forecast package for R,” *J. Stat. Softw.*, vol. 27, no. 3, pp. 1–22, 2008, doi: 10.18637/jss.v027.i03.
- [67] C. W. Chase, "Demand-Driven Forecasting : A Structured Approach to Forecasting, John Wiley & Sons, Incorporated, 2013.", in *ProQuest Ebook Central*, <https://ebookcentral.proquest.com/lib/ikbu-ebooks/detail.action?docID=1315864>.
- [68] R. Bedi, N. Verma, K. Gautam, and V. Agiwal, “Forecasting the Anti-Rabies Vaccine Demand at Jawaharlal Medical College and Hospital, Ajmer, Rajasthan: A Comparative Analysis based on Time Series Model,” *Indian J. Community Heal.*, vol. 33, no. 3, pp. 451–455, 2021, doi: 10.47203/IJCH.2021.V33I03.008.
- [69] R. J. Hyndman, G. Athanasopoulos, C. Bergmeir, “Estimation: Forecasting Time Series and Linear Model, R Package Version 80.3”, *Monash University, Australia*, 2018.
- [70] C. Erden, “Zaman Serisi Tahminleri ve ARIMA Modelleri,” *Çalışma Notları*. pp. 1–28, 2020.
- [71] W. C. Hong, “Hybrid Intelligent Technologies in Energy Demand Forecasting,”

- Hybrid Intelligent Technologies in Energy Demand Forecasting*. pp. 1–179, 2020, doi: 10.1007/978-3-030-36529-5.
- [72] M. D. Howell and J. P. Stevens, “Predictive Modeling 3.0: Machine Learning, in Understanding Healthcare Delivery Science, New York”, in *McGraw-Hill Education*, 2020. <https://accesspharmacy.mhmedical.com/content.aspx?bookid=2736§ionid=228657302>.
 - [73] Koushik, Raja B., and Ravindran, Sharan Kumar, "R Data Science Essentials : R Data Science Essentials", in *ProQuest Ebook Central*, Packt Publishing, Limited, 2016. <https://ebookcentral.proquest.com/lib/ikbu-ebooks/detail.action?docID=4520703>.
 - [74] R. Sathya and A. Abraham, “Comparison of Supervised and Unsupervised Learning Algorithms for Pattern Classification,” *Int. J. Adv. Res. Artif. Intell.*, vol. 2, Feb. 2013, doi: 10.14569/IJARAI.2013.020206.
 - [75] F. Sohil, M. U. Sohali, and J. Shabbir, "An introduction to statistical learning with applications in R," vol. 6, no. 1. Springer New York, 2022.
 - [76] F. Schwenker, “Ensemble Methods: Foundations and Algorithms [Book Review],” *IEEE Comput. Intell. Mag.*, vol. 8, no. 1, pp. 77–79, 2013, doi: 10.1109/mci.2012.2228600.
 - [77] M. Skurichina and R. P. W. Duin, “Bagging for linear classifiers,” *Pattern Recognit.*, vol. 31, no. 7, pp. 909–930, 1998, doi: 10.1016/S0031-3203(97)00110-6.
 - [78] T. C. Nokeri, “Data Science Solutions with Python: Fast and Scalable Models Using Keras, PySpark MLlib, H2O, XGBoost, and Scikit-Learn,” *Data Science Solutions with Python: Fast and Scalable Models Using Keras, PySpark MLlib, H2O, XGBoost, and Scikit-Learn*. pp. 1–119, 2021, doi: 10.1007/978-1-4842-7762-1.
 - [79] A. B. Hyndman, R. J., & Koehler, “Another look at measures of forecast accuracy. International Journal of Forecasting,” *International Journal of Forecasting*. pp. 679–688, 2006.
 - [80] S. C. Banerjee, S. Banerjee, and P. Rai, “Vaccine Supply Optimization and Forecasting using Random Forest and ARIMA Models,” *2022 IEEE 3rd Global*

Conference for Advancement in Technology, GCAT 2022. doi: 10.1109/GCAT55367.2022.9972154.

- [81] S. C. Banerjee, S. Banerjee, and R. K. Jain, "Vaccine Supply Forecasting and Optimization using Deterministic and Probabilistic Approaches," *2023 2nd International Conference for Innovation in Technology, INOCON 2023*. 2023, doi: 10.1109/INOCON57975.2023.10101255.
- [82] Junjie Liang; Huilin Yao; Jiayi Wang; Ya-Hui Jia, "Dynamic Information Mining Based Vaccine Distribution Strategy," *International Conference on Universal Village (UV)*, IEEE. doi: 10.1109/UV56588.2022.10185518.
- [83] M. Imran, J. Abdul, N. Abid, and A. Chohan, "Modeling Towards Pentavalent Vaccine Coverage in Pakistan," *Journal of University Medical & Dental College*, vol. 7, no. 1. pp. 41–46, 2016, [Online]. Available: <http://jumdc.com/index.php/jumdc/article/view/169>.
- [84] R. Bedi, N. Verma, K. Gautam, and V. Agiwal, "Forecasting the Anti-Rabies Vaccine Demand at Jawaharlal Medical College and Hospital, Ajmer, Rajasthan: A Comparative Analysis based on Time Series Model," *Indian Journal of Community Health*, vol. 33, no. 3. pp. 451–455, 2021, doi: 10.47203/IJCH.2021.V33I03.008.
- [85] G. Emmanuel, A. Ramadhan, M. Zarlis, E. Abdurachman, and A. Trisetyarso, "Machine learning in drug supply chain management during disease outbreaks: a systematic review," *International Journal of Electrical and Computer Engineering*, vol. 13, no. 5. pp. 5517–5533, 2023, doi: 10.11591/ijece.v13i5.pp5517-5533.
- [86] A. C. Brown, "Take the risk out of financial risk management", in *Financial Risk Management for Dummies*, A. W. Brand, Ed., USA: Wiley, ch.4-7, pp. 57-105.
- [87] C. Bernard, C. De Vecchi, S. Vanduffel, "The Impact of Correlation on (Range) Value at Risk", *Taylor & Francis*, vol.6, pp.531-564, Agust. 2023.
- [88] S. Boubaker, B. Buchanan, D. K. Nguyen, "Risk Management" in *Risk Management in Emerging Markets: Issues, Framework, and Modelling*, England, ENG, UK: Emerald Group Publishing, 2016, vol. 3, pp. 653-654.

- [89] W. Wang, Y. Yang, and S. Luo, "The max–min newsvendor pricing problem under conditional value-at-risk criterion," *Flexible Services and Manufacturing Journal*, vol. 36, no. 1. pp. 71–102, 2024, doi: 10.1007/s10696-022-09472-9.
- [90] W. Boehmer, "Cost-benefit trade-off analysis of an ISMS based on ISO 27001," *Proceedings - International Conference on Availability, Reliability and Security*, ARES 2009. Page: 392-399, DOI: 10.1109/ARES.2009.128, ISBN: 9780769535647.
- [91] R. Meyer, D. Krueger, "A Minitab Guide to Statistics", *Pearson Yayınları, London, UK*, 10 Agust 2004. 3. Baskı: 379. ISBN-13: 978-0131492721.
- [92] A. Hamlet *et al.*, "POLICI: A web application for visualising and extracting yellow fever vaccination coverage in Africa," *Vaccine*, vol. 37, no. 11. pp. 1384–1388, 2019, doi: 10.1016/j.vaccine.2019.01.074.
- [93] A. Aerts and D. Bogdan-Martin, "Leveraging data and AI to deliver on the promise of digital health," *International Journal of Medical Informatics*, vol. 150. 2021, doi: 10.1016/j.ijmedinf.2021.104456.
- [94] F. M. Shearer *et al.*, "Global yellow fever vaccination coverage from 1970 to 2016: an adjusted retrospective analysis," *The Lancet Infectious Diseases*, vol. 17, no. 11. pp. 1209–1217, 2017, doi: 10.1016/S1473-3099(17)30419-X.

EK A

A.1 TEZDEN ÜRETİLEN ÇALIŞMALAR

Bu çalışmadan üretilen yayın ve geliştirmeler aşağıda sıralanmaktadır.

1. ARIMA, SARIMA, Doğrusal Regresyon ve XGBoost ile Sarı Humma Aşısı Talebi Tahmini

IEEE Erişimi2024 |

Dergi makalesi DOI: [10.1109/ACCESS.2024.3517652](https://doi.org/10.1109/ACCESS.2024.3517652)

KATKIDA BULUNANLAR: N. Sen; L.Ö Temur; D.Ç. Atilla

<https://doi.org/10.1109/ACCESS.2024.3517652>

2. Bulut Tabanlı Yazılım Üzerinden Olgunluk Modellerinin Operasyonel, Finansal, Performans ve Risk Göstergeleri İçin Karar Destek Sistemi

2021 Uluslararası Mühendislik ve Gelişen Teknolojiler Konferansı (ICEET)

2021-10-27 | Konferans bildirisi

DOI: [10.1109/iceet53442.2021.9659584](https://doi.org/10.1109/iceet53442.2021.9659584)

KATKIDA BULUNANLAR: N. Şen; D. Ç. Atilla; O. Karan