T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ENERJİ TÜKETİMİ TAHMİNİNDE ZAMAN SERİSİ TABANLI ALGORİTMALARIN PERFORMANS ANALİZİ İÇİN ÜNİVERSİTE KAMPÜSÜ UYGULAMASI

Buğra KARAKOÇ

YÜKSEK LİSANS TEZİ

Elektrik Mühendisliği Anabilim Dalı

Elektrik Tesisleri Programı

Danışman

Dr. Öğr. Üyesi Ali DURUSU

Temmuz, 2024

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ENERJİ TÜKETİMİ TAHMİNİNDE ZAMAN SERİSİ TABANLI ALGORİTMALARIN PERFORMANS ANALİZİ İÇİN ÜNİVERSİTE KAMPÜSÜ UYGULAMASI

Buğra KARAKOÇ tarafından hazırlanan tez çalışması 09.07.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Tesisleri Anabilim Dalı, Yüksek Lisans Programı **YÜKSEK LİSANS** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Ali DURUSU
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Ali DURUSU, Danışman
Yıldız Teknik Üniversitesi _____

Doç. Dr. Bedri KEKEZOĞLU, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Hakan AKÇA, Üye
Ege Üniversitesi _____

Danışmanım Dr. Öğr. Üyesi Ali DURUSU sorumluluğunda tarafımca hazırlanan "Enerji Tüketimi Tahmininde Zaman Serisi Tabanlı Algoritmaların Performans Analizi İçin Üniversite Kampüsü Uygulaması" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Buğra KARAKOÇ

İmza

Aileme

ve

Sevdiklerime

TEŞEKKÜR

Bu yüksek lisans tezinin tamamlanmasında değerli katkıları ve destekleriyle her zaman yanımda olan danışman hocam Ali DURUSU ‘ya sonsuz minnetlerimi sunarım. Hocamızın engin bilgi birikimi, keskin analitik bakış açısı ve yönlendirmesi olmadan bu tezin başarılı bir şekilde tamamlanması mümkün olmazdı. Çalışmamızın kalitesini ve etkisini artırmak için gösterdiği üstün çaba ve sonsuz desteği için kendisine en içten teşekkürlerimi sunarım.

Ayrıca, bu akademik yolculuğumda beni bugünlere getiren değerli aileme ve her zaman destek veren arkadaşlarıma da sonsuz teşekkürler. Sizlerin sağladığı maddi ve manevi destekler olmadan bu başarıyı elde etmem mümkün olmazdı. Beni yetiştirip bugünlere taşıyan, her zaman arkamda duran ve bana güvenen ailemle, zorlukları birlikte aşan değerli arkadaşlarım, hepinize ne kadar minnettarsam o kadar da sizleri seviyorum.

Bu değerli deneyim, bana gelecekteki çalışmalarım için de ışık tutacaktır. Hepinizin katkısıyla elde ettiğim bu başarı, beni daha da motive ediyor ve hedeflerime ulaşma konusunda daha da kararlı olmamı sağlıyor. Sonsuz teşekkürler.

Buğra KARAKOÇ

İÇİNDEKİLER

TEŞEKKÜR v
KISALTMA LİSTESİ viii
ŞEKİL LİSTESİ ix
TABLO LİSTESİ x
ÖZET xi
ABSTRACT xiii
1 GİRİŞ 1
1.1 Literatür Taraması 1
1.2 Tezin Amacı 6
1.3 Literatüre Katkı 7
2 TALEP TARAFI TAHMİNİ 9
2.1 Tahmin Metotları 9
2.1.1 Holt-Winters'ın Mevsimsel Üstel Düzgünleştirme Yöntemi 10
2.1.2 Mevsimsel ARIMA (SARIMA) 17
2.2 Model Performans Değerlendirme Kriterleri 20
2.2.1 MAPE 20
2.2.2 MAE 22
2.2.3 AIC (Akaike Bilgi Kriteri) ve BIC (Bayesian Bilgi Kriteri) 23
2.2.4 LOGL (log-Olasılığı) 24
3 TAHMİN YÖNTEMİ GELİŞTİRİLMESİ 25
3.1 Veri Setinin İncelenmesi 27
3.1.1 Zaman Serisinin Mevsimsellik Analizi 28
3.2 Metodoloji 30
3.2.1 Veri Setinin Düzeltilmesi 32
3.2.2 SARIMA (Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama Modeli) 36
3.2.3 Holt Winter's Mevsimsel Üstel Düzgünleştirme Metoduyla Tahmin Yapılması 46
4 TAHMİN SONUÇLARININ DEĞERLENDİRİLMESİ 50

4.1 Holt Winter’s Mevsimsel Üstel Düzgünleştirme Modeli 50
4.2 SARIMA Modeli Sonuçlarının Değerlendirilmesi 52
5 SONUÇ **56**
KAYNAKÇA **58**
TEZDEN ÜRETİLMİŞ YAYINLAR **61**

KISALTMA LİSTESİ

ADF	Genişletilmiş Dickey-Fuller
AIC	Akaike Bilgi Kriteri
ANN	Yapay Sinir Ağları
ARIMA	Otoregresif Bütünleşik Hareketli Ortalama
BIC	Bayesian Bilgi Kriteri
CNN	Evrişimsel Sinir Ağları
FFN	İleri Beslemeli Ağlar
GRU	Geçitli Tekrarlayan Birimler
IQR	Çeyrekler Arası Aralık
LOGL	Log-Olasılığı
LSTM	Uzun Kısa Vadeli Hafıza
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hatası
MARS	Çok Değişkenli Uyarlanabilir Regresyon Spline
MSE	Ortalama Karesel Hata
RNN	Tekrarlayan Sinir Ağları
RMSE	Ortalama Karesel Hatanın Kökü
SARIMA	Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama
SHAP	Shapley'in Eklemeli Gösterimler Metodu
STL	Mevsimsel Trend Ayrıştırma
SVR	Destek Vektör Regresyonu

ŞEKİL LİSTESİ

Şekil 3.1 Zaman serisi modellemesi ve tahmini genel akış diyagramı 26
Şekil 3.2 Veri setinin grafiksel gösterimi 27
Şekil 3.3 İşlenmemiş veri setine ait dekompozisyon grafiği 28
Şekil 3.4 Veri analizi ve tahminine genel bakış diyagramı 31
Şekil 3.5 Veri normalizasyon işlemleri uygunlandıktan sonraki veri setinin grafiksel gösterimi 33
Şekil 3.6 Düzenlenmiş veri setinin dekompozisyon grafiği 34
Şekil 3.7 SARIMA akış diyagramı 38
Şekil 3.8 Düzenlemiş veri setinin otokorelasyon ve kısmi otokorelasyon grafikleri 41
Şekil 3.9 Düzenlenmiş veri setinin kutu grafiği 42
Şekil 3.10 SARIMA tahmin grafiği 45
Şekil 3.11 Holt Winter's mevsimsel üstel düzgünleştirme tahmin yönteminin sonuç grafiği 48
Şekil 4.1 Holt Winter's mevsimsel üstel düzgünleştirme yöntemi detaylı tahmin grafiği 50
Şekil 4.2 SARIMA yöntemi tahmin sonuç grafiği 52
Şekil 4.3 SARIMA tahminine ait standart dağılım ve istatistiksel analiz grafikleri 54

TABLO LİSTESİ

Tablo 3.1 İşlenmemiş veri setine ait istatistiksel tablo.....29
Tablo 3.2 Düzenlenmiş veri setine ait istatistiksel bilgiler 34
Tablo 3.3 ADF test istatistiği sonuçları.....39
Tablo 3.4 SARIMA AIC değerlerine göre model parametre tablosu 44
Tablo 3.5 Seçilen SARIMA modeli için performans kriterleri.....45
Tablo 4.1 Holt Winter's mevsimsel üstel düzgünleştirme modeli için tahmin ve gerçek değer kıyaslama tablosu 51
Tablo 4.2 SARIMA modeli için tahmin ve gerçek değer kıyaslama tablosu.....53
Tablo 4.3 SARIMA ve Holt Winter's mevsimsel üstel düzgünleştirme metodu kıyaslama tablosu.....55

ÖZET

Enerji Tüketimi Tahmininde Zaman Serisi Tabanlı Algoritmaların Performans Analizi İçin Üniversite Kampüsü Uygulaması

Buğra KARAKOÇ

Elektrik Tesisleri Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Ali DURUSU

Elektrik tüketimi tahmini, etkili enerji yönetimi için çok önemlidir. Kamu hizmetlerinin ve işletmelerin gelecekteki talebi doğru ve verimli bir şekilde planlamasına olanak tanır. Tahmin modelleri, çeşitli zaman ufuklarında gelecekteki elektrik kullanımını öngörmek için geçmiş tüketim modellerini, hava durumu verilerini, ekonomik göstergeleri ve diğer ilgili faktörleri analiz eder. Bu tahminler kaynak tahsisini, şebeke operasyonlarını ve altyapı planlamasını optimize etmek için gereklidir ve sonuçta maliyet tasarrufuna, şebeke güvenilirliğine ve sürdürülebilirlik çabalarına katkıda bulunur. Makine öğrenimi algoritmaları ve istatistiksel yöntemler gibi gelişmiş tahmin teknikleri, elektrik tüketimi tahminlerinin hassasiyetini ve güvenilirliğini artırmaktadır. Bu da paydaşların dinamik enerji ortamında bilinçli kararlar almasını sağlıyor. Bu çalışmada, Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) ve Holt Winter's mevsimsel üstel düzgünleştirme teknikleri ile 5 yıllık elektrik tüketimi verileri kullanılarak 6 aylık elektrik tüketimi tahmini yapılmıştır. Çalışmanın doğruluğu AIC (Akaike Bilgi Kriteri) ve ortalama mutlak yüzde hata (MAPE) matrisi kullanılarak ölçülmüştür. Sonuçlar, tahminin büyüklüğü ve tutarlılığı nedeniyle literatür için kayda değer bir çalışmadır.

Anahtar Kelimeler: Elektrik tüketimi, SARIMA, MAPE, Holt Winter's üstel düzgünleştirme

ABSTRACT

A University Campus Application For The Performance Analysis Of Time Series Based Algorithm In Energy Consumption Forecasting

Buğra KARAKOÇ

Department of Electrical Engineering

Master of Science

Supervisor: Assist.Prof. Dr. Ali DURUSU

Electricity consumption forecasting is crucial for effective energy management. It allows utilities and businesses to plan for future demand accurately and efficiently. Forecasting models analyse historical consumption patterns, weather data, economic indicators, and other relevant factors to project future electricity usage over various time horizons. These forecasts are essential for optimizing resource allocation, grid operations, and infrastructure planning, ultimately contributing to cost savings, grid reliability, and sustainability efforts. Advanced forecasting techniques, such as machine learning algorithms and statistical methods, are improving the precision and reliability of electricity consumption predictions. This empowers stakeholders to make informed decisions in the dynamic energy landscape. In this study, we estimated a 6-month electricity consumption forecast using 5 years of electricity consumption data with Seasonal Autoregressive Integrated Moving Average (SARIMA) and Holt Winter's seasonal exponential smoothing techniques. The study's accuracy was measured using the AIC (Akaike Information Criteria) and Mean Absolute Percentage Error (MAPE) matrix. The results are significant for the literature due to the forecast's size and accuracy.

Keywords: Electricity consumption, SARIMA, MAPE, Holt Winter's exponential smoothing.

1
GİRİŞ

1.1 Literatür Taraması

Elektrik tahmini, enerji sistemlerinin etkin planlanması, yönetimi ve optimizasyonunda önemli bir rol oynayan kritik ve çok yönlü bir süreçtir. İncelenen araştırma, geçmiş tüketim verileri, hava koşulları, ekonomik göstergeler, demografik değişkenler ve teknolojik gelişmeler de dahil olmak üzere çok çeşitli faktörlerin analizini içeren bu çalışmanın kapsamını vurgulamaktadır.

Enerji talep tahmininin önemine ilişkin çalışmalar incelendiğinde, Hyndman'ın araştırmasındaki SARIMA modellerinin zaman serisi tahmininde uygulamasına rastlıyoruz. Araştırma, R programlama dilinde forecast paketini kullanarak zaman serisi tahmininde nasıl başarılı sonuçlar elde edileceğini göstermekte ve bu yaklaşımın Python programlama dili için de uyarlanabileceğini göstermektedir. Zaman serisi tahmininde, enerji talep tahmininin önemi giderek artmakta ve enerji sektöründe stratejik karar alma aşamasında kritik bir rol oynamaktadır. Enerji talep tahmininde enerji sektöründe faaliyet gösteren şirketler ve kurumlar, enerji üretim ve dağıtımını planlamak, enerji maliyetlerini azaltmak ve enerji arz güvenliği sağlamak için enerji talep tahminine ihtiyaç duymaktadır. Bu sebeple, enerji talep tahmininde kullanılan yöntemlerin doğruluğu ve sürekliliği son derece önemlidir. Hyndman'ın araştırmalarındaki SARIMA modellerinin uygulanması, enerji talep tahmininde daha fazla doğruluk ve süreklilik sağlamaktadır [1].

Araştırmacılar, elektrik talebini yüksek doğrulukla tahmin etmek için zaman serisi tahmin modellerinin, özellikle SARIMA gibi, uygulanmasını aktif olarak araştırmaktadır. Bu, özellikle Ulusal Elektrik Piyasası'nın önemli engellerle karşılaştığı Queensland, Avustralya gibi bölgelerde, enerji sektöründe sürdürülebilirlik sorunlarının ele alınması için çok önemlidir. Elektrik talebinin doğru tahmin edilmesi, enerji üretimini ve dağıtımını optimize etmek için kritik bir adımdır. Hyndman'ın araştırması, sağlam tahmin modelleri geliştirmek için Python'a uyarlanabilen R'daki forecast paketinin kullanımına ilişkin değerli bilgiler sağlamıştır. Bu paket, gelecekteki elektrik talebini tahmin etmek için kullanılabilecek bir dizi yöntem sunar [2].

Bir çalışmada, araştırmacılardan oluşan bir ekip 0,5, 1 ve 24 saatlik aralıklarla elektrik talebini tahmin etmek için yenilikçi veri odaklı teknikler kullanmıştır. İstatistiksel olarak anlamlı gecikmeli girdileri içeren çok değişkenli uyarlanabilir regresyon spline (MARS), destek vektör regresyonu (SVR) ve otoregresif entegre hareketli ortalama (ARIMA) modellerini kullandılar. Bu yöntemler, farklı zaman aralıklarında elektrik talebinin tahmin edilmesine olanak sağlar. Sonuçlar, enerji yönetimi politikalarını optimize etmek isteyen mühendisler, enerji sağlayıcıları, tüketiciler için değerli bilgiler sağlamıştır. Daha verimli enerji yönetim sistemlerinin geliştirilmesi için bu bulgu, enerji sektöründe sürdürülebilirlik sorunlarının ele alınması için kritik bir adımdır [3].

Son yıllarda araştırmacılar, elektrik tüketim modellerini tahmin etmek için gelişmiş istatistiksel modellerin ve makine öğrenimi algoritmalarının uygulanmasını aktif olarak araştırmaktadır. Böyle bir çalışmada, mikro şebeke tabanlı bir eğitim binasının elektrik tüketimini tahmin etmek için SARIMA ve yapay sinir ağı (YSA) modelleri geliştirilmiştir. Sonuçlar, YSA modellerinin SARIMA modellerinden daha iyi performans göstererek daha doğru ve tutarlı tahminler sağladığını ortaya koymuştur. Bu bulgu, daha verimli enerji yönetim sistemlerinin geliştirilmesi için önemli çıkarımlara sahiptir. Ayrıca, bu çalışmanın sonuçları, mikro şebeke tabanlı eğitim binalarının elektrik tüketimini tahmin etmek için yapay sinir ağı modellerinin kullanılabileceğini göstermiştir. Bu, enerji yönetiminde yeni bir yaklaşım olabilir [4].

Diğer bir araştırma grubu, enerji tüketim modellerini tahmin etmek için SARIMA ve doğrusal olmayan otoregresif sinir ağı (NARNET) modellerini kullanarak bir üniversite kampüsünde gerçek bir vaka çalışması yürütmüştür. Bu çalışmada, araştırmacılar, enerji tüketim modellerinin davranışını tanımlamak ve gerçek zamanlı dalgalanmaları tahmin etmek için NARNET modelinin SARIMA modelinden daha iyi performans gösterdiğini bulmuşlardır. Bu sonuç, enerji tüketimi tahminlerinin doğruluğu enerji planlaması ve yönetimi üzerinde doğrudan bir etkiye sahip olduğundan, belirli bağlamlar için en uygun tahmin modelini seçmenin önemini vurgulamaktadır [5].

Günümüzde, enerji talebi tahmini için geliştirilmiş yöntemler giderek artan bir önem taşımaktadır. Çin'den araştırmacılar, orta vadeli elektrik talebi tahmini için geliştirilmiş bir varyasyonel mod ayrıştırma (VMD) tekniğini bir serçe arama algoritması ile optimize edilmiş bir aşırı öğrenme makinesi (ELM) modeliyle birleştiren yeni bir yaklaşım önermişlerdir. Bu yenilikçi yaklaşım, elektrik talebi tahmininin doğruluğunu önemli ölçüde artırarak daha etkili enerji planlaması ve yönetimi sağlama potansiyeline sahiptir. Ayrıca, bu yaklaşım, enerji sektöründe sürdürülebilirlik sorunlarının ele alınmasına yardımcı olabilir [6].

Ayrıca, bir başka araştırma elektrik talebi tahmini için klasik istatistiksel yöntemleri makine öğrenimi algoritmalarıyla birleştiren hibrit bir yaklaşımın etkinliğini incelemiştir. Bu yaklaşım, Ukrayna'da bir vaka çalışmasına uygulanarak araştırmacıların metodolojiyi ve elektrik talebinin tahmin edilmesindeki uygulamasını değerlendirmelerine olanak sağlamıştır. Çalışma, bu hibrit yaklaşımın özelliklerini, geleneksel tahmin yöntemlerine göre avantajlarını ve enerji planlaması ve yönetimi üzerindeki etkilerini incelemiştir. Bu sonuçlar, enerji talebi tahmini için geliştirilmiş yöntemlerin önemini vurgulamaktadır [7].

D. Hadjout ve ekibi çalışmalarında, Cezayir piyasasında elektrik tüketimini tahmin etmek için hibrit bir kümeleme ve derin öğrenme modeli geliştirilmiştir. Bu çalışma, gerçek dünya elektrik tüketim verileri kullanılarak değerlendirilmiş ve elde edilen sonuçlar doğruluk ve aykırı değerlere karşı sağlamlık açısından geleneksel tahmin yöntemlerinden daha iyi performans gösterdiğini ortaya koymuştur. Yazarlar, yaklaşımlarının, özellikle verilerde önemli aykırı değerler veya düzensizlikler bulunan piyasalarda elektrik tüketimi tahmini için etkili bir çözüm sağladığı sonucuna varmışlardır. Bu bilgi, güç sistemi planlaması, talep tarafı yönetimi ve enerji politikası karar verme süreçleri için çok önemlidir. Ayrıca, enerji sektöründe sürdürülebilirlik sorunlarının ele alınmasına yardımcı olabilir [8].

Bir başka çalışmada, yenilenebilir enerji kaynaklarının entegrasyonundan kaynaklanan şebeke belirsizliklerinin karmaşıklığı araştırılarak enerji sektöründe tahmin sistemlerinin rolü incelenmiştir. Enerji sektörü, tahmin yeteneklerini geliştirmek için AI, ICT ve IoT gibi en son teknolojilerden yararlanarak dijital bir dönüşüm geçiriyor. Gelecek vaat eden araçlardan biri, gelecekteki enerji taleplerini tahmin etmenin karmaşıklığını netleştiren yapay zekâ odaklı bir yaklaşım olan Shapley'in eklemeli gösterimler (SHAP) metodu'dur [9].

Araştırmacılar ayrıca gelecekteki elektrik talebini tahmin etmek için yedi yıllık verileri kullanarak istatistiksel modeller geliştirdiler. Holt-Winters mevsimsellik ve SARIMA modellerinin performansını karşılaştırarak verilerin mevsimsel ve trend bileşenlerini değerlendirdiler. Bulgular, Holt-Winters'ın eklemeli trend ve mevsimsellik ile en düşük ortalama mutlak yüzde hatayı verdiğini ve elektrik talebi tahmini için uygun bir yöntem olduğunu göstermektedir [10].

Bir diğer çalışma, altı daireli bir bina senaryosu için yapılan bilgisayar simülasyonları, önerilen çerçevenin genel enerji maliyeti açısından farklı teknik çözümlerin etkinliğini doğru bir şekilde değerlendirebileceğini göstermiştir. Bu, mikro şebeke tasarımı sırasında karar verme sürecine yardımcı olmaktadır. Simülasyon sonuçları, enerji tasarrufu ölçümlerinin optimize edilmesi ve enerji maliyetlerinin düşürülmesi için çerçeveyi doğrulamıştır. Buna ek olarak, simülasyonlar, binanın enerji verimliliği için en uygun tasarım seçeneklerini belirlemektedir [11].

Ayrı bir çalışmada, gerçek bir dağıtık rüzgar-hibrit mikro şebekenin yüksek doğruluklu bir MATLAB-Simulink modeli geliştirilmiş ve sonuçlar mikro şebekenin ekonomik ve esnek çalışmasını yüksek doğrulukla göstermiştir. Bu çalışmada, mikro şebekenin enerji üretim miktarı, enerji depolama cihazlarının performansı ve elektrik yükü verileri birlikte incelenmiştir. Araştırma, mikro şebekenin tasarımında ve işletiminde elektrik yükü tahminine dayalı karar verme süreçlerini iyileştirmeye yardımcı olmaktadır [12].

Araştırmacılar, MAPE kullanarak ARIMA ve yapay sinir ağı dahil olmak üzere farklı tahmin yöntemlerinin performansını karşılaştırmıştır. İrlanda'da rastgele seçilen 709 hanenin 18 aylık bir dönemdeki günlük gerçek yük elektrik verilerine dayanan çalışma, YSA'nın doğrusal olmayan yük verileri için ARIMA'dan daha iyi performans gösterdiğini ortaya koymuştur. Bu sonuçlar, elektrik yükü tahmininde yapay sinir ağlarının etkinliğini doğrulamıştır [13].

Bir başka çalışma, Assam'daki elektrik yükünü (L) tahmin etmek için veriye dayalı bir tahmin şeması geliştirmeye odaklanmıştır. Araştırmada, SLDC, Kahilipara, Assam'dan elde edilen günlük 24 saatlik L verileri kullanılarak ARIMA ve SARIMA olmak üzere iki tür regresyon modeli kullanılmıştır.

Çalışma, tahmin modelini oluşturmak için girdi verilerini eğitim ve test verileri olmak üzere iki gruba ayırarak modellerin performansını değerlendirmiştir. Tahmin modellerinin doğruluğu farklı hata matrisleri kullanılarak değerlendirilmiştir. Sonuçlar, yük verilerindeki mevsimselliği dikkate alan SARIMA modelinin düşük MAPE değeri ile daha doğru tahminler ürettiğini göstermektedir. Araştırma, elektrik yükü tahmininde SARIMA modelinin etkinliğini doğrulamıştır [14].

2025 tahmin modelinin incelenmesi, zaman serisi modellerinin tahmin performansını artırmak için kullanılabilecek içgörüler sağlamıştır [15]. Dikkat tabanlı tekrarlayan sinir ağları (RNN'ler), [16] ve [17] çalışmalarında kanıtlandığı üzere, daha önceki istatistiksel ve makine öğrenimi yaklaşımlarına kıyasla volatiliteyi ele almada üstün performans sergilemiştir. Bununla birlikte, bir dizi koşulda sağlamlık açısından hala iyileştirme kapsamı vardır [18].

2030 incelemesine bakıldığında, dönüştürücü derin öğrenme ve yapay zeka teknolojilerinin zaman serisi tahmininde yeni sınırların kilidini açması beklenmektedir. Araştırmacılar, kapsamlı etiketsiz veri kümeleri üzerinde modelleri eğitmek için yenilikçi kendi kendine denetimli öğrenme yöntemlerini araştıracaklardır [19]. Bu yaklaşım, geçmiş etiketli verilerin yokluğundan kaynaklanan sınırlamaların üstesinden gelmeyi amaçlamaktadır [20].

Hesaplama gücü ve donanımdaki gelişmeler, yüksek performanslı hesaplama kümelerinde trilyonlarca parametreye sahip önemli ölçüde daha büyük transformatör, evrişimsel sinir ağı (CNN) ve RNN mimarilerinin eğitimini kolaylaştıracaktır [21]. Bu daha büyük modeller, zaman serisi verilerindeki son derece karmaşık örüntüleri tanımlayabilir [22].

Görüntü transformatörü [23], graf sinir ağları [24] ve bilgisel damıtma [25] yapılandırılmış, yapılandırılmamış ve ilişkisel verilerin çok modlu füzyonu için güçlü tekniklerdir. Bu teknikler, modellerin zamansal bağımlılıklar ve dış etki faktörleri hakkında akıl yürütme yeteneklerini önemli ölçüde geliştirir.

2030 yılına gelindiğinde, alanlar arasında sürekli kendi kendine denetimli ön eğitim ve transfer öğrenimi, son derece genelleştirilebilir tahmin çerçeveleri sağlayacaktır [26].

Nihai hedef, yapay zeka destekli tahminlerin çeşitli uygulamalarda insan düzeyinde doğruluğa ulaşması ve hatta bunu aşmasıdır [27]. İlerlemenin devam etmesiyle birlikte, 2030 yılına kadar yeni bir optimal tahmin analitiği çağına ulaşmayı bekleyebiliriz.

Bu çalışmalar toplu olarak, sürdürülebilir enerji yönetimi için doğru elektrik talebi tahmininin önemini vurgulamaktadır. Araştırmacılar, gelişmiş istatistiksel modellerden, makine öğrenimi tekniklerinden ve yapay zekâ odaklı yaklaşımlardan yararlanarak, enerji sektöründe bilinçli karar vermeyi destekleyen etkili tahmin yöntemleri geliştirebilirler. Gelişmiş istatistiksel modellerin, makine öğrenimi algoritmalarının ve hibrit yaklaşımların entegrasyonu, elektrik talebi tahmini alanında devrim yaratma potansiyeline sahiptir. Dünya daha sürdürülebilir ve merkezi olmayan bir enerji sistemine doğru geçiş yaptıkça, doğru ve güvenilir tahmin modellerinin geliştirilmesi giderek daha önemli hale gelecektir. Araştırmacılar, bu son teknoloji yaklaşımlardan yararlanarak daha verimli, sürdürülebilir ve dirençli bir enerji sektörü yaratmak için birlikte çalışabilirler.

1.2 Tezin Amacı

Elektrik tahmini, enerji sistemlerinin etkin planlanması, yönetimi ve optimizasyonunda çok önemli bir rol oynayan çok yönlü ve karmaşık bir süreçtir. Bu kapsamlı analiz, bu çabaya dahil olan çeşitli faktörleri ve teknikleri titizlikle inceleyerek gelecekteki elektrik tüketimini doğru bir şekilde tahmin etmenin önemini aydınlatmayı amaçlamaktadır.

Elektrik tahminlerinin özünde, araştırmacıların ve analistlerin karmaşık kalıpları tanımlamalarına, altta yatan eğilimleri ayırt etmelerine ve mevsimsel değişimleri tanımalarına olanak tanıyan geçmiş tüketim verilerinin titizlikle toplanması ve titiz bir şekilde analiz edilmesi yatmaktadır.

Literatürde' ki çalışmalara bakıldığında verilerdeki karmaşık ilişkileri yakalamak için zaman serisi analizi, regresyon modellemesi ve ARIMA modellerinin yanı sıra yapay sinir ağları ve destek vektörleri gibi en yeni makine öğrenimi algoritmaları da dahil olmak üzere gelişmiş istatistiksel tekniklerin uygulanması araştırılmaktadır.

Enerji ortamı, yenilenebilir enerji kaynaklarının artan entegrasyonu ve akıllı teknolojilerin yaygınlaşmasıyla gelişmeye devam ettikçe, doğru ve uyarlanabilir tahmin modellerinin önemi daha da artmaktadır. Bu akademik çalışma, hızla değişen enerji ortamının dinamik zorluklarını ele almada sürekli uygunluklarını ve etkinliklerini sağlamak için bu modellerin sürekli izlenmesi, titiz bir şekilde doğrulanması ve stratejik olarak yeniden kalibre edilmesine duyulan zorunlu ihtiyacı vurgulamaktadır.

Çalışma ayrıca, enerji tahminlerinin doğruluğunu, şeffaflığını ve yorumlanabilirliğini artırmak için SARIMA gibi gelişmekte olan teknolojilerin potansiyelini araştırmaktadır. Bu gelişmeler, tahmin modellerini daha da iyileştirme ve enerji tahsisi ve dağıtımını optimize etme ve nihayetinde daha sürdürülebilir ve dirençli enerji sistemlerinin geliştirilmesine katkıda bulunma vaadini taşımaktadır.

Sonuç olarak, bu kapsamlı analiz elektrik tahminlerinin enerji sektöründeki kritik rolünün altını çizmektedir.

Bu sürecin çok yönlü doğasını, gelişmiş analitik tekniklerin uygulanmasını ve çeşitli paydaşlar için geniş kapsamlı sonuçlarını ortaya koyan bu çalışma, bu alanda sürekli araştırma ve yeniliğe ilham vermeyi ve dünya çapında enerji sistemlerinin uzun vadeli sürdürülebilirliğini ve dayanıklılığını sağlamayı amaçlamaktadır.

1.3 Literatüre Katkı

Bu yüksek lisans tezi, bir üniversite kampüsü bağlamında gelişmiş zaman serisi modelleme tekniklerinin performansı ve uygulanabilirliği hakkında değerli bilgiler sunmaktadır. Çalışma, yaygın olarak kullanılan SARIMA ve Holt-Winters mevsimsel üstel düzgünleştirme yöntemlerinin tahmin yeteneklerini karşılaştırarak bu yöntemlerin güçlü yönleri ve sınırlılıkları hakkında kapsamlı bir değerlendirme sunmaktadır.

Metodolojik gelişme anlamında ise zaman serisi verilerinin tutarlılığını ve güvenilirliğini garanti altına almak için titiz bir veri ön işleme ve normalleştirme metodolojisi kullanılmıştır. Bu, gerçek dünya enerji tüketimi veri kümeleri bağlamında yaygın sorunlar olan eksik değerlerin ve aykırı değerlerin yönetimini gerektirmiştir.

Özellikle SARIMA modellemesinin uygulanması, yöntemin elektrik tüketim verilerinin doğasında bulunan karmaşık mevsimsel kalıpları ve eğilimleri yakalamadaki etkinliğini göstermiştir.

Karşılaştırmalı bir analiz ve bu analizden elde edilen içgörüler burada sunulmaktadır. SARIMA ve Holt-Winters mevsimsellik modelinin karşılaştırmalı analizi, model karmaşıklığı, yorumlanabilirliği ve tahmin gücü arasında önemli ilişkiler olduğunu ortaya koymuştur. Holt-Winters mevsimsellik yaklaşımı daha basit ve kullanıcı dostu bir tahmin çözümü sunsa da, SARIMA modeli elektrik tüketim verilerinin altında yatan dinamiklerin daha sofistike bir temsilini sağlamıştır. Bu içgörü, doğru tahmin ihtiyacını model uygulama ve yorumlamanın pratik hususlarıyla dengeleme pratiğiyle uğraşanlar için değerlidir.

2
TALEP TARAFI TAHMİNİ

Talep tarafı tahmini, kamu hizmetlerinin ve şebeke operatörlerinin müşterilerinin muhtemel elektrik tüketim modellerini anlamalarını ve tahmin etmelerini sağladığından, güç sistemi planlaması ve işletmesinin önemli bir unsurudur. Bununla birlikte, enerji sektöründe talep tarafı tahmini ile ilgili bazı önemli zorluklar bulunmaktadır.

Kritik sorunlardan biri, dağıtık enerji kaynaklarının (DER'ler), elektrikli araçların ve akıllı ev teknolojilerinin giderek daha fazla benimsenmesi gibi faktörler nedeniyle elektrik talebinin artan karmaşıklığıdır [28]. Yeni teknolojilerin ve tüketici eğilimlerinin ortaya çıkması, elektrik talebi modelleri üzerinde derin bir etkiye sahip olabilir ve gelecekteki talebi doğru bir şekilde tahmin etme görevini daha zor hale getirebilir [29]. Araştırmacılar, modern elektrik talebinin karmaşıklığını ele almak için yapay sinir ağları, bulanık mantık ve hibrit modeller de dahil olmak üzere bir dizi gelişmiş tahmin tekniğini incelemişlerdir [30, 31].

Elektrik talep tarafı tahmininde bir diğer kritik konu da hava koşullarının elektrik tüketimi üzerindeki etkisidir. Sıcaklık, nem ve diğer meteorolojik değişkenlerin ısıtma, soğutma ve elektriğe bağlı diğer hizmetlere olan talep üzerinde önemli bir etkisi olduğu açıktır [32]. Elektrik talebi tahminlerinin güvenilirliğini artırmak için hava durumu verilerini doğru bir şekilde dahil etmek ve hava durumuna duyarlı tahmin modelleri geliştirmek büyük önem taşımaktadır [33]. Meteorolojik verilerin talep tarafı tahmin modellerine dahil edilmesi, hava durumu tahminindeki gelişmelerle birleştiğinde, elektrik talebi tahminlerinin doğruluğunu artırma potansiyeline sahiptir [34].

2.1 Tahmin Metotları

Zaman serisi verilerinin doğru tahmini, iş dünyası ve finansın yanı sıra enerji ve ulaşım da dahil olmak üzere çeşitli alanlarda çok önemli bir görevdir. Zaman serisi tahmini için yaygın olarak kullanılan iki teknik Holt-Winters'ın mevsimsel yöntemi ve mevsimsel ARIMA'dır.

Bu çalışma, araştırmacılara ve uygulayıcılara kendi özel tahmin ihtiyaçları için en uygun yaklaşımı seçmelerinde yardımcı olmak amacıyla, bu iki yöntemin temel ilkelerini, güçlü yönlerini ve sınırlamalarını vurgulayarak ayrıntılı bir karşılaştırmasını sunmaktadır.

2.1.1 Holt-Winters'ın Mevsimsel Üstel Düzgünleştirme Yöntemi

Holt Winters'ın mevsimsel üstel düzgünleştirme yöntemini anlatmadan önce bu yöntemin temeli olan basit üstel düzgünleştirme yönteminden başlanması gerekirse, basit üstel düzgünleştirme, özellikle veriler bir eğilim veya mevsimsellik sergilediğinde, zaman serisi verilerini tahmin etmek için güçlü bir tekniktir. Yöntem, geçmiş gözlemlere azalan ağırlıklar atayarak daha yeni veri noktalarına daha yüksek önem verir. Bu, modelin eski veri noktalarını dikkate alırken verilerdeki değişikliklere hızlı bir şekilde yanıt vermesini sağlar. Sonraki dönem için tahmin, mevcut gözlemin ve önceki tahminin ağırlıklı ortalaması olarak hesaplanır ve ağırlık (yumuşatma parametresi) istenen yumuşatma seviyesine göre belirlenir.

Basit üstel düzgünleştirme Denklem 2.1 ile gösterilmiştir:

$$s_t = \alpha x_t + (1-\alpha)s_{t-1} = s_{t-1} + \alpha(x_t - s_{t-1}) \qquad (2.1)$$

Bu denklemde α, $0 \leq \alpha \leq 1$ olmak üzere düzeltme faktörünü temsil eder. Basit bir ifadeyle, düzleştirilmiş istatistik s_t mevcut gözlemin x_t ve önceki düzleştirilmiş istatistik s_{t-1}'in temel ağırlıklı ortalamasıdır.

Basit üstel düzleştirmenin uygulanması basittir ve iki gözlem mevcut olduğunda düzleştirilmiş bir istatistik üretir. "düzgünleştirme faktörü" terimine rağmen, daha büyük α değerleri aslında düzgünleştirme seviyesini azaltır. α = 1 olduğunda, çıktı serisi mevcut gözlemle aynıdır. α'nın 1'e yakın değerleri son veri değişikliklerine öncelik verirken, 0'a yakın olanlar yumuşatmayı vurgular ve son değişimlere daha az tepki verir. α = 0 olduğunda, çıktı serisi, t = 0 zamanında yumuşatma sürecinin başlangıcındaki x_0 ilk gözleminden itibaren sabit kalır. α'yı seçmek için standart bir yaklaşım yoktur. İstatistikçiler α'yı optimize etmek için kendi yargılarına veya istatistiksel yöntemlere güvenebilirler. Örnek olarak, en küçük kareler yöntemi, gözlenen ve tahmin edilen değerler $(s_t - x_{t+1})^2$ arasındaki karesel farkların toplamını en aza indirerek optimum α değerini belirleyebilir[35].

Zaman serisi analizi alanında, uygulayıcılar sıklıkla trendler ve mevsimsellik gibi karmaşık örüntüler sergileyen verilerle karşılaşırlar. Basit üstel düzleştirme durağan seriler için etkili olsa da bu karmaşık örüntülerle başa çıkmak için yetersizdir. Holt'un doğrusal trend yöntemi, basit üstel düzeltmenin sofistike bir uzantısı olup, doğrusal trend gösteren zaman serisi verilerini ele almak için özel olarak tasarlanmıştır.

Holt'un yönteminin temel yeniliği, iki farklı yumuşatma parametresi kullanmasında yatmaktadır. Bunlardan ilki olan α, basit üstel düzleştirmede olduğu gibi verilerin seviyesini düzleştirmeye adanmıştır. İkincisi, β, trend bileşenini yumuşatan yeni bir eklemedir. Bu çift parametreli yaklaşım, modelin verilerin hem seviyesindeki hem de eğilimindeki değişikliklere dinamik olarak adapte olmasını sağlayarak modeli gelişen modellere daha basit muadilinden çok daha duyarlı hale getirmektedir [35].

Şimdi bu yöntemin altında yatan matematiği inceleyelim. x_0, x_1, x_2, ... olarak gösterilen ve t = 0 zamanında başlayan orijinal bir veri gözlem dizisi ile başlıyoruz. t zamanındaki her noktada iki temel bileşen kullanıyoruz:

s_t: Bu, t zamanındaki düzeltilmiş değeri temsil eder. Serinin o noktadaki seviyesine ilişkin en iyi tahminimizdir.

b_t: Bu, t zamanındaki eğilime ilişkin en doğru tahminimizi temsil eder. Serinin artma veya azalma oranını yakalar.

Algoritmanın nihai amacı, x_{t+m} değerinin gelecekteki bir m> 0 zamanında bir yaklaşımı olan x_{t+m} değerini üretmektir. Bu tahmin, t zamanına kadar mevcut olan tüm ham verilere dayanmaktadır. Özünde, gelecek hakkında bir tahmin yapmak için mevcut bilgimizi kullanıyoruz [35].

Holt'un lineer trend yönteminin özeti, çift üstel düzleştirme olarakta bilinen metot Denklem 2.2 ile gösterilmiştir:

$$s_t = \alpha x_t + (1 - \alpha)(s_{t-1} + b_{t-1}) \tag{2.2}$$

Bu denklem tahmini seviyeyi günceller. Mevcut x_t gözleminin ve önceki tahminin ağırlıklı bir ortalamasıdır. α parametresi ($0 \leq \alpha \leq 1$), önceki tahmine karşı mevcut gözleme verilen göreceli ağırlığı belirler.

$$b_t = \beta(s_t - s_{t-1}) + (1 - \beta)b_{t-1} \quad (2.3)$$

Denklem 2.3 trend tahminimizi günceller. Mevcut eğilim tahmininin ve önceki eğilim tahmininin ağırlıklı ortalaması hesaplanır. ß parametresi ($0 \leq \beta \leq 1$) mevcut trend tahminine karşı bir öncekine verilen göreceli ağırlığı belirler.

Bu denklemlerin uyarlanabilir yapısı önemli bir avantajdır. Eğer α yüksekse, model seviyedeki değişikliklere hızla adapte olabilmektedir. Eğer ß yüksekse, model trenddeki değişikliklere hızla adapte olabilir. Bu esneklik modelin dinamik ortamlarda çevik kalmasını sağlar. Güncellenmiş seviye ve trend tahminleri hesaplandıktan sonra tahmin fonksiyonu Denklem 2.4'te gösterilmektedir:

$$F_{t+m} = s_t + m * b_t \quad (2.4)$$

Mevcut seviye tahmini s_t, mevcut trend tahmininin m katı olarak modele eklenir. Bu, modelin varsayımlarının mantıksal bir sonucudur. Serinin şu anda s_t seviyesinde olduğunu ve her dönem b_t kadar arttığını düşünürsek, bundan m dönem sonra mb_t kadar artmış olması gerekir.

Kritik bir soru ortaya çıkmaktadır: modeli nasıl başlatacağız? Özellikle, ilk trend tahmini b_0'yi nasıl seçeceğiz? Evrensel olarak üzerinde uzlaşılmış bir cevap yoktur; bu kişisel tercih ve alan bilgisi meselesidir.

$$b_0 = x_1 - x_0 \quad (2.5)$$

Denklem 2.5 başlangıç eğiliminin ilk iki gözlem arasındaki değişime eşit olduğunu varsayar. Zaman 0'a kadar olan verilerden zaman 0'ı tahmin etmek mümkün olmadığından x_0'nin tanımsız olduğuna dikkat etmek önemlidir. Ancak, tanım gereği, $s_0 = x_0$, olarak tanımlanmıştır. Bu, sonraki tüm tahminlerin hesaplanabileceği bir başlangıç noktası sağlar [35].

Holt'un doğrusal trend yöntemi, zaman serisi tahmininde önemli bir ilerlemeyi temsil etmektedir. Seviye ve trendi ayrı ayrı modelleyerek, basit üstel düzleştirmeden daha geniş bir gerçek dünya senaryosu yelpazesine uyum sağlar.

Bununla birlikte, birçok zaman serisi sadece trendler değil, aynı zamanda mevsimsel modeller de sergiler; örneğin dondurma satışlarının yazın zirve yapması veya perakende satışların tatillerde artması gibi. Bu tür karmaşıklıklarla başa çıkabilmek için Holt'un lineer trend yönteminin ötesine geçerek daha da karmaşık bir uzantısını Holt-Winters'ın mevsimsel yöntemini kullanmamız gerekir[35].

Çok sayıda zaman serisi verisinde, çok sayıda dizi mevsimsel bir ritim sergiler. Örnekler arasında tatillerde artan perakende satışlar, aşırı hava koşullarında zirve yapan enerji tüketimi veya yaz aylarında gelişen turizm sayılabilir. Holt'un doğrusal trend yöntemi trendleri ele almada usta olsa da bu mevsimsel ritimleri yakalayacak incelikten yoksundur. Holt-Winters'ın mevsimsel yöntemi, zaman serisi analizi alanında önemli bir ilerlemeyi temsil etmektedir. Bu yöntem, modelin hem trendi hem de mevsimselliği yakalama yeteneğini geliştirmek için üçüncü bir yumuşatma parametresi ekleyerek selefinin temel ilkeleri üzerine inşa edilmiştir [35].

Holt-Winter’s mevsimsel yöntemi, α, ß ve γ'dan oluşan ve toplu olarak modelin yalnızca değişen seviyelere ve trendlere değil aynı zamanda gelişen mevsimsel modellere de uyum sağlamasına olanak tanıyan üçlü bir parametre grubu sunar. Birçok gerçek dünya zaman serisine yayılan ince ritimleri tanımlayabilen ve tahmin edebilen oldukça etkili bir araçtır [35].

x_0, x_1, x_2, ... alt simgeleriyle gösterilen bir gözlem serisi t = 0 zamanında başlatılır. Seri, L uzunluğunda bir döngüye sahip mevsimsel bir modelle karakterize edilir. Örneğin, veriler yıllık mevsimsel modelle aylık olarak modellenirse, L = 12 olacaktır [35].

Holt-Winter’s mevsimsel yaklaşımı, ilk olarak veri için genel yörüngesini temsil eden bir trend çizgisi hesaplayan sofistike bir yöntemdir. Bu eğilim çizgisi daha sonra mevsimsel endekslerle kaplanır. Endeksler daha sonra trend çizgisi değerlerini mevsimsel döngüdeki mevcut konuma göre ayarlar. Örneğin trend çizgisi ılımlı bir satış tahminine işaret ediyorsa, ancak mevsimsel endeks şu anda tatil sezonunda olduğumuzu gösteriyorsa, mevsimsel endeks daha iyimser bir tahminle sonuçlanacaktır [35].

Bu yaklaşımda kullanılan metodoloji üç ana bileşenden oluşmaktadır:

t zamanındaki düzeltilmiş sabit değer, mevsimsellikten arındırılmış seviyeye ilişkin en iyi tahminimizi temsil etmektedir.

b_t: Mevsimsel değişimlerle entegre edilmiş optimal doğrusal trend tahminleri dizisi.

c_t: Verilerde gözlemlenen döngüsel kalıpları kapsayan mevsimsel düzeltme faktörleri dizisi.

Amaç, mevsimsel döngü içindeki her i noktasında c_i'yi tahmin etmektir; burada i, t zamanındaki L değerinin modunun alınmasına eşittir. Bu bilgi, yine aynı örnek üzerinden gitmemiz gerekirse, ocak ayı satışlarının trendin ne ölçüde üstünde veya altında olduğunu tespit etmemizi sağlar. Mevsimsel faktörlerin sağlamlığını sağlamak için tipik olarak en az iki tam sezon (2L dönem) geçmiş veriye sahip olmak gerekir.

Yöntemin özü, t zamanına kadar olan verilere dayanarak x_{t+m} tahminimizi temsil eden $\hat{x}_{t+m}$ çıktısını veren algoritmadır. Bu, geleceğe yönelik m adım atabilen tahmin modelimizdir. Bu tahmini yapmak için, dengelemeye çalıştığımız üç bileşeni yansıtan üçlü üstel düzleştirme kullanıyoruz: seviye, trend ve mevsimsellik.

Holt-Winters yönteminin, mevsimselliğin trendle etkileşim biçimine göre ayırt edilen iki çeşidi mevcuttur.

Çarpımsal mevsimsellik bağlamında, mevsimsel etkinin mevcut seviye ile orantılı olduğu Denklem 2.6 kullanılarak varsayılır [35].

$$s_t = \alpha \frac{x_t}{c_{t-L}} + (1-\alpha)(s_{t-1} + b_{t-1}) \tag{2.6}$$

Mevsimsel bileşen, son sezonun faktörüne bölünerek mevsimsellikten arındırılır ve ardından önceki seviye ve trend ile çarpılarak Denklem 2.7 ortaya çıkar [35].

$$b_t = \beta(s_t - s_{t-1}) + (1-\beta)b_{t-1} \tag{2.7}$$

Bunlar, Holt tarafından önerilen ve trend tahmininin güncellendiği lineer trend yöntemine benzer denklemlerdir [35].

$$c_t = \gamma \frac{x_t}{s_t} + (1-\gamma)c_{t-L} \tag{2.8}$$

Denklem 2.8'de ise, mevcut mevsimsel faktör x_t/s_t olarak tahmin edilir ve bir önceki sezonun faktörü ile harmanlanır. x_{t+m} ile gösterilen mevcut mevsimsel faktörün tahmini değeri Denklem 2.9'daki gibi hesaplanır:

$$F_{t+m} = (s_t + mb_t)c_{t-L+1+(m-1) mod\ L} \tag{2.9}$$

Bu değer daha sonra uygun mevsimsel faktör ile çarpılır.

Eklemeli mevsimsellik bağlamında, mevsimsel etkinin mevcut seviyeden bağımsız olarak sabit bir miktar olduğu Denklem 2.10'da varsayılır [35].

$$s_t = \alpha(x_t - c_{t-L}) + (1-\alpha)(s_{t-1} + b_{t-1}) \tag{2.10}$$

Geçen sezonun faktörünü çıkararak x_t'i mevsimsellikten Denklem 2.11'de arındırırız.

$$b_t = \beta(s_t - s_{t-1}) + (1-\beta)b_{t-1} \tag{2.11}$$

Bu bir önceki denklemle aynıdır.

$$c_t = \gamma(x_t - s_{t-1} - b_{t-1}) + (1-\gamma)c_{t-L} \tag{2.12}$$

Mevcut mevsimsel faktör Denklem 2.12'de x_t - s_t olarak tahmin edilir.

$$F_{t+m} = s_t + mb_t + c_{t-L+1+(m-1) mod\ L} \tag{2.13}$$

Denklem 2.13 fonksiyonunda seviye ve eğilim tahmin edilir, ardından uygun mevsimsel faktör eklenir.

Başlangıç sürecinin doğru şekilde yürütüldüğünden emin olmak büyük önem taşımaktadır. B_0 olarak belirlenen ilk trend tahmini aşağıdaki şekilde hesaplanır:

B_0, Denklem 2.14 kullanılarak hesaplanır:

$$b_0 = \frac{1}{L}\left(\frac{x_{L+1} - x_1}{L} + \frac{x_{L+2} - x_2}{L} + \cdots \frac{x_{L+L} - x_L}{L}\right) \tag{2.14}$$

Bu denklem, ilk tam sezon boyunca doğrusal bir eğilim olduğunu varsayar.

Başlangıçtaki mevsimsel endekslerin c_i (i = 1, 2, ..., L için) belirlenmesi daha karmaşık bir süreçtir. Veri seti N tam döngü içeriyorsa,

A_j ile gösterilen j. döngüdeki x'in ortalama değeri hesaplanacaktır.

Çarpımsal mevsimsellik durumunda, mevsimsel endeksler Denklem 2.15 kullanılarak hesaplanır:

$$A_j = \frac{\sum_{i=1}^{L} x_{L(j-1)+i}}{L} \tag{2.15}$$

Bu bağlamda, her mevsimin faktörü, döngü ortalamasından ortalama nispi sapması olarak tanımlanır [35].

Eklemeli mevsimsellik için c_i faktörü Denklem 2.16 ile hesaplanır:

$$c_i = \frac{1}{N}\sum_{j=1}^{N} \frac{x_{L(j-1)+i}}{A_j} \tag{2.16}$$

Her sezonun faktörü, döngü ortalamasından ortalama mutlak sapmasıdır. Holt-Winters mevsimsel yöntemi, zaman serisi tahminlerinin evriminin bir kanıtı niteliğindedir. Basit üstel düzgünleştirmenin basitliğinden trend farkındalığına sahip Holt'un lineer yöntemine kadar, artık trendlerin ve mevsimsel ritimlerin karmaşık etkileşimini yakalayabilen bir araca sahibiz. Bu yöntem sadece sayısal değerleri tahmin etmekle kalmaz, aynı zamanda verilerin altında yatan ritimleri de ayırt eder ve perakende, turizm, enerji ve ötesi gibi mevsimselliğin çok önemli olduğu alanlarda paha biçilmez hale getirir.

Bu yöntemlerde ilerledikçe, basitlikten karmaşıklığa doğru bir geçiş gözlemliyoruz. Bu metotların temeli, zarif ağırlıklı ortalamalar kullanan basit üstel düzleştirme ile atılmıştır. Holt'un lineer trend yöntemi bunun üzerine inşa edilmiş ve doğrusal yörüngelerde gezinmek için bir trend bileşeni eklemiştir. Bulmacanın son parçası olan mevsimsellik ise Holt-Winters mevsimsellik yönteminin kullanılmaya başlanmasıyla eklenmiştir. Bu, verilerin kendi doğal ritimleriyle uyum içinde tahmin edilmesini sağlar.

2.1.2 Mevsimsel ARIMA (SARIMA)

Zaman serisi analizi, ekonomi, finans ve çevre çalışmaları da dahil olmak üzere birçok disiplinde ileriye dönük eğilimlerin anlaşılması ve tahmin edilmesi için çok önemli bir araçtır. Bu bölümde, yaygın olarak kullanılan üç zaman serisi modeline kapsamlı bir genel bakış sunulacaktır: Otoregresif hareketli ortalama (ARMA), otoregresif entegre hareketli ortalama (ARIMA) ve mevsimsel otoregresif entegre hareketli ortalama (SARIMA) bu üç modeldir [36].

ARMA modeli iki temel zaman serisi modelinin birleşimidir: Otoregresif (AR) model ve hareketli ortalama (MA) modeli. Durağan bir zaman serisindeki doğrusal bağımlılıkları yakalamak için kullanılır [36].

ARMA(p,q) modelinin matematiksel ifadesi Denklem 2.17 ile gösterilmiştir:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \cdots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_1 \varepsilon_{t-2} - \cdots - \theta_q \varepsilon_{t-q} \quad (2.17)$$

Burada :

- x_t, t zamanında gözlenen zaman serisidir.

- ϕ_1, ϕ_2, ..., ϕ_p otoregresif parametrelerdir.

- θ_1, θ_2, ..., θ_q hareketli ortalama parametreleridir.

- ε_t, t zamanındaki hata terimidir ve beyaz gürültü (yani, sıfır ortalama ve sabit varyans ile bağımsız ve özdeş dağılımlı) olduğu varsayılır.

- p otoregresif (AR) bileşenin mertebesidir.

- q hareketli ortalama (MA) bileşeninin sırasıdır.

ARMA modeli, zaman serisinin durağan olduğunu, yani serinin ortalamasının, varyansının ve otokorelasyon yapısının zaman içinde değişmediğini varsayar. Eğer zaman serisi durağan değilse, bir ARMA modeli kurmadan önce durağanlığı sağlamak için dönüştürülmesi gerekir [36].

ARIMA modeli, durağan olmayan zaman serilerini ele alma kapasitesi sunan ARMA modelinin bir uzantısını temsil eder. ARIMA modeli bağlamında "entegre" terimi, zaman serisini durağan hale getirmek için kullanılan farklılaştırma sürecini ifade eder [37].

ARIMA(p,d,q) modelinin genel formu Denklem 2.18 ile gösterilmiştir:

$$\Phi(B)\cdot (1-B)^{d} X_t = \Theta(B)\, \varepsilon_t \qquad (2.18)$$

(2.18) ifadesini daha detaylı anlatmak gerekirse,

$\Phi(B) = 1 - \phi_1 * B - \phi_1 * B^2 - \ldots - \phi_p * B^p$ otoregresif (AR) polinomudur [37].

$\Phi(B) = 1 + \theta_1 * B + \theta_2 * B^2 + \ldots + \theta_q * B^q$ hareketli ortalama (MA) polinomudur [37].

B geri kaydırma operatörüdür, ve $B^k . X_t = X_{t-k}$ olarak modellenebilir [37].

$(1-B)^d$, zaman serisini durağan hale getirmek için kullanılan fark alma operatörüdür.

ARIMA modelinin parametreleri şunlardır:

p: otoregresif (AR) bileşenin sırası

d: farklılaştırma bileşeninin mertebesi

q: hareketli ortalama (MA) bileşeninin sırasıdır.

ARIMA modeli, durağan olmayan zaman serilerinin modellenmesi ve tahmin edilmesi amacıyla kullanılabilir. Bu, ilk olarak söz konusu serinin durağanlık durumuna dönüştürülmesiyle elde edilir; bu süreç fark alma olarak bilinir. Bunu takiben, farkı alınmış seriye bir ARMA modeli yerleştirilir [38].

SARIMA modeli, ARIMA modelinin bir uzantısını temsil eder ve mevsimsel modeller sergileyen zaman serilerinin analizini kolaylaştırır. SARIMA modeli $ARIMA(\mathrm{p},\mathrm{d},\mathrm{q})(\mathrm{P},\mathrm{D},\mathrm{Q})_m$ ile temsil edilir. Sırasıyla p, d ve q ile gösterilen mevsimsel olmayan ARIMA parametreleri, modelin mevsimsel olmayan bileşenlerini tanımlamak için kullanılır. Sırasıyla P, D ve Q ile gösterilen mevsimsel ARIMA parametreleri, modelin mevsimsel bileşenlerini tanımlamak için kullanılır. Sezon başına düşen zaman dilimi sayısı, m ile gösterilir, veri setine bağlı olarak değişen bir parametredir. Örneğin, m aylık veriler için 12, üç aylık veriler için 4 olabilir [39].

SARIMA modelinin genel formu Denklem 2.19 ile ifade edilmiştir:

$$\Phi(\mathrm{B}^{\mathrm{m}}) \cdot \Phi(\mathrm{B}) \cdot (1 - \mathrm{B}^{\mathrm{m}})^{\mathrm{D}} \cdot (1 - \mathrm{B})^{\mathrm{d}} \cdot \mathrm{X}_{\mathrm{t}} = \Theta(\mathrm{B}^{\mathrm{m}}) \cdot \Theta(\mathrm{B}) \cdot \varepsilon_{\mathrm{t}} \tag{2.19}$$

Bu ifadeyi daha detaylı anlatmak gerekirse,

$\Phi(B^m) = 1 - \Phi_1 \cdot B^m - \Phi_2 \cdot B^{2m} - \cdots - \Phi_P \cdot B^{Pm}$ mevsimsel otoregresif (SAR) polinomudur [40].

$\Theta(B^m) = 1 + \Theta_1 \cdot B^m + \Theta_2 \cdot B^{2m} + \cdots + \Theta_Q \cdot B^{Qm}$ mevsimsel hareketli ortalama (SMA) polinomudur [40].

$\Phi(B) = 1 - \phi_1 \cdot B - \phi_2 \cdot B^2 - \cdots - \phi_p \cdot B^p$ mevsimsel olmayan otoregresif (AR) polinomudur [40].

$\Theta(B) = 1 + \theta_1 \cdot B + \theta_2 \cdot B^2 + \cdots + \theta_q \cdot B^q$ mevsimsel olmayan hareketli ortalama (MA) polinomudur [40].

$(1 - \mathrm{B}^{\mathrm{m}})^{\mathrm{D}}$ mevsimsel fark alma operatörüdür [40].

$(1 - \mathrm{B})^{\mathrm{d}}$ mevsimsel olmayan fark alma operatörüdür [40].

Mevsimsel ARIMA modeli, hem mevsimsel olmayan hem de mevsimsel bileşenler sergileyen zaman serilerinin modellenmesi ve tahmin edilmesi için sağlam bir analitik aracı temsil etmektedir. Model, özellikle satış tahmini, enerji talebi tahmini ve makroekonomik analiz gibi bağlamlarda faydalı olan verilerdeki karmaşık modellerin ve karşılıklı bağımlılıkların tanımlanmasına izin verir [41].

2.2 Model Performans Değerlendirme Kriterleri

2.2.1 MAPE

Ortalama mutlak yüzde hata (MAPE), tahmin ve performans değerlendirme alanında yaygın olarak kullanılan bir metriktir. Hatayı gerçek değerlerin bir yüzdesi olarak ifade ederek tahmin modellerinin doğruluğunu değerlendirmek için basit ve sezgisel bir yol sağlar [11].

MAPE, her bir gözlem için gerçek değer A_i ile tahmin değeri F_i arasındaki mutlak farkın alınması, gerçek değere bölünmesi ve ardından tüm gözlemler için bu oranların ortalamasının alınmasıyla hesaplanır [12]. MAPE için matematiksel formül Denklem 2.20 ile gösterilmiştir:

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{|A_i - F_i|}{A_i} \tag{2.20}$$

Burada:

A_i gözlem için gerçek değeri temsil eder.

F_i gözlem için tahmin değerini temsil eder.

n toplam gözlem sayısını ifade eder.

MAPE'yi bir performans ölçütü olarak kullanmanın başlıca avantajları vardır bunlar:

Yorumlama kolaylığı, MAPE'nin bir diğer avantajıdır [13]. MAPE, farklı tahmin modelleri ve veri kümeleri arasında sezgisel anlama ve karşılaştırmalı analizi kolaylaştıran bir yüzde olarak ifade edilir [13]. MAPE, farklı ölçeklere veya ölçüm birimlerine sahip değişkenler için tahmin doğruluğunun karşılaştırılmasına olanak tanıyan ölçekten bağımsız bir ölçüdür. MAPE, birçok pratik uygulamada mutlak hata ölçüsünden daha anlamlı olan göreceli bir hata ölçüsüdür [13]. MAPE, yüzde hatanın mutlak değerini aldığı için düşük ve yüksek tahminleri eşit olarak ele alır [13]. Yaygın uygulamasına rağmen, MAPE'nin dikkate alınması gereken eksiklikleri de yok değildir bunlar:

MAPE'nin küçük gerçek değerlere olan hassasiyeti dikkate alınması gereken bir sınırlamadır. Gerçek değerler A_i sıfıra yakın olduğunda hata yüzdesi sonsuza yaklaşabileceğinden MAPE kararsız veya tanımsız hale gelebilir [14].

Hataların asimetrik olarak ele alınması MAPE'nin bir başka sınırlamasıdır. MAPE, pozitif ve negatif hataları eşit olarak ele aldığından, hatanın büyüklüğünün yönünden daha önemli olduğu senaryolar için en uygun seçim olmayabilir [14].

Aykırı değer etkisi potansiyeli MAPE'nin bir diğer sınırlamasıdır. Az sayıda büyük yüzdeli hatanın genel metrik üzerinde orantısız bir etkisi olabileceğinden, MAPE aykırı değerlerin etkisine karşı hassastır [14].

Sonuç olarak, MAPE tahmin modellerinin doğruluğunu değerlendirmek için değerli ve yaygın olarak kullanılan bir metriktir. Metriğin basitliği, ölçekten bağımsızlığı ve sezgisel yorumu, onu işletme, ekonomi ve mühendislik dahil olmak üzere çeşitli alanlarda popüler bir seçim haline getirmektedir. Bununla birlikte, araştırmacıların MAPE'nin sınırlamalarının farkında olmaları ve tahmin performansının daha kapsamlı bir değerlendirmesini elde etmek için tamamlayıcı metrikler kullanmayı düşünmeleri önemlidir [4].

2.2.2 MAE

Ortalama mutlak hata (MAE), makine öğrenimi, istatistik ve tahmin dahil olmak üzere çeşitli alanlarda tahmin modellerinin doğruluğunun değerlendirilmesinde sıklıkla kullanılan bir metriktir. MAE, hataların yönüne bakılmaksızın, bir dizi tahmindeki hataların ortalama büyüklüğünün bir ölçüsünü sağlar [5]. Ortalama mutlak hatayı hesaplamak için kullanılan formül Denklem 2.21 ile verilmiştir:

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|x_i - x| \tag{2.21}$$

Burada:

n örnekteki veri noktalarının veya tahminlerin sayısıdır

x_i gerçek (gözlenen) değerdir

x tahmin edilen değerdir

$|x_i - x|$ gerçek ve tahmin edilen değerler arasındaki mutlak farkı temsil eder

MAE'yi bir performans ölçütü olarak kullanmanın en önemli avantajları basitliği, yorumlanabilirliği ve aykırı değerlere karşı sağlamlığıdır. Ortalama karesel hata (MSE) veya ortalama karesel hatanın kökü (RMSE) gibi diğer hata metriklerinin aksine MAE, hedef değişkenin ölçeğine duyarlı değildir, bu da onu farklı veri kümeleri veya değişkenler arasında modellerin performansını karşılaştırmak için uygun bir araç haline getirir. Ayrıca, MAE değeri hataların ortalama büyüklüğünü temsil eder ve bu da modelin tahmin doğruluğunun kolayca anlaşılabilir bir ölçüsünü sağlar. Bu, [6-8] çalışmalarının bulgularıyla uyumludur.

MAE, MSE'de olduğu gibi karesel farkları en aza indirmenin aksine, amaç tahmin edilen ve gerçek değerler arasındaki ortalama mutlak farkı en aza indirmek olduğunda özellikle kullanışlıdır. Bu durum MAE'yi, karesel hatadan ziyade hatanın büyüklüğünün öncelikli olduğu uygulamalar için tercih edilebilir bir seçenek haline getirmektedir. Bu, maliyete duyarlı problemleri ve modelin tahminlerinin hedef değişkenin orijinal ölçeğinde yorumlanması gereken durumları içerir [42].

MAE'nin bir sınırlaması, yalnızca ortalama büyüklüğü dikkate aldığı için hataların dağılımı hakkında herhangi bir bilgi sağlamamasıdır.

Genel olarak, MAE özellikle hata ölçüsünün yorumlanabilirliği ve sağlamlığının çok önemli olduğu durumlarda, tahmin modellerinin doğruluğunu değerlendirmek için değerli ve yaygın olarak kullanılan bir metriktir.

2.2.3 AIC (Akaike Bilgi Kriteri) ve BIC (Bayesian Bilgi Kriteri)

Model seçimi, araştırmacıların verileri için en uygun modeli belirlemelerini sağladığından, birçok araştırma alanında çok önemli bir adımdır. Yaygın olarak kullanılan iki model seçim yöntemi Akaike bilgi kriteri (AIC) ve Bayesian bilgi kriteridir (BIC) [43].

AIC, bir modelin uyumu ile karmaşıklığını dengeleyen bir ölçüdür. Denklem 2.22 kullanılarak AIC formülü tanımlanmıştır:

$$AIC = 2k - 2\ln(L) \tag{2.22}$$

Burada k modeldeki parametre sayısı, L ise modelin maksimum olabilirliğidir [44]. En düşük AIC değerine sahip model, modelin açıklayıcı gücü ile basitliği arasında iyi bir denge sağladığı için en iyi uyum olarak kabul edilir.

BIC, örneklem büyüklüğünü de dikkate alan AIC'ye benzer bir model seçim kriteridir. BIC Denklem 2.23 ile tanımlanır:

$$BIC = k\ln(n) - 2\ln(L) \tag{2.23}$$

Burada n örneklem büyüklüğüdür [45]. BIC, model karmaşıklığını AIC'den daha güçlü bir şekilde tespit eder ve özellikle örneklem büyüklüğü büyük olduğunda daha az parametreye sahip daha basit modelleri tercih eder.

2.2.4 LOGL (log-Olasılığı)

Log-likelihood (LOGL) model seçimi ve tahmininde temel bir kavramdır. LOGL Denklem 2.24 ile tanımlanır:

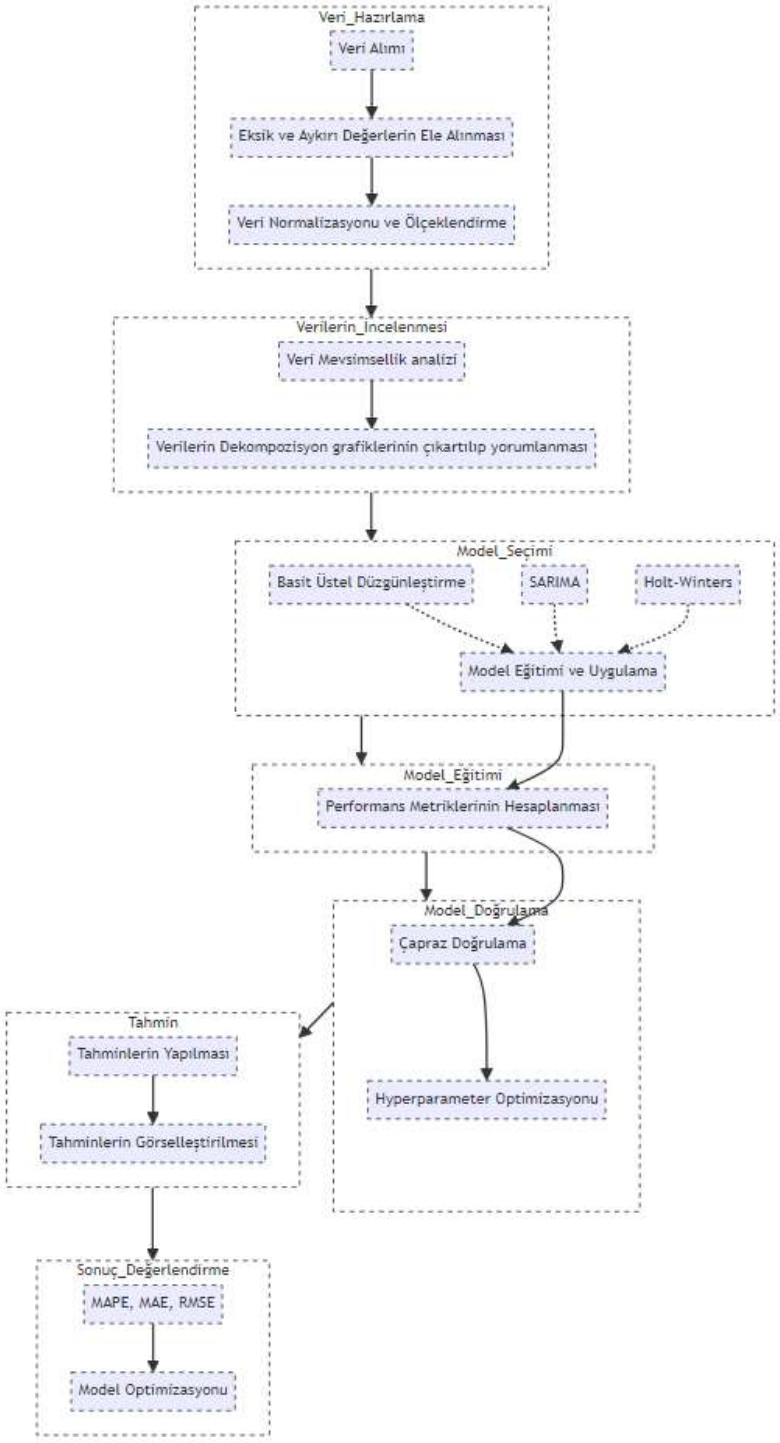
$$LOGL = \ln(L) \tag{2.24}$$

Burada L, model parametreleri göz önüne alındığında gözlenen verilerin olasılığını ölçen olabilirlik fonksiyonudur. LOGL, hem AIC hem de BIC'nin hesaplanmasında kullanılır ve maksimizasyonu genellikle model tahmininde birincil hedeftir [46].

3
TAHMİN YÖNTEMİ GELİŞTİRİLMESİ

Şekil 3.1'de sunulan genel süreç diyagramı, veri analizi ve tahmine dayalı modelleme alanındaki akademik araştırmaların ayrılmaz bir bileşeni olan zaman serisi tahmini için metodolojik olarak genel bir çerçeve sunmaktadır. Kapsamlı süreç yedi kritik aşamayı kapsamaktadır. Veri hazırlama aşaması, verilerin toplanmasını ve temizlenmesini, özelliklerin oluşturulmasını ve uygun bir modelin seçilmesini içerir. Model eğitimi aşaması, seçilen modelin verilere uygulanmasını gerektirirken, model doğrulama aşaması modelin performansını değerlendirir. Tahmin aşaması, gelecekteki sonuçları tahmin etmek için eğitilmiş modeli kullanır ve sonuç değerlendirme aşaması tahminin doğruluğunu değerlendirir.

Veri hazırlama aşaması, veri bütünlüğünü sağlamak için eksik değerleri ve aykırı değerleri ele alarak titiz bir temizleme, normalleştirme ve ölçeklendirme gerektirir. Bu aşama, doğru analiz için sağlam bir temel oluşturmada büyük önem taşır. Özellik mühendisliği aşamasında veriler, model yorumlanabilirliğini ve performansını artırmak için ilgili özelliklerin çıkarılması ve boyut azaltma tekniklerinin uygulanmasıyla dönüşüm ve zenginleştirmeye tabi tutulur. Model Seçiminin amacı, çeşitli veri özelliklerini yakalamaya uygunluklarına göre basit üstel düzgünleştirme, SARIMA ve Holt-Winters mevsimsel metot gibi en uygun tahmin modellerini belirlemektir. Daha sonra, yukarıda bahsedilen modeller geçmiş veriler kullanılarak model eğitimi aşamasında eğitilir ve ince ayar yapılır, ardından performans metriklerinin hesaplanması ve çapraz doğrulama yoluyla titiz model doğrulaması yapılır. Bu süreç modellerin tahmin doğruluğunu ve genelleştirilebilirliğini sağlar.

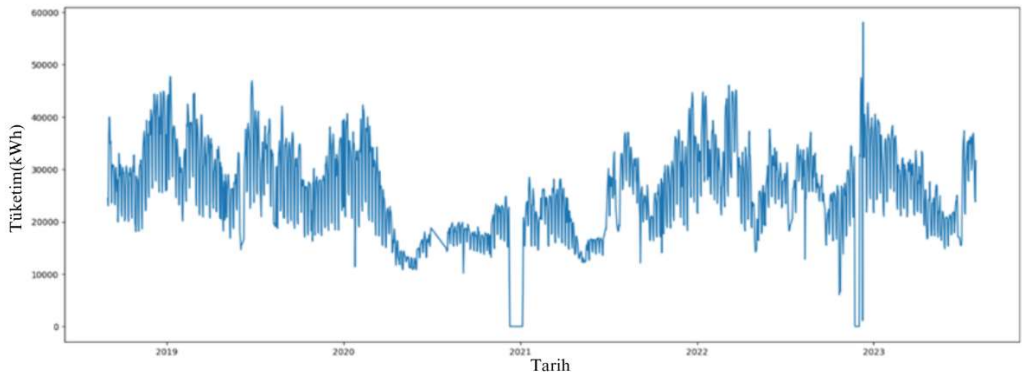


Şekil 3.1 Zaman serisi modellemesi ve tahmini genel akış diyagramı

Tahminleme, gelecek tahminleri oluşturmak için eğitilmiş modelleri kullanır ve bunlar daha sonra yorumlanabilirliği ve karar vermeyi kolaylaştırmak için görsel bir formatta sunulur. Son aşama olan sonuç değerlendirmesi, MAPE, MAE ve RMSE gibi metrikler kullanılarak tahmin doğruluğunun ayrıntılı bir değerlendirmesini içerir. Bu aşama aynı zamanda sürekli iyileştirme için yinelemeli model optimizasyonunu da içerir.

3.1 Veri Setinin İncelenmesi

Şekil 3.2'de gösterilen veri seti grafiği, 1 Eylül 2018'den 31 Temmuz 2023'e kadar yaklaşık beş yıllık bir dönemi kapsayan gerçek zamanlı üniversite kampüs günlük elektrik tüketim verilerini içermektedir. Bu verilerin analizi, verimliliği optimize etmek ve enerji tüketiminin çevresel etkisini azaltmak için hedeflenen stratejilerin uygulanmasına bilgi verecek olan üniversitenin enerji kullanım modellerine ilişkin içgörülerde sağlamaktadır.

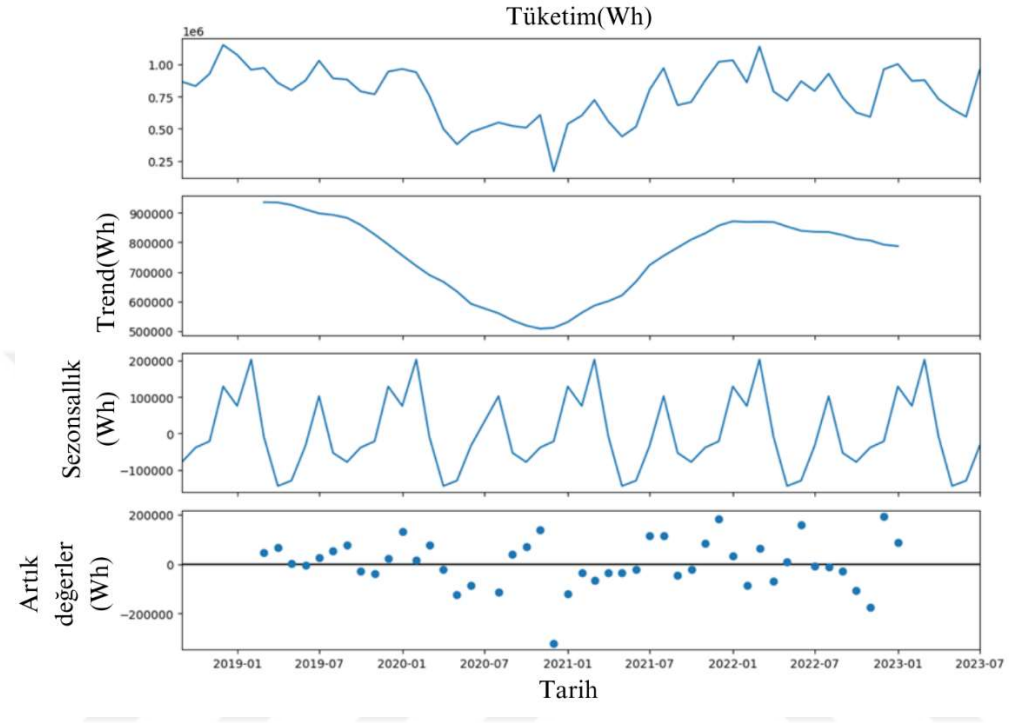


Şekil 3.2 Veri setinin grafiksel gösterimi

Şekil 3.2'deki veriler ve Tablo 3.1'deki değerler incelendiğinde pandemi ve deprem dönemlerinde oluşan pozitif ve negatif pik değerleri ve OSOS (otomatik sayaç okuma sistemi)'daki teknik arızadan dolayı eksik değerleri görmekteyiz. Veri seti, 2018'den 2023'e kadar beş yıl boyunca kaydedilen günlük elektrik talebi değerlerini içermektedir. Veriler, kayda değer mevsimsel modellerle birlikte önemli günlük dalgalanmalar sergilemektedir. Veri setinin ön görselleştirmesi, mevsimsel etkilerin ve potansiyel aykırı değerlerin varlığına işaret eden periyodik değişimleri ve bazı uç değerleri göstermektedir. Bu değerler tahmin algoritmaları için korelasyonu bozan algoritmanın tahmin yeteneğini kısıtlayan negatif faktörlerdir.

3.1.1 Zaman Serisinin Mevsimsellik Analizi

Şekil 3.3'teki grafik, bir tüketim zaman serisi veri setinin trend, mevsimsel ve artık bileşenlerine ayrıştırılmasını incelemektedir. Ayrıştırma işlemi, verilere belirli bir dönem (bu çalışmada 12 aylık bir dönem) uygulanarak gerçekleştirilmektedir.



Şekil 3.3 İşlenmemiş veri setine ait dekompozisyon grafiği

Toplam tüketim verisinden başlayacak olunursa, bu grafik zaman serisindeki orijinal verileri göstermektedir. Gözlemler Eylül 2018'den Temmuz 2023'e kadar aylık tüketim verilerini içermektedir. Grafikte, veri setinde önemli mevsimsel ve trend etkilerinin varlığına işaret eden bir dizi dalgalanma ve ani değişiklik görülmektedir.

Trend bileşeni grafiği ise, zaman serisindeki uzun vadeli değişiklikleri temsil etmektedir. Grafik, tüketimin başlangıçta yüksek olduğunu, ancak 2020'ye doğru önemli bir düşüş gözlendiğini göstermektedir. Düşüş 2021'in başında en düşük seviyesine ulaşmış, ardından kademeli bir toparlanma ile yükselmeye başlamıştır. 2021 yılının ortalarından itibaren tüketim değerlerinin yeniden düşüş eğilimine girdiği görülmektedir. Bu uzun vadeli eğilimler ekonomik, sosyal veya diğer makroekonomik faktörlerle ilişkili olabilir.

Mevsimsel bileşen grafiği, belirli bir dönem boyunca tekrar eden düzenli kalıpları gösterir. Grafik, 12 aylık dönemler boyunca düzenli dalgalanmaların meydana geldiğini göstermekte ve her yıl belirli aylarda tüketimde tutarlı bir artış ve azalış modeline işaret etmektedir. Özellikle, belirli aylarda tüketim seviyelerinde kayda değer dalgalanmalar görülmektedir. Bu tür dalgalanmalar mevsimsel değişiklikler, tatil dönemleri veya diğer düzenli olaylarla ilişkili olabilir.

Son olarak artık bileşen grafiği ise, trend ve mevsimsel bileşenler çıkarıldıktan sonra kalan kısmı temsil eder. Bu bileşen rastgele veya açıklanamayan değişimleri içerir. Grafikte görüldüğü gibi, artık değerler genellikle sıfır etrafında dağılmakta ve net bir örüntü veya eğilim sergilememektedir. Bu durum, modelin veri setindeki mevsimsel ve trend etkilerini oldukça iyi yakaladığını göstermektedir. Bununla birlikte, bazı aylar (özellikle 2020'de) daha büyük sapmalar göstermektedir. Bu sapmalar öngörülemeyen olaylara (afet, pandemi vb.) veya modelin hesaba katamadığı diğer faktörlere atfedilebilir.

Tablo 3.1 İşlenmemiş veri setine ait istatistiksel tablo

Veri Adedi	1764
Ortalama	25630
Standard Sapma	8831
Minimum Değer	0
1.Çeyrekler Açıklığı	19225
2.Çeyrekler Açıklığı	25606
3.Çeyrekler Açıklığı	32049
Maksimum Değer	58084

3.2 Metodoloji

Yaklaşık beş yıllık bilgiyi kapsayan veri setini altı aylık bir zaman diliminde tahmin etmek için kullanılan metodolojilere yer verilen bu bölümde, algoritma tarafından doğruluğunu ve güvenilirliğini artırmak için veri setinde yapılan özel ayarlamalar da ele alınmaktadır.

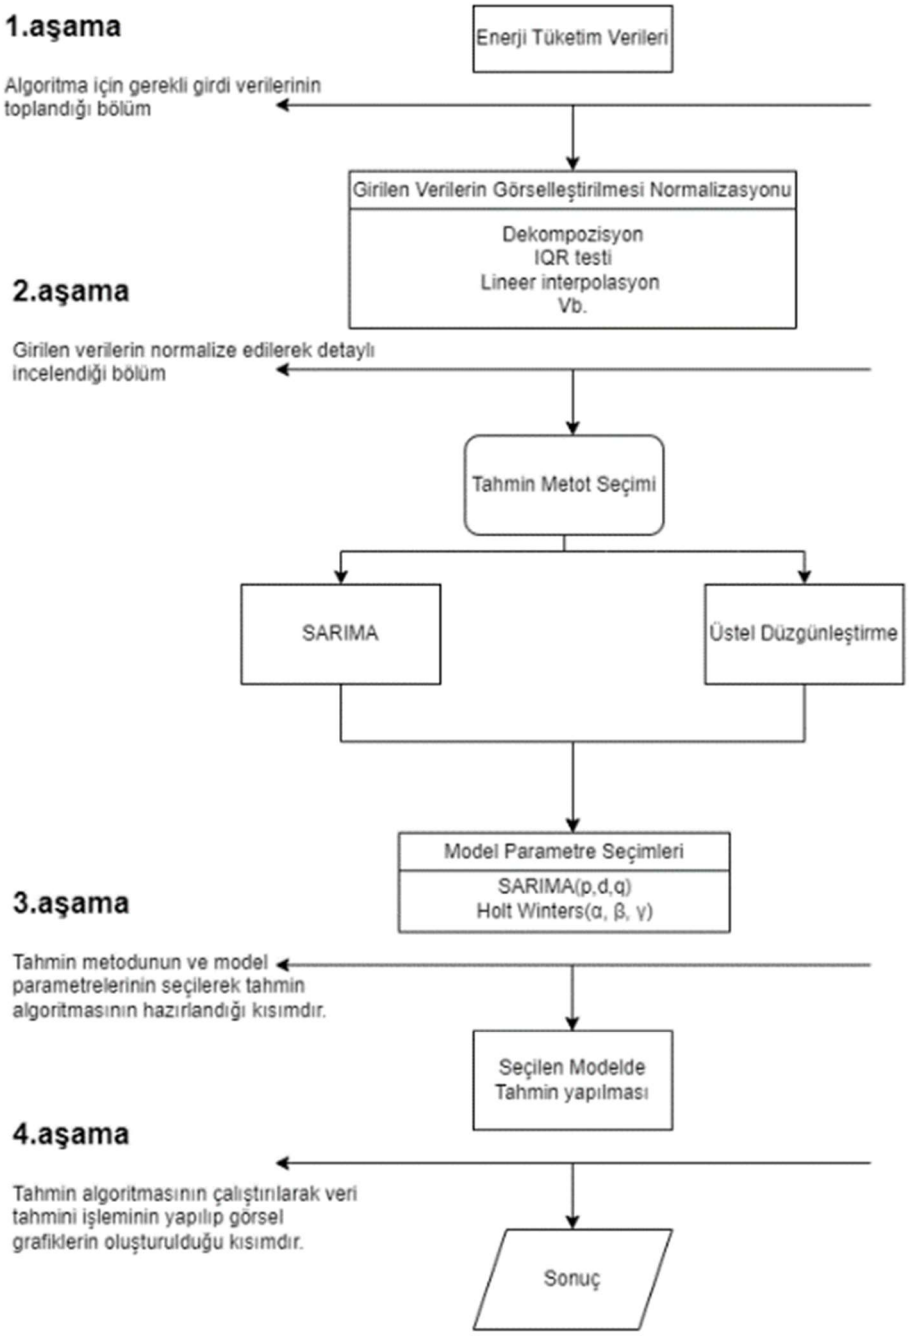
Hem Holt Winter's mevsimsel üstel düzgünleştirme hem de SARIMA, zaman serisi tahmini için yaygın olarak kullanılmaktadır. Ancak, temel varsayımları ve yaklaşımları açısından farklılık gösterirler. Holt Winter's mevsimsel üstel düzgünleştirme, geçmiş gözlemlere azalan ağırlıkların atanmasına dayanan daha sezgisel ve basit bir yöntemdir. Buna karşın SARIMA, çeşitli mertebelerin ve parametrelerin tanımlanmasını gerektiren daha karmaşık bir modeldir. Bununla birlikte, verilerdeki daha karmaşık kalıpları potansiyel olarak yakalayabilir.

Üstel düzgünleştirmenin en önemli avantajlarından biri basitliği ve uygulama kolaylığıdır, bu da uygulayıcılar arasında popüler olmasına yol açmıştır. Özellikle Holt-Winter's yöntemi hem trend hem de mevsimselliği etkili bir şekilde ele alabilen köklü ve yaygın olarak kullanılan bir varyanttır. Bununla birlikte, üstel düzgünleştirmenin verilerdeki daha karmaşık ilişkileri yakalama kabiliyetinin sınırlı olabileceği unutulmamalıdır.

Buna karşılık SARIMA, özellikle güçlü mevsimsel kalıplar sergileyen verilerle uğraşırken daha doğru tahminler sağlayabilecek daha sofistike bir modeli temsil etmektedir. Hem mevsimsel olmayan hem de mevsimsel bileşenleri ayrı ayrı modelleme kapasitesi, zaman serilerinin altında yatan dinamikleri yakalamada avantajlı olabilir. Bununla birlikte, SARIMA için model seçimi ve parametre tahmini süreci daha karmaşık ve zaman alıcı olabilir ve zaman serisi analizinin daha derinlemesine anlaşılmasını gerektirir.

Performans açısından hem Holt-Winter's üstel düzgünleştirme hem de SARIMA çeşitli çalışmalarda etkileyici tahmin doğruluğu göstermiştir. İki yöntem arasındaki karar genellikle zaman serisi verilerinin belirli özelliklerine, tahmin ufkuna ve hesaplama kaynaklarının mevcudiyetine bağlıdır. Şekil 3.4'te sunulan akış diyagramında gösterildiği üzere, bu analizde kullanılan her iki yöntem de şu aşamaları kapsamaktadır: kapsamlı veri analizi, model seçimi ve geliştirme, parametre seçimi ve tahmin yapılması.

SARIMA yaklaşımı daha karmaşık bir model yapısına sahipken, üstel düzleştirme tekniği daha basit ve anlaşılır bir matematiksel yöntemdir. Ayrıca, SARIMA modeli mevsimsel kalıpları ve altta yatan eğilimleri daha derinlemesine yakalasa da üstel düzeltme yaklaşımı eldeki görev için daha hızlı ve daha kolay uygulanabilir bir çözüm sunmaktadır.



Şekil 3.4 Veri analizi ve tahminine genel bakış diyagramı

3.2.1 Veri Setinin Düzeltilmesi

Modelleme öncesinde, Tahmin modelinin doğruluğunu sağlamak için veri ön işleme adımları gereklidir. Ön işleme adımları şunları içerir:

3.2.1.1 Kayıp Değerlerin Ele Alınması

Veri setindeki kayıp değerlerin doğru bir şekilde tanımlanması ve ele alınması SARIMA modelinin etkin bir şekilde çalışması için büyük önem taşımaktadır. Araştırma ele alınan veri setinde, Şekil 3.2'ye baktığımızda eksik noktalar görülmektedir. Kayıp değerlerin türü (rastgele, sistematik, vb.), miktarı analiz edilerek ve uygun eksiklikleri tamamlama yöntemleri, (ortalama, medyan, kök değerler, lineer enterpolasyon gibi, yöntemler kullanılarak verilerdeki eksik noktaları tamamlanmıştır. Kayıp değerlerin ortadan kaldırılması ile, modelleme sürecinin güvenilirliği için gerekli olan verilerin bütünlüğü ve istikrarıda sağlanmış oldu.

3.2.1.2 Aykırı Değerlerin Tespiti ve İşlenmesi

Aykırı değerler zaman serisi verilerindeki anormallikleri temsil eder ve bunların varlığı tahmin modelinin performansı üzerinde negatif bir etkiye sahip olabilir.

Çeyrekler aralığı (IQR) yöntemini kullanarak aykırı değerleri bulmak ve tespit etmek için aşağıdaki adımları izlenecektir:

Verilerin medyanını (50. yüzdelik dilim) hesaplanır

Birinci yüzdelik dilimi (Q1) ve üçüncü yüzdelik dilimi (Q3) hesaplanır.

IQR = Q3 - Q1 olarak hesaplanır.

Aykırı değerler Q1 - 1,5 * IQR'nin altında ve Q3 + 1,5 * IQR'nin üzerinde olan veri noktaları olarak tanımlanır.

Bu işlemler veri setine uygulanırsa;

Medyan 23321 kWh'dir.

1. yüzdelik dilim (Q1) 19107,5 kWh ve 3. yüzdelik dilim (Q3) 28974,5 kWh'tir.

IQR ise Q3 - Q1 = 28974,5 - 19107,5 = 9867 kWh'tir.

Aykırı değerler için alt sınır Q1 - 1,5 * IQR = 19107,5 - 1,5 * 9867 = 3540 kWh'tir.

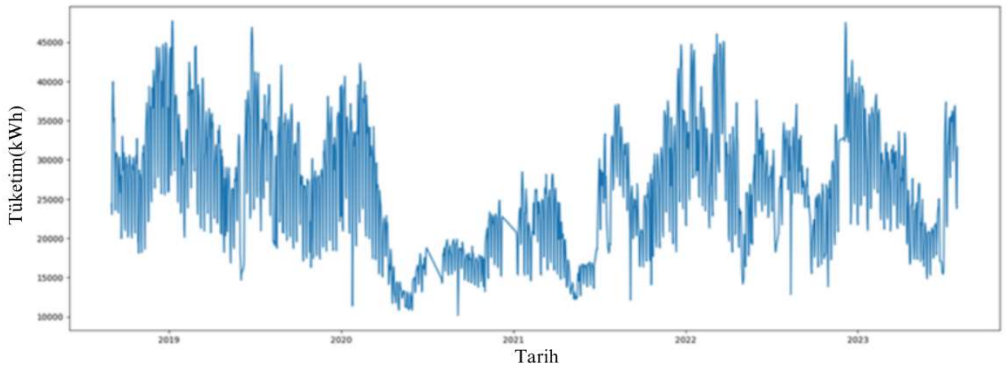
Aykırı değerler için üst sınır Q3 + 1,5 * IQR = 28974,5 + 1,5 * 9867 = 44502' kWh'tir.

Veriler incelendiğinde, bu sınırların dışında kalan ve aykırı değer olarak kabul edilebilecek birkaç veri noktası vardır:

Mart 2020 civarında 54000 kWh değer

Ocak 2022 civarında 49000 kWh değer

Bunlar o dönemin şartları göz önüne alındığında normal veri noktaları gibi görünmektedir, ancak gözlemlerin geri kalanından önemli ölçüde yüksektir ve IQR yöntemine göre aykırı değerler olarak kabul edilir. Çalışmada tespit edilen aykırı değerler için, veri normalizasyon işlemi uygulayarak veri setindeki veri aralığı normalize edilmiştir. Böylelikle ekstrem pik noktalar minimize edilerek modelin daha güvenilir ve sağlam tahminler yapması da sağlanmıştır. Tüm bu işlemlerin yapılmasının ardından veri seti Şekil 3.5'teki hale gelmiştir.

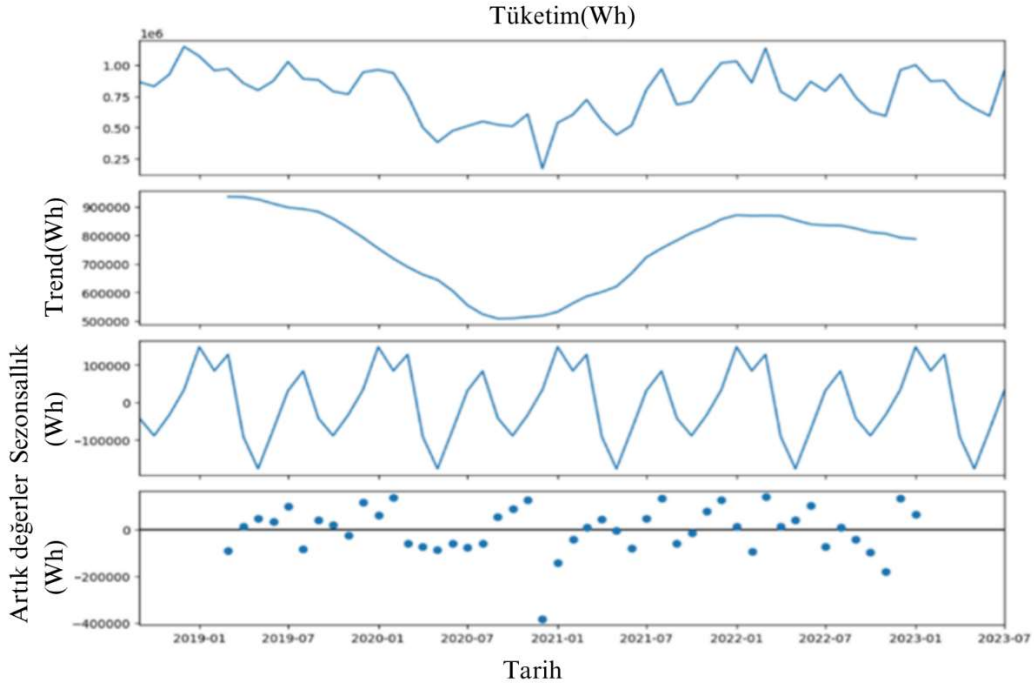


Şekil 3.5 Veri normalizasyon işlemleri uygunlandıktan sonraki veri setinin grafiksel gösterimi

Tablo 3.2'deki ve Şekil 3.5'teki yeni veri setimizi incelediğimizde Tablo 3.1'e göre maksimum ve minimum pik noktaların azaldığı kayıp noktaların yok olduğu ve veri setindeki değerlerin ortalamasına daha çok yaklaştığı görülmektedir.

Tablo 3.2 Düzenlenmiş veri setine ait istatistiksel bilgiler

Veri Adedi	1720
Ortalama	26230
Standard Sapma	7972
Minimum Değer	10184
1.Çeyrekler Açıklığı	19644
2.Çeyrekler Açıklığı	25865
3.Çeyrekler Açıklığı	32173
Maksimum Değer	47714



Şekil 3.6 Düzenlenmiş veri setinin dekompozisyon grafiği

Şekil 3.6'da dört farklı panelden oluşan zaman içindeki tüketim verilerinin kapsamlı bir görselleştirmesini sunmaktadır.

Üst panel, tepe ve dip noktalarıyla dalgalı bir model sergileyen ham tüketim verilerini göstermektedir. İkinci panel, zaman serisinin trend bileşenini göstermekte ve gözlemlenen dönem boyunca tüketimde genel bir düşüş eğilimi olduğunu ortaya koymaktadır. Üçüncü panel mevsimsel bileşeni göstermekte ve potansiyel olarak mevsimsel faktörler veya konjonktürel kalıplar tarafından yönlendirilen tüketimdeki periyodik değişimleri vurgulamaktadır. Alt panelde ise trend ve mevsimsel etkiler hesaba katıldıktan sonra verilerde kalan düzensiz değişimleri temsil eden artık bileşen sunulmaktadır. Grafikte genel olarak dalgalanmalar ve önemli değişiklikler gözlemlenmektedir. Bu durum, verilerin hem bir trend hem de mevsimsel bir bileşen içerdiğini göstermektedir.

2019'dan 2021'in başına kadar tüketimde net bir düşüş eğilimi gözlenmektedir. Bu dönemdeki düşüş makroekonomik faktörlere, pandemi etkilerine veya diğer dışsal faktörlere bağlanabilir. 2021'in ortalarından sonra tüketimde bir toparlanma ve artış eğilimi görülmektedir. Ancak 2022 ortalarından itibaren tekrar düşüş eğilimi başlamıştır. Bu değişiklikler ekonomik toparlanma süreçleri veya mevsimsel faktörlerle açıklanabilir. Mevsimsel bileşen, belirli dönemlerde tekrar eden düzenli dalgalanmaları göstermektedir.

İkinci panelde gözlemlendiği üzere trend bileşeni genel olarak aşağı yönlü bir yörünge sergilemekte ve analiz edilen dönem boyunca ara dönem artışlarına rağmen genel trended azalan bir tüketim modeline işaret etmektedir. Bu uzun vadeli eğilim çeşitli ekonomik, sosyal veya teknolojik faktörlerden etkilenmiş olabilir.

Üçüncü panelde gösterilen mevsimsel bileşen, tüketici davranışları, tatil kalıpları veya diğer döngüsel etkiler gibi mevsimsel faktörlerden kaynaklanabilecek tüketimdeki periyodik dalgalanmaları ortaya koymaktadır. 12 aylık bir dönem boyunca düzenli dalgalanmalar gözlemlenmektedir. Tüketim artışları ve azalışları belirli aylarda tekrarlanmaktadır. Özellikle yaz ve kış aylarında tüketimde önemli artışlar, bahar aylarında ise düşüşler görülmektedir. Bu mevsimsel değişiklikler iklim koşulları, tatil sezonları veya yıllık etkinlikler gibi faktörlere bağlanabilir.

Alt panelde gösterilen artık bileşen, trend ve mevsimsel etkiler çıkarıldıktan sonra kalan verilerdeki açıklanamayan veya düzensiz varyasyonları temsil eder. Bu artıklar modelin açıklayamadığı rastgele varyasyonları içerir. Artıklar grafiği sıfır etrafında rastgele bir dağılım göstererek modelin verileri genel olarak iyi açıkladığını gösterir. Ancak bazı dönemlerde (özellikle 2020'nin başlarında ve 2022'nin sonlarına doğru) artık değerlerde büyük sapmalar gözlenmektedir. Bu sapmalar öngörülemeyen olaylara veya modelin açıklayamadığı diğer değişkenlere atfedilebilir.

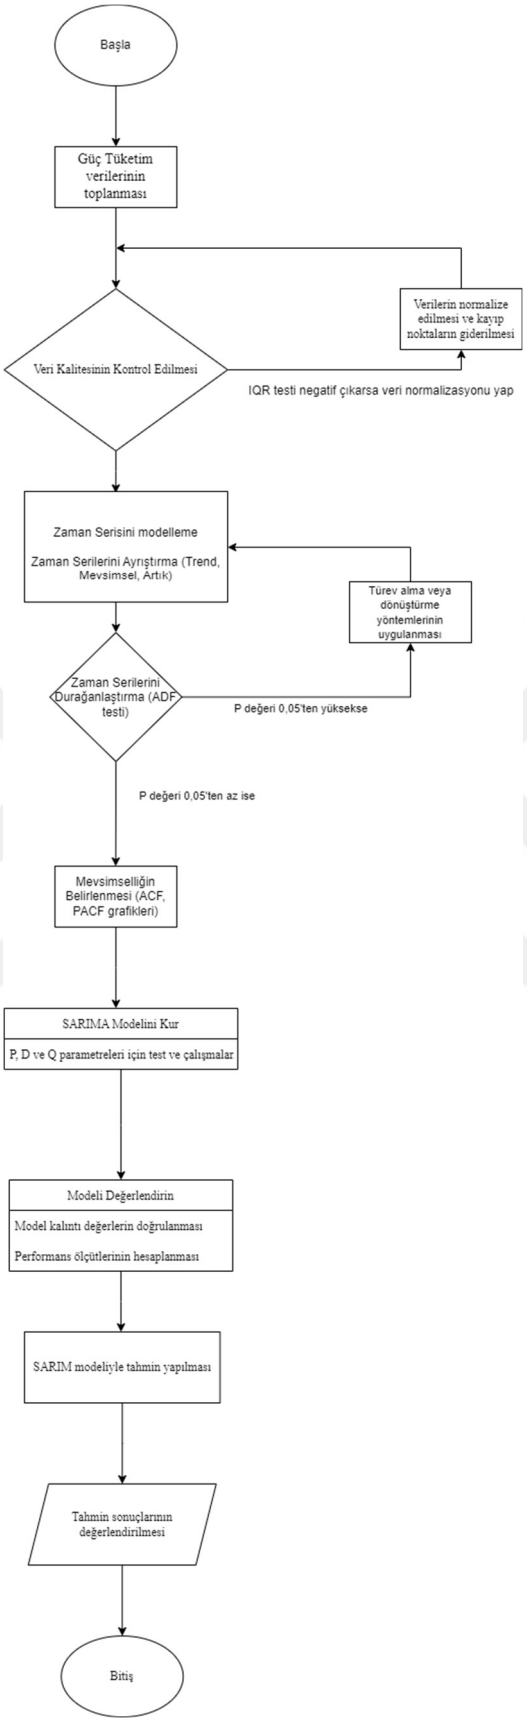
3.2.2 SARIMA (Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama Modeli)

Etkin enerji yönetimi ve planlamasını kolaylaştırmak için elektrik talebini doğru bir şekilde tahmin etmek son derece önemlidir. Sıklıkla kullanılan yaklaşımlardan biri, güç talebi verilerindeki karmaşık kalıpları ve mevsimselliği etkili bir şekilde yakalayabilen SARIMA modelidir.

Şekil 3.7'deki SARIMA akış diyagramı incelendiğinde Öncelikle, geçmiş elektrik talebi verilerini toplamak ve bu verileri inceleyip gerekli veri temizliği yapılarak veri kalitesini iyileştirmekle başlanmaktadır. Zaman serilerinin görselleştirilmesini içeren keşifsel veri analizi, eğilimlerin, mevsimselliğin ve diğer altta yatan özelliklerin belirlenmesine yardımcı olur. Zaman serisinin trend, mevsimsel ve artık bileşenlerine ayrıştırılması çok değerli bilgiler sağlar. SARIMA modelini kurmadan önce, trendleri ve mevsimselliği ortadan kaldırmayı içeren verileri durağanlaştırmak çok önemlidir. Model için en uygun mevsimsel ve mevsimsel olmayan sıralamaların belirlenmesi büyük önem taşımaktadır, çünkü bu parametreler modelin verilerdeki benzersiz kalıpları yakalama yeteneğini belirlemektedir.

SARIMA modeli kurulduktan sonra, doğruluğunu ve güvenilirliğini tespit etmek için titiz bir değerlendirme sürecinden geçmelidir. Son olarak, doğrulanan model, enerji planlaması ve yönetimi ile ilgili önemli kararları bilgilendirebilecek gelecekteki elektrik talebi tahminlerini oluşturmak için kullanılabilir. Enerji talebinin doğru bir şekilde tahmin edilmesi, kaynakların etkin kullanımı ve enerji arzındaki olası kesintilerin azaltılması için gerekli olan enerji kaynaklarının verimli bir şekilde yönetilmesini ve planlanmasını sağladığından büyük önem taşımaktadır.

SARIMA modeli, elektrik talebi verilerindeki karmaşık kalıpları ve mevsimselliği yakalama kabiliyetiyle, bu çabada değerli bir araç olduğu kanıtlanmış, yaygın olarak benimsenen bir yaklaşımdır. Geçmiş verilerin titizlikle derlenmesi ve analiz edilmesi, en uygun model parametrelerinin belirlenmesi ve modelin performansının titizlikle değerlendirilmesi, enerji yönetimi ve planlaması için geniş kapsamlı etkileri olabilecek üretilen tahminlerin doğruluğunu ve güvenilirliğini sağlamada kritik öneme sahip aşamalardır.



Şekil 3.7 SARIMA akış diyagramı

3.2.2.1 Zaman Serisi Verileri İçin Durağanlığın ve SARIMA Tahmininin Kapsamlı Analizi

Zaman serisi tahmin tekniklerinin doğru bir şekilde uygulanması için temel ön koşullardan biri, veri seti olarak kullanılacak verilerin durağanlığıdır. Bu bağlamda durağanlık, zaman serilerinin zaman içinde sabit kalan ortalama ve varyans gibi istatistiksel özelliklerini ifade eder. Bu varsayıma uyulmaması, verilerin dönüştürülmesi ve durağanlığın sağlanması için uygun tekniklerin kullanılmasını gerektirerek yanlı ve hatalı tahminlerin üretilmesine neden olabilir.

SARIMA algoritmasının bu aşamasında, belirli bir zaman serisinin durağanlığı ve bunun SARIMA tahmin modellerinin uygulanması üzerindeki etkilerinin kapsamlı bir analizi yapılmaktadır.

Zaman serisinin durağanlığını değerlendirmek için, bir zaman serisinde birim köklerin varlığını tespit etmek için yaygın olarak kabul edilen bir istatistiksel teknik olan augmented Dickey-Fuller (ADF) testi kullanılmıştır.

Tablo 3.3 ADF test istatistiği sonuçları

ADF istatistiği	-2.9331
P değeri	0.041621
Gecikme sayısı	0
ADF regresyonu için kullanılan gözlem sayısı	52
1 düzeyinde, ADF test istatistiği	-3.5628
5 düzeyinde, ADF test istatistiği	-2.9189
10 düzeyinde, ADF test istatistiği	-2.5973

ADF testinin sıfır hipotezi (H0), zaman serisinin durağan olmadığı ve bir birim kökün mevcut olduğu varsayımına dayanır. Alternatif hipotez (H1) ise, zaman

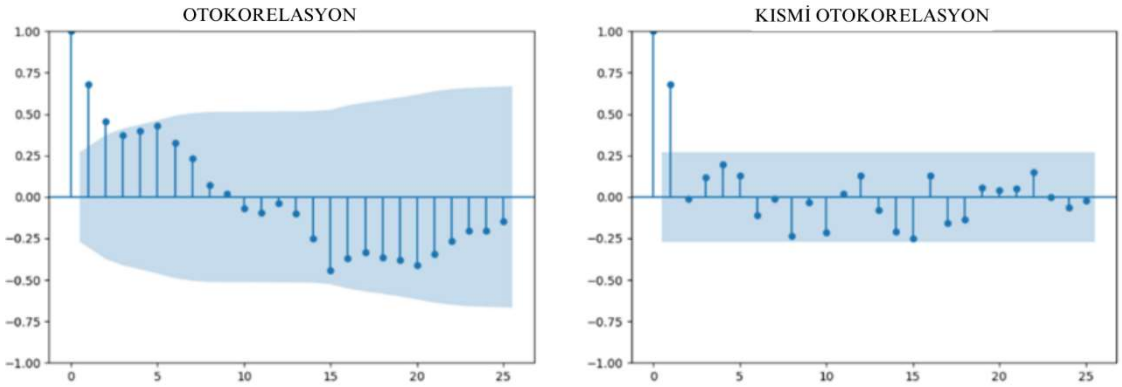
serisinin durağan olduğunu ve birim kök içermediğini belirtir. ADF testi, birim kökün var olup olmadığını belirlemek için zaman serisine uygulanan istatistiksel bir testtir. Mevcut analizde Tablo 3.3'te ADF test sonuçları gözlemlenmiştir:

ADF testinin sonuçları incelendiğinde, p değerinin 0.0416 yaygın olarak kullanılan anlamlılık düzeyi olan 0.05'ten küçük olduğu gözlemlenmiştir.

ADF testinin sıfır hipotezi, zaman serisinin durağan olmadığı ve bir birim kökün var olduğunu ileri sürmektedir. Başka bir deyişle, 0.05 anlamlılık düzeyinde H0'ı reddederek, zaman serisinin durağan olmadığı hipotezini çürütürüz ve alternatif hipotez olan H1'i kabul ederiz. Bu da zaman serisinin durağan olduğunu ve birim kök içermediğini gösterir. P değerinin bu anlamlılık düzeyinin altında olması, sıfır hipotezinin reddedilebileceğini ve dolayısıyla zaman serisinin durağan olduğunu göstermektedir. Bu bağlamda, ADF testi kullanılarak sağlanan zaman serisi verilerinin durağan olduğu sonucuna varılmıştır. Bu da SARIMA modelleme yaklaşımı için temel bir varsayımı karşılamaktadır. Eğer p değeri 0.05'ten büyük olsaydı, yani zaman serisinin durağan olmadığının tespit edilmesi durumunda, verileri dönüştürmek ve durağanlığı sağlamak için çeşitli tekniklerin uygulanması gerekmekteydi. En yaygın yaklaşım, ardışık gözlemler arasındaki farkın hesaplandığı ve yeni zaman serisi olarak kullanıldığı fark alma işlemidir. Fark alma işlemi, SARIMA modelindeki "d" parametresi tarafından belirtilen fark alma sırası ile durağanlık elde edilene kadar tekrarlanabilir.

3.2.2.2 SARIMA Model Katsayılarının Belirlenmesi İçin Otokorelasyon ve Kısmi Otokorelasyon Grafiklerinin İncelenmesi

Şekil 3.8'de verilen otokorelasyon ve kısmi otokorelasyon grafikleri tahmin için en uygun modelin belirlenmesine yardımcı olmak amacıyla zaman serisi analizinde yaygın olarak kullanılmaktadır. Bu grafikleri inceleyerek veri setinin, veri tahmini için uygunluğu denetlenir.



Şekil 3.8 Düzenlemiş veri setinin otokorelasyon ve kısmi otokorelasyon grafikleri

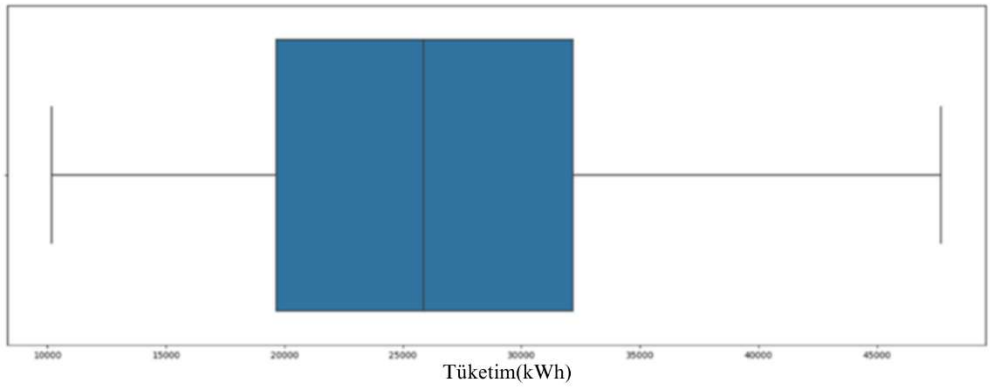
Korelogram olarak da bilinen otokorelasyon grafiği (ACF), bir zaman serisinin bugünkü değeri ile önceki değerleri arasındaki korelasyonu gösterir. Y ekseni -1 ile 1 arasında değişen otokorelasyon katsayısını temsil ederken, x ekseni gecikmeyi veya mevcut değer ile geçmiş değerler arasındaki zaman dilimi sayısını temsil eder.

Verilen otokorelasyon grafiğinde, mavi çubuklar farklı gecikmelerdeki otokorelasyon katsayılarını temsil etmektedir. Grafik, gecikme arttıkça otokorelasyon katsayılarında kademeli bir düşüş olduğunu göstermekte ve zaman serisinde mevsimsel veya mevsimsel olmayan bir bileşenin potansiyel varlığına işaret etmektedir. Otokorelasyon grafiğinde gözlemlenen örüntü, tahmin için en uygun modele ilişkin içgörü sağlayabilir. Örneğin, otokorelasyon katsayıları kademeli, üstel bir düşüş sergiliyorsa, bu bir otoregresif (AR) modelin uygunluğuna işaret edebilir. Otokorelasyon katsayıları sinüzoidal bir model sergiliyorsa, bu SARIMA modeli kullanılarak modellenebilecek mevsimselliğin varlığına işaret edebilir.Kısmi otokorelasyon grafiği (PACF), ara gecikmelerin etkisi kaldırıldıktan sonra bir zaman serisinin mevcut değeri ile geçmiş değerleri arasındaki kısmi korelasyonu gösterir. Y ekseni kısmi otokorelasyon katsayısını, x ekseni ise gecikmeyi temsil eder.

Verilen kısmi otokorelasyon grafiğindeki mavi çubuklar farklı gecikmelerdeki kısmi otokorelasyon katsayılarını temsil etmektedir. Grafik, ilk gecikmede önemli bir artış ve ardından diğer gecikmelerde daha küçük artışlar göstermektedir. Kısmi otokorelasyon katsayıları tipik olarak yalnızca önemli gecikmelerde sıfır olmadığından, bu model bir otoregresif (AR) modelin kullanıldığını düşündürebilir. Otokorelasyon grafiği ve kısmi otokorelasyon grafiğinin kombinasyonu, zaman serisinin altında yatan yapı hakkında değerli bilgiler sağlayabilir ve en uygun SARIMA modelinin seçilmesine yardımcı olabilir.

Sağlanan veriler bağlamında, SARIMA modeli altı aylık verilerin tahmini için uygun bir seçim olacaktır, çünkü grafikler zaman serisinde hem mevsimsel olmayan hem de mevsimsel bileşenlerin varlığına işaret etmektedir.

Şekil 3.9'da gösterildiği gibi Kutu grafiği, belirli bir veri setinin dağılım özelliklerini etkili bir şekilde aktaran ve yaygın olarak kullanılan bir istatistiksel görselleştirme tekniğidir. Bu grafiksel gösterim beş temel özet istatistiği kapsamaktadır: minimum değer, birinci çeyrek, medyan, üçüncü çeyrek ve maksimum değer. Mevcut bağlamda, grafiğin y ekseni "Tüketim" değişkenine karşılık gelmektedir. Bu da tasvir edilen kutu grafiklerin tüketim değerlerinin belirli bir zaman aralığındaki dağılımını temsil ettiği anlamına gelmektedir.



Şekil 3.9 Düzenlenmiş veri setinin kutu grafiği

Kutu grafiği tüketim verilerine kısa ama bilgilendirici bir genel bakış sunarak veri setindeki merkezi eğilim, dağılım ve potansiyel aykırı değerler hakkında değerli bilgiler edinilmesini sağlar.

Medyan tüketim değeri yaklaşık 26.000 kWh olarak görünmektedir, bu da bu nokta etrafında merkezi bir eğilim olduğunu göstermektedir. Bununla birlikte, birinci ve üçüncü çeyrekler arasındaki mesafeyi ifade eden önemli çeyrekler arası aralık, veri içindeki tüketim değerlerinin kayda değer bir dağılımına işaret etmektedir. Ayrıca, genişletilmiş kutuların üst ve alt çitlerinin ötesine uzanan münferit veri noktalarının varlığının olmaması, dağılımda potansiyel aykırı değerlerin olmadığına işaret etmektedir.

Kutu grafikleri, zaman serisi özellikleri ve uygun bir tahmin modelinin seçimine ilişkin olarak ACF ve PACF grafikleri ile aynı düzeyde bilgi sağlamamakla birlikte, yine de verilerin genel dağılımı ve özellikleri hakkında değerli bilgiler sunmaktadır. Bu bilgiler, tahmin amacıyla bir SARIMA modeli seçerken ve uygularken dikkate alınması gereken bağlam ve varsayımların anlaşılmasında etkili olabilir.

3.2.2.3 SARIMA Model Seçimi

Model uydurma süreci, SARIMA parametreleri (p, d, q, P, D, Q, s) için en uygun değerleri belirlemek üzere kapsamlı bir araştırma içermektedir. Bu yaklaşım, uygun ARIMA ve SARIMA model yapılarını belirlemek için literatürde iyi bilinen bir tekniktir. Model parametrelerinin, özellikle otoregresif (p ve P) ve hareketli ortalama (q ve Q) bileşenlerinin belirlenmesi, SARIMA modelleme sürecinde kritik bir adımdır, çünkü bu bileşenler zaman serisi verilerindeki içsel kalıpları ve bağımlılıkları yakalar.

Parametre seçim sürecini otomatikleştirmek için araştırmada, değerlendirme ölçütleri olarak AIC, logL ve BIC dikkate alarak en uygun SARIMA modelini otomatik olarak değerlendiren ve seçen oto ARIMA algoritması kullanılmıştır. Bu bilgi teorik ölçütler, modelin uyum iyiliği ve karmaşıklığının dengeli bir şekilde değerlendirilmesini sağlayarak en basit ve iyi uyum sağlayan SARIMA modelinin belirlenmesine olanak tanır. Mevcut 5 yıllık veri setini 4,4 yıllık bir eğitim setine ve 6 aylık bir test setine bölerek modelin performansının objektif bir şekilde değerlendirilmesi sağlanmıştır.

Eğitim verileri SARIMA modellerini uydurmak için kullanılırken, test verileri nihai model değerlendirmesi için ayrılmıştır.

Tablo 3.4 SARIMA AIC değerlerine göre model parametre tablosu

ARIMA (3,2,2) (3,1,2) [12]	AIC=1082.098
ARIMA (0,2,1) (0,1,2) [12]	AIC=1074.488
ARIMA (0,2,0) (0,1,1) [12]	AIC=1102.670
ARIMA (1,2,0) (0,1,1) [12]	AIC=1090.984
ARIMA (0,2,2) (0,1,1) [12]	AIC=1070.544

Tablo 3.4 incelendiğinde, ARIMA (3,2,2) (3,1,2) [12], ARIMA (0) dahil olmak üzere çeşitli aday SARIMA modellerinin AIC ölçütüne göre performansı görülmektedir. Modeller AIC değerlerine göre değerlendirilmiş ve en düşük AIC değerine sahip model en iyi uyan SARIMA modeli olarak kabul edilmiştir.

Ayrıca, en düşük AIC değerine sahip SARIMA modelinin, uyum iyiliği ve model karmaşıklığı arasında en uygun dengeyi sağladığı için tipik olarak en iyi model olarak kabul edildiği vurgulanmalıdır. Bu, AIC'nin model seçimi için değerli bir ölçüt olarak hizmet ettiği istatistiksel modellemede köklü bir ilkedir.

Tablo 3.5'de seçilen SARIMA modeli olan ARIMA (0,2,2) (0,1,1) [12] için logL, AIC ve BIC değerleri dahil olmak üzere karşılaştırma kriterlerini sunmaktadır.

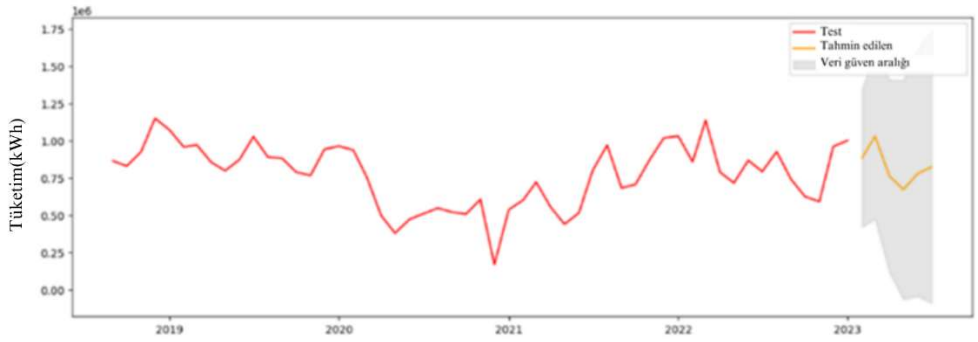
Tablo 3.5 Seçilen SARIMA modeli için performans kriterleri

LogL	-531.272
AIC	1070.544
BIC	1077.199

Bu ölçütler, modelin performansının kapsamlı bir değerlendirmesini sağlayarak algoritmanın uyum kalitesini ve modelin verilen tüketim verileri için genel uygunluğunu değerlendirmesine olanak tanır.

3.2.2.4 SARIMA Model Tahmininin Gerçekleştirilmesi

Şekil 3.10'da 2019'dan 2023'ün ilk aylarına kadar uzanan zaman serisi verilerini ve 2023 sonuna kadar uzanan 6 aylık bir tahmini göstermektedir. Bu bölümde hem gözlenen hem de tahmin edilen değerler detaylı bir incelemeye tabi tutulmuştur.



Şekil 3.10 SARIMA tahmin grafiği

Gözlenen değerler (Gerçek), kırmızı çizgi ile temsil edilirken, 2019'dan 2023'ün başına kadar olan tüketim verilerini göstermektedir.

Gözlenen değerler dönem boyunca dalgalanmalar göstermektedir; yani mevsimsel örüntülerin, trend bileşenlerinin ve zaman serisi verilerinde tipik olan diğer döngüsel davranışların varlığını göstermektedir. Sonuç olarak verilerin sabit bir ortalama seviye etrafında salındığını ve uzun vadeli eğilimlerin minimum düzeyde olduğunu göstermektedir.

Sarı çizgi ile gösterilen tahmini değerler, modelin 2023 yılı başından itibaren yaptığı tahminleri göstermektedir. Bu tahminler geçmiş verilere dayanmaktadır ve serinin benzer değişkenlik ve nispeten istikrarlı bir ortalama seviye ile devam etmesinin beklendiğini göstermektedir. Tahmin çizgisi, serinin seviyesinde önemli bir değişiklik veya kayma olmayacağını göstermektedir. Bu da SARIMA modelinin gelecekteki ani büyük eğilimleri veya döngüleri tahmin etmediğini göstermektedir.

Güven aralıkları, tahmin çizgisinin etrafındaki gri alanla temsil edilmektedir. Tahmin ufku geleceğe doğru uzadıkça, güven aralıkları genişlemektedir; bu, artan belirsizlik nedeniyle uzun vadeli tahminler için tipik bir olgudur. Bununla birlikte, tahmin ufkunun sonunda bile, güven aralığı nispeten dar kalmakta ve modelin belirtilen aralıktaki tahminlerinde yüksek derecede kesinlik olduğunu göstermektedir.

Sonuç olarak, SARIMA modeli, gözlemlenen verilerin mevsimsellik ve trend bileşenlerini etkili bir şekilde yakalayarak gelecek dönem için güvenilir tahminler sağlamaktadır. Analiz, tüketim serisinin geçmiş kalıpları yansıtan dalgalanmalarla nispeten istikrarlı kalmasının beklendiğini göstermektedir. Modelin güven aralıkları, tahminlerde yüksek düzeyde kesinlik olduğunu göstermekte ve karar verme ve planlama amaçları için tahmin edilen değerlerin güvenilirliğini artırmaktadır. Modelin performansı ilerleyen bölümde istatistiksel olarak daha detaylı incelenecektir.

3.2.3 Holt Winter's Mevsimsel Üstel Düzgünleştirme Metoduyla Tahmin Yapılması

Üçlü üstel düzgünleştirme olarak da bilinen Holt-Winters mevsimsel üstel düzgünleştirme metodu, sadece bir trend ve seviye değil aynı zamanda mevsimsellik de sergileyen zaman serisi verilerini tahmin etmek için kullanılan bir tekniktir. Bu modelde de işlem görmemiş ham verinin gözden geçirilip eksik noktaların ve aykırı değerlerin düzeltilmesi gibi SARIMA ile tahmin öncesindeki yaptığımız işlemlerin aynıları yapılmaktadır. Bu adımlardan kısa olarak bahsedilmesi gerekirse:

Veri ön işleme, elektrik tüketim verileri, eksik değerlerin, aykırı değerlerin ve gerekli dönüşümlerin ele alınmasını içeren ön işleme tabi tutulur.

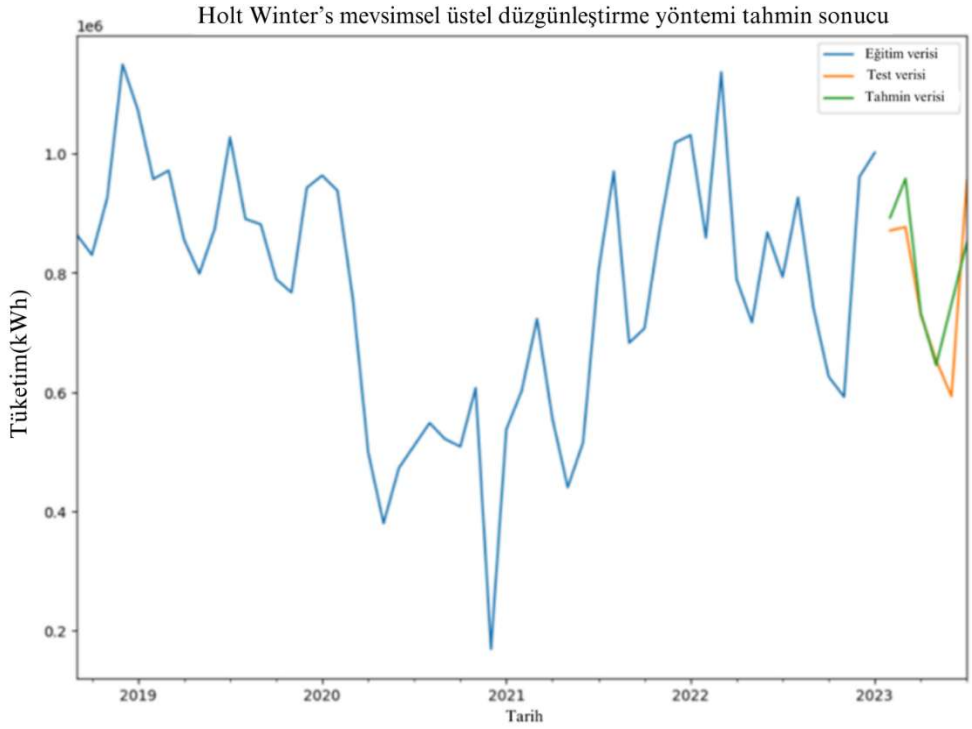
Model seçimi, üstel düzgünleştirme modelleri (basit üstel düzleştirme, Holt Winter's lineer trend ve Holt Winter's mevsimsel) eğitim verilerine uydurulur ve optimum düzleştirme parametreleri maksimum olabilirlik tahmini veya ızgara arama gibi teknikler kullanılarak modellerden birisi belirlenir.

Tahminin değerlendirilmesi, kurulan model tarafından üretilen tahminlerin doğruluğunun değerlendirilmesini içerir. Eğitilen model test verileri için tahmin üretmek üzere kullanılır ve tahmin doğruluğu MAPE metriği kullanılarak değerlendirilir.

Hassasiyet analizi, Üstel düzleştirme modellerinin düzleştirme parametrelerindeki ve diğer girdi değişkenlerindeki değişikliklere duyarlılığını değerlendirmek için bir duyarlılık analizi yapılır. Bu analiz, modellerin girdi parametrelerindeki değişikliklere duyarlılığını inceleyerek tahmin yaklaşımının sağlamlığını değerlendirir.

Model hakkında çıkarımlar, bu analizden elde edilen bilgiler, önerilen metodolojinin pratik yönleri, sınırlamaları ve potansiyel uzantılarının incelenmesi de dahil olmak üzere gerçek dünyadaki elektrik talebi tahmin uygulamaları bağlamında tartışılmaktadır.

Analizde, Şekil 3.4'te sunulan düzeltilmiş artık noktalardan arındırılmış veriler bu model için girdi verisi olarak kullanılmıştır.



Şekil 3.11 Holt Winter's mevsimsel üstel düzgünleştirme tahmin yönteminin sonuç grafiği

Yukarıda verilen Şekil 3.11 modelin tahmin grafiğini sunmaktadır. Grafik aşağıdakileri içermektedir:

Mavi çizgi, eğitim aşaması sırasında gözlemlenen değerleri temsil etmektedir.

Turuncu çizgi, modelin etkinliğini değerlendirmek için kullanılan bir test doğrulama setini temsil etmektedir.

Yeşil çizgi, modelin geçmiş verilere dayalı tahminlerini göstermektedir.

Veri seti 2019'dan 2023'e kadar olan dönemi kapsamakta ve gözlemlenen, test edilen ve tahmin edilen veriler açıkça gösterilmektedir. Tahmin değerleri, düzenli yukarı ve aşağı kaymaların da gösterdiği gibi, geçmiş verilerin genel eğilimini ve mevsimselliğini yakından takip etmektedir. Bu, modelin verilerdeki hem eğilimi hem de mevsimselliği etkili bir şekilde yakalama kapasitesini göstermekte ve böylece güvenilir kısa vadeli tahminlerin oluşturulmasını sağlamaktadır.

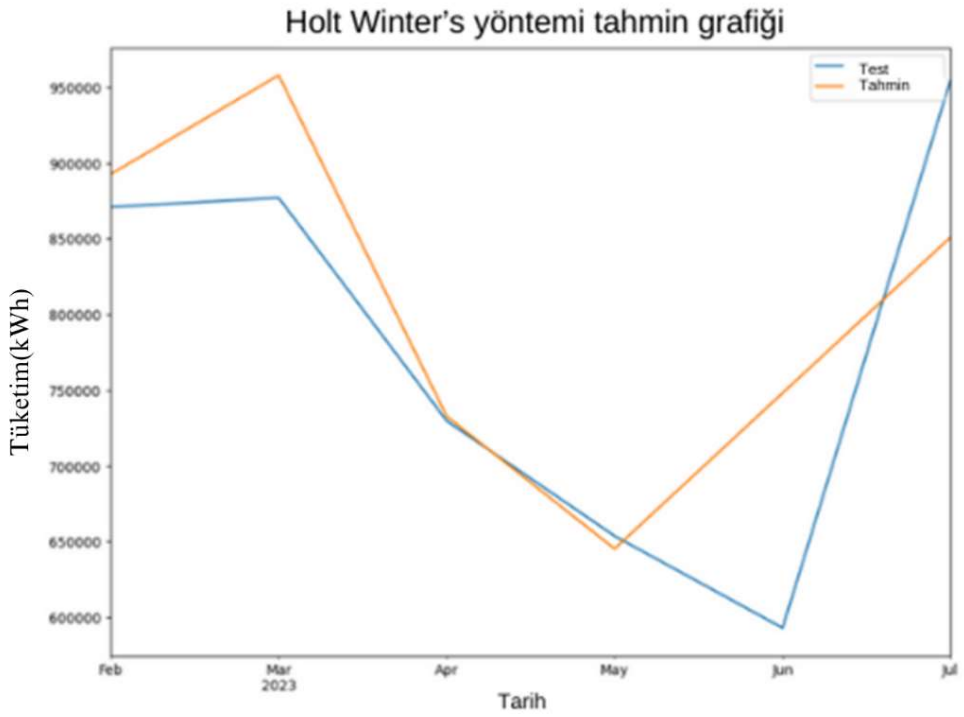
Bu çalışmada kullanılan değerlendirme ölçütleri arasında MAE ve ortalama mutlak MAPE yer almaktadır. 2023 Şubat ayından Temmuz 2023'e kadar olan dönem için MAE 62160’tır ve zaman serisinin belirli bölümlerinde önemli hatalar olduğunu göstermektedir. MAPE %7,97'dir ve genel olarak tatmin edici bir uyuma işaret etmekle birlikte, modelin yüksek oynaklıkla başa çıkmakta zorluk çektiği alanları da ortaya çıkarmıştır.

4
TAHMİN SONUÇLARININ DEĞERLENDİRİLMESİ

Bu bölüm, SARIMA ve Holt Winter's mevsimsel üstel düzgünleştirme olarak iki tahmin yönteminin performansının değerlendirmesinin yapıldığı ve sonuçların kıyaslandığı kısımdır. Her iki model de 4,5 yıllık veriler üzerinde eğitilmiş ve altı aylık tahminleri gerçek test sonuçlarıyla karşılaştırılmıştır. Bu karşılaştırmalı analiz, elektrik talebini tahmin etmede her bir yöntemin güçlü ve zayıf yönlerini ortaya koymayı amaçlamaktadır.

4.1 Holt Winter's Mevsimsel Üstel Düzgünleştirme Modeli

Holt Winter's mevsimsel üstel düzgünleştirme modeli, şubat ayından temmuz 2023'e kadar uzanan döneme odaklanarak zaman serisi verilerini tahmin etmek amacıyla kullanılmıştır. Tahmin sonuçları Şekil 4.1'de sunulmuştur; mavi çizgi gerçek gözlemlenen değerleri, turuncu çizgi ise tahmin edilen değerleri temsil etmektedir.



Şekil 4.1 Holt Winter's mevsimsel üstel düzgünleştirme yöntemi detaylı tahmin grafiği

Holt Winter's mevsimsel üstel düzgünleştirme modeli tarafından oluşturulan tahmin yörüngesi, test verilerinde gözlemlenen genel eğilimle genellikle tutarlı olan daha düzgün ve daha sürekli bir model göstermektedir. Bununla birlikte, Holt Winter's mevsimsel üstel düzgünleştirme modeli tarafından üretilen çizgi, gerçek zaman serisinde mevcut olan ani, düzensiz geçişleri doğru bir şekilde yansıtmamaktadır. Bununla birlikte, modelin performansı, veriler tarafından sergilenen geniş, kapsayıcı örüntüyü tahmin etmede orta derecede başarılı olarak kabul edilebilir. Holt Winter's mevsimsel metodunun söz konusu zaman serisinin belirli kesimlerinde gözlemlenen yüksek derecede oynaklığı yeterince yakalamakta zorlandığını belirtmek gerekir.

Modelin tahmin performansına ilişkin daha kapsamlı bir nicel değerlendirme sağlamak amacıyla, Tablo 4.1'de gerçek değerler ve model tahminiyle hesaplanan değerler gösterilmektedir. 62.160'lık MAE, modelin tahmin ettiği değerler ile gerçek gözlemlenen değerler arasındaki gözlemlenen hataların ortalama boyutunu temsil etmektedir. Buna ek olarak, 7,97'lik MAPE, her bir veri noktası tahminiyle ilişkili tipik hata yüzdesini gösterir.

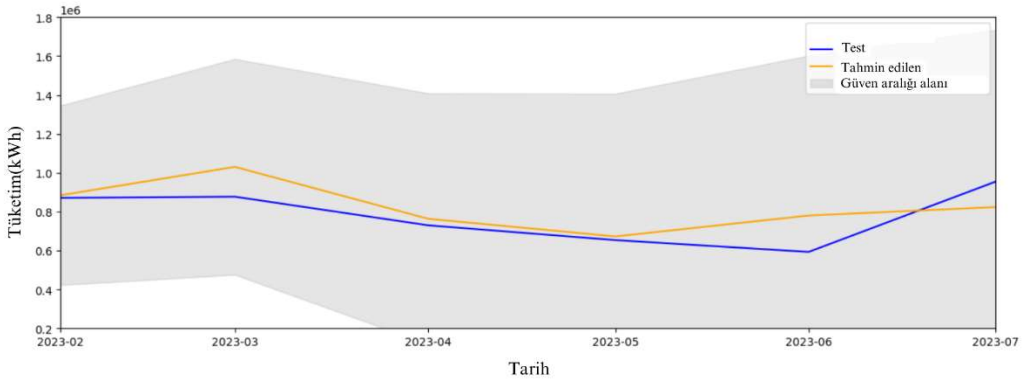
Tablo 4.1 Holt Winter's mevsimsel üstel düzgünleştirme modeli için tahmin ve gerçek değer kıyaslama tablosu

Tarih	Gerçek Tüketim (kWh)	Tahmini Tüketim (kWh)
1.02.2023	870932	892611
1.03.2023	876956	957934
1.04.2023	729696	732742
1.05.2023	653685	645225
1.06.2023	592972	748052
1.07.2023	954684	850966

Hem MAE hem de MAPE ölçütlerine göre hesaplanan değerler, modelin tahmin doğruluğunun artırılması açısından iyileştirme için hala önemli bir alan olduğunu göstermektedir. Tek haneli MAPE değeri genel uyumun oldukça iyi olduğunu gösterir ve modelin verilerin sergilediği genel eğilimi takip etmede başarılı olduğunu teyit ederken, nispeten yüksek MAE değeri, özellikle verilerin keskin, ani değişiklikler sergilediği durumlarda, tahmin edilen ve gözlemlenen değerler arasında önemli farklılıklar olduğunu göstermektedir.

4.2 SARIMA Modeli Sonuçlarının Değerlendirilmesi

Bu çalışmada kullanılan SARIMA modeli, Şekil 4.2 incelendiğinde tüketim verilerinde gözlemlenen genel eğilime tatmin edici bir uyum göstermektedir. SARIMA yaklaşımı tarafından üretilen tahmin değerleri genel olarak gerçek zaman serisinin sergilediği geniş örüntü ile tutarlıdır. Bununla birlikte, gözlemlenen verilerde mevcut olan daha belirgin dalgalanmaları ve ani geçişleri tam olarak yakalayamamaktadırlar.



Şekil 4.2 SARIMA yöntemi tahmin sonuç grafiği

Tablo 4.2'ye göre hesaplanan performans ölçütleri, modelin tahmin doğruluğunun nicel bir değerlendirmesini sağlar. MAE değerinin 89.512 olması, modelin tahminlerinin gerçek tüketim değerlerinden ortalama olarak yaklaşık 89.512 birim saptığını göstermektedir. Ayrıca, %11,48'lik MAPE, her bir tahminle ilişkili tipik yüzde hatanın yaklaşık %11,48 olduğunu göstermektedir. MAPE değeri genel olarak kabul edilen doğruluk aralığında olmasına rağmen, nispeten yüksek MAE, modelin tüketim zaman serisinin belirli kesimlerinde gözlemlenen önemli dalgalanmaları ve keskin değişiklikleri doğru bir şekilde yakalamakta zorluk çektiğini göstermektedir.

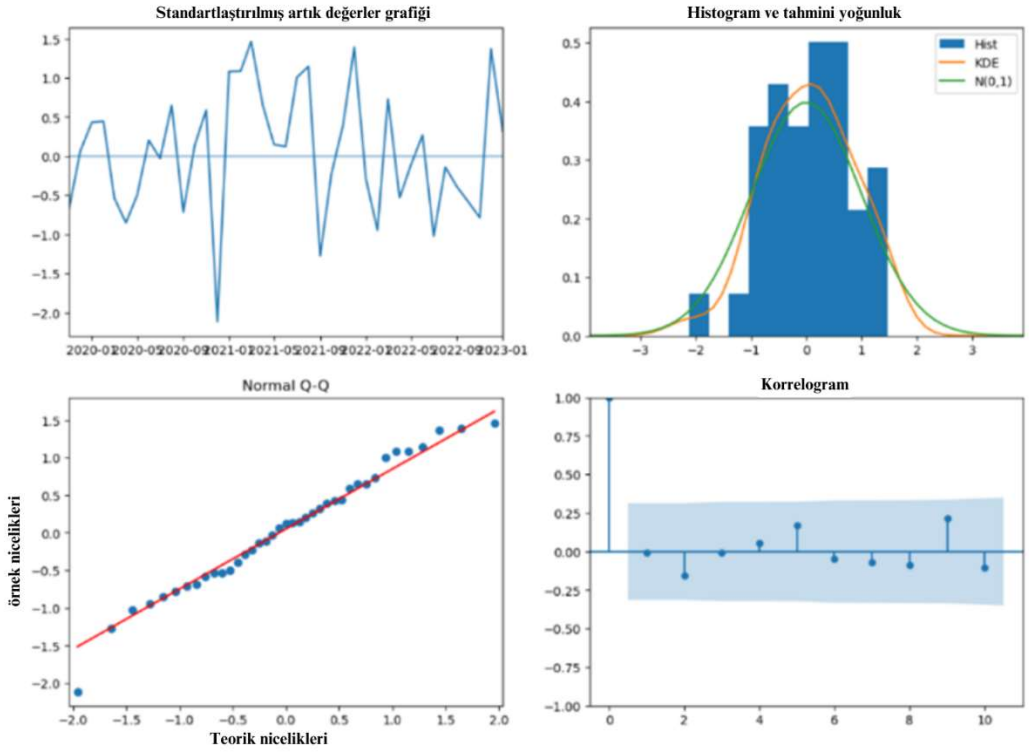
Bu tutarsızlık, SARIMA tarafından üretilen tahminlerin belirli durumlarda gerçek tüketim değerlerinden önemli ölçüde farklılaştığı tabloda açıkça görülmektedir.

Modelin tahmin performansını artırmak için SARIMA parametrelerinde daha fazla iyileştirme ve ayarlama yapılması gerekebilir. Dışsal değişkenlerin dahil edilmesi veya alternatif modelleme yaklaşımlarının denenmesi, modelin verilerde mevcut olan altta yatan dinamikleri ve kısa vadeli dalgalanmaları yakalama kabiliyetini potansiyel olarak artırabilir ve böylece gözlemlenen hataların büyüklüğünü azaltabilir.

Tablo 4.2 SARIMA modeli için tahmin ve gerçek değer kıyaslama tablosu

Tarih	Gerçek Tüketim (kWh)	Tahmini Tüketim (kWh)
1.02.2023	870932	883996
1.03.2023	876956	1030246
1.04.2023	729696	763380
1.05.2023	653685	672542
1.06.2023	592972	780098
1.07.2023	954684	823629

SARIMA modeli, Şekil 4.3'te standartlaştırılmış artık grafiğinde gösterildiği gibi, orijinal zaman serisi verilerinde mevcut olan eğilimleri ve mevsimselliği etkili bir şekilde ortadan kaldırmak için kullanılmıştır. Artıklar sıfır çizgisi etrafında rastgele bir dalgalanma sergilemekte olup, fark edilebilir bir örüntü içermemektedir; bu da modelin bu özellikleri başarılı bir şekilde ortadan kaldırdığını göstermektedir. Artıklardaki birkaç izole sivri uç, bazı aykırı değerlerin tam olarak hesaba katılmadığını gösterse de genel sonuçlar oldukça umut vericidir.



Şekil 4.3 SARIMA tahminine ait standart dağılım ve istatistiksel analiz grafikleri

Şekil 4.3'teki yoğunlaştırılmış histogram grafiği, standartlaştırılmış artıkların yaklaşık olarak normal dağıldığını ve böylece hataların normalliği varsayımını karşıladığını doğrulayan bir yoğunluk grafiği ile bir histogram sunmaktadır. Kernel yoğunluk tahmininde (KDE) sıfırda küçük bir tepe noktası artıklarda küçük bir basıklık derecesine işaret etse de normallikten sapma söz konusu değildir.

Şekil 4.3'teki normal kuantil-kuantil grafiği bu sonuca daha fazla destek sağlamaktadır, çünkü noktalar kuantillerin çoğu için referans çizgisine yakın bir şekilde hizalanmaktadır. Artık hatalar, dağılımın kuyruklarında sapmaya neden olacak kadar önemli değildir.

Şekil 4.3'teki korelogram grafiği, otokorelasyon fonksiyonunda hızlı bir düşüş göstermekte ve tüm değerler güven bantları içinde kalmaktadır. Bu, SARIMA modelinin orijinal zaman serisinde bulunan tüm zamansal bağımlılıkları başarıyla ortadan kaldırdığını göstermektedir. Özet olarak, SARIMA modeli tüketim verilerindeki genel eğilime makul düzeyde uyum göstermektedir.

Tablo 4.3 SARIMA ve Holt Winter's mevsimsel üstel düzgünleştirme metodu kıyaslama tablosu

Tarih	SARIMA metodu tahmini tüketim değerleri (kWh)	Gerçek tüketim değerleri (kWh)	Holt Winter's mevsimsel üstel düzgünleştirme metodu tahmini tüketim değerleri(kWh)
1.02.2023	883996	870932	892611
1.03.2023	1030246	876956	957934
1.04.2023	763380	729696	732742
1.05.2023	672542	653685	645225
1.06.2023	780098	592972	748052
1.07.2023	823629	954684	850966

Tablo 4.3'de sunulan sonuçlara, Şekil 4.1 ve Şekil 4.2 deki model performans grafiklerine göre, Holt Winter's mevsimsel üstel düzgünleştirme modeli, MAPE ile kanıtlandığı üzere, zaman serisi tahmini için önemli bir potansiyel sergilemektedir.

Ancak model, MAE ile gösterildiği üzere, yüksek volatilite dönemlerinde zorluklarla karşılaşmaktadır. Tahmin performansını artırmak için, ani dalgalanmaları daha iyi ele alan tahmin tekniklerini dahil etmek tahmin sonuçlarının güvenilirliği için önemlidir.

5
SONUÇ

Bu çalışmada, altı aylık bir süre boyunca Holt-Winters mevsimsel üstel düzgünleştirme yönteminin ve SARIMA modelinin gelecekteki elektrik talebini tahmin etmedeki etkinliğinin kapsamlı bir değerlendirmesi yapılmıştır. Zaman serisi verilerinin tutarlı çıktı sağlayacak şekilde modellenmesi, titiz veri ön işleme ve normalizasyon aşamaları sayesinde mümkün olmuştur. Özellikle SARIMA modeli, elektrik tüketimine ilişkin verilerin doğasında bulunan karmaşık mevsimsel kalıpları ve eğilimleri doğru bir şekilde temsil etme kapasitesini göstermiştir. Nicel değerlendirme ölçütleri olarak MAPE, AIC, BIC ve MAE gibi yöntemler kullanılarak, her bir tahmin yönteminin göreceli performansları ve sınırlamaları hakkında önemli bilgiler sağlanmıştır. SARIMA modeli, yüzde 11,48'lik bir MAPE ile tahminlerinde nispeten düşük bir ortalama yüzde hata sergilemiştir. Holt-Winter's üstel düzgünleştirme yöntemi yüzde 7,97'lik bir MAPE ile üstün bir genel doğruluk sergilemiş olsa da, zaman serisindeki daha ani trend değişikliklerini etkili bir şekilde takip edememiştir. İki yaklaşımın karşılaştırmalı analizi, modellerin karmaşıklığı, yorumlanabilirliği ve tahmin gücü arasındaki dengeleri ortaya koymuştur. Holt-Winter's yaklaşımı, elektrik tüketiminin altında yatan dinamiklerin daha karmaşık ve incelikli bir temsilini sunan SARIMA modeline göre daha basit, daha kullanıcı dostu ve potansiyel olarak daha esnek bir tahmin çözümü sunmuştur.

Stratejik karar alma süreçlerini bilgilendirmek için geliştirilen tahmin modellerini kullanarak kaynak tahsisini, altyapı yatırımlarını ve sürdürülebilirlik girişimlerini optimize etmek mümkündür. Bu çalışmadan elde edilen metodolojik içgörüler, önemli miktarda enerji kullanan diğer kurumsal bağlamlara uygulanabilir ve böylece enerji sistemlerinin dayanıklılığını ve verimliliğini artırmaya yönelik genel hedef daha da ileriye götürülebilir. Daha ileri araştırmalar, farklı metodolojilerin güçlü yönlerini birleştiren, örneğin makine öğrenimi algoritmalarını geleneksel zaman serisi yaklaşımlarıyla entegre eden hibrit modelleme stratejilerini araştırabilir.

Ayrıca, tahmin modellerinin doğruluğu ve esnekliği, meteorolojik veriler, doluluk eğilimleri ve ekonomik göstergeler gibi harici değişkenlerin dahil edilmesiyle artırılabilir. Geliştirilen çözümlerin gelişen enerji ortamları bağlamında uzun vadeli uygunluğunu ve etkinliğini sağlamak için sürekli model doğrulama, izleme ve yeniden kalibrasyon yapılması önemlidir. Sonuç olarak, bu kapsamlı yüksek lisans tezi, bir üniversite kampüsü bağlamında geleneneksel ve en yeni analitik tekniklerinin kıyaslamalı etkinliğini göstererek, enerji talebi tahmini alanında farklı bir bakış açısı sağlamıştır. Enerji sistemlerinin sürdürülebilirliğini ve dayanıklılığını artırmak için, çalışmanın sonuçları ve metodolojik içgörüleri sayesinde gerçek dünya uygulamaları mümkün olacaktır.

KAYNAKÇA

[1] R. J. Hyndman and G. Athanasopoulos, Forecasting: Principles and Practice, 2nd ed., OTexts, 2018.

[2] R. J. Hyndman and Y. Khandakar, "Automatic Time Series Forecasting: The forecast Package for R," Journal of Statistical Software, vol. 27, no. 3, pp. 1-22, 2008.

[3] M. S. Al-Musaylh, R. C. Deo, J. F. Adamowski, and Y. Li, "Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia," Energy Conversion Management, vol. 16, no. 3, pp. 795-806, 2018.

[4] M. Wasesa, A. R. Tiara, M. A. Afrianto, F. I. Ramadhan, I. N. Haq, and J. Pradipta, "SARIMA and Artificial Neural Network Models for Forecasting Electricity Consumption of a Microgrid Based Educational Building," Energies, vol. 16, no. 3, pp. 795-806, 2023.

[5] J. A. Zancanaro, O. L. Santos, L. F. Ugarte, M. Giesbrecht, and M. C. Almeida, Eds., Proceedings of 2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe): Bucharest, Romania, 29 September-2 October 2019. Universitatea Politehnică București, IEEE Power & Energy Society, Institute of Electrical and Electronics Engineers, 2019.

[6] G. Tian, D. Niu, Z. Ji, and L. Sun, "Mid-term electricity demand forecasting using improved variational mode decomposition and extreme learning machine optimized by sparrow search algorithm," Energy, vol. 261, pp. 1-12, 2022, doi: 10.1016/j.energy.2022.125305.

[7] T. González Grandón, J. Schwenzer, T. Steens, and J. Breuing, "Electricity demand forecasting with hybrid classical statistical and machine learning algorithms: Case study of Ukraine," Applied Energy, vol. 355, pp. 1-12, 2024, doi: 10.1016/j.apenergy.2024.120355.

[8] D. Hadjout, A. Sebaa, J. F. Torres, and F. Martínez-Álvarez, "Electricity consumption forecasting with outliers handling based on clustering and deep learning with application to the Algerian market," Expert Systems with Applications, vol. 227, 2023, doi: 10.1016/j.eswa.2023.120123.

[9] D. A. Bolstad, U. Cali, M. Kuzlu, and U. Halden, "Day-ahead Load Forecasting using Explainable Artificial Intelligence," in Proceedings of the IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), 2022, pp. 1-5.

[10] R. K. Shiwakoti, C. Charoenlarpnopparut, and K. Chapagain, "Time Series Analysis of Electricity Demand Forecasting Using Seasonal ARIMA and an Exponential Smoothing Model," in Proceedings of the 2017 10th International Conference on Electrical and Electronics Engineering (ELECO), 2017, pp. 1-5.

[11] M. Severini, S. Squartini, and F. Piazza, "Computational framework based on task and resource scheduling for micro grid design," in Proceedings of the IEEE International Conference on Smart Grid Communications (SmartGridComm), 2015, pp. 1-6.

[12] B. Anderson, J. Rane, and R. Khan, "Distributed wind-hybrid microgrids with autonomous controls and forecasting," IEEE Transactions on Sustainable Energy, vol. 14, no. 3, pp. 1234-1245, Mar. 2023.

[13] C. Tarmanini, N. Sarma, C. Gezegin, and O. Ozgonenel, "Short term load forecasting based on ARIMA and ANN approaches," in Proceedings of the IEEE International Conference on Power Systems Technology (POWERCON), 2023, pp. 1-6.

[14] K. Goswami and A. B. Kandali, "Electricity Demand Prediction using Data Driven Forecasting Scheme: ARIMA and SARIMA for Real-Time Load Data of Assam," in Proceedings of the 2020 International Conference on Computational Performance Evaluation (ComPE), 2020, pp. 570-574.

[15] J. Brownlee, "A Gentle Introduction to Time Series Forecasting," 2020.

[16] A. Vaswani et al., "Attention is All You Need," arXiv:1706.03762, 2017.

[17] D. Bahdanau et al., "Neural Machine Translation by Jointly Learning to Align and Translate," arXiv:1409.0473, 2015.

[18] I. Sutskever et al., "Sequence to Sequence Learning with Neural Networks," arXiv:1409.3215, 2014.

[19] T. Chen et al., "A Simple Framework for Contrastive Learning of Visual Representations," arXiv:2002.05709, 2020.

[20] C. Doersch et al., "Unsupervised Visual Representation Learning by Context Prediction," arXiv:1505.05192, 2020.

[21] J. Kaplan et al., "Scaling Laws for Neural Language Models," arXiv:2001.08361, 2020.

[22] T. Brown et al., "Language Models are Few-Shot Learners," arXiv:2005.14165, 2020.

[23] A. Dosovitskiy et al., "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," arXiv:2010.11929, 2021.

[24] Z. Wu et al., "A Comprehensive Survey on Graph Neural Networks," IEEE Transactions on Neural Networks and Learning Systems, vol. 32, no. 1, pp. 4-24, Jan. 2020.

[25] G. Hinton et al., "Distilling the Knowledge in a Neural Network," arXiv:1503.02531, 2015.

[26] S. Pan and Q. Yang, "A Survey on Transfer Learning," IEEE Transactions on Knowledge and Data Engineering, vol. 22, no. 10, pp. 1345-1359, Oct. 2010.

[27] S. Makridakis et al., "The M4 Competition: Results, findings, conclusion and way forward," International Journal of Forecasting, vol. 36, no. 1, pp. 802-808, 2020.

[28] J. Wang, H. Zhong, C. Ai, Q. Xia, and C. Kang, "Demand-side management for residential customers in the smart grid," Energies, vol. 12, no. 12, p. 2320, 2019.

[29] M. Arenas-Martinez, P. Goncalves, and M. Pourakbar, "Forecasting electricity demand with the Internet of Things and machine learning," IEEE Trans. Ind. Inform., vol. 16, no. 3, pp. 1608-1619, 2019.

[30] A. Khotanzad, E. Zhou, and H. Elragal, "A neuro-fuzzy approach to short-term load forecasting in a price-sensitive environment," IEEE Trans. Power Syst., vol. 17, no. 4, pp. 1273-1282, 2002.

[31] D. Jain, N. Dhiman, and A. Kumar, "Hybrid forecasting models for short-term electricity demand prediction," Electr. Power Syst. Res., vol. 162, pp. 74-86, 2018.

[32] F. Apadula, A. Bassini, A. Elli, and S. Scapin, "Relationships between meteorological variables and monthly electricity demand," Appl. Energy, vol. 98, pp. 346-356, 2012.

[33] G. Gross and F. Galiana, "Short-term load forecasting," Proc. IEEE, vol. 75, no. 12, pp. 1558-1573, 1987.

[34] M. Ghofrani, M. Hassanzadeh, M. Etezadi-Amoli, and M. Fadali, "Smart grid: Reinforcement learning for renewable energy management with battery storage," in Proc. IEEE PES Gen. Meet., 2011, pp. 1-7.

[35] NIST/SEMATECH, "e-Handbook of Statistical Methods," 2012. Doi: 10.18434/M32189.

[36] Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time series analysis: forecasting and control. John Wiley & Sons.

[37] Shumway, R. H., & Stoffer, D. S. (2017). Time series analysis and its applications: with R examples. Springer.

[38] Brockwell, P. J., & Davis, R. A. (2016). Introduction to time series and forecasting. Springer.

[39] Chatfield, C. (2016). The analysis of time series: an introduction. CRC Press.

[40] Tsay, R. S. (2014). Multivariate time series analysis: with R and financial applications. John Wiley & Sons.

[41] Cryer, J. D., & Chan, K. S. (2008). Time series analysis: with applications in R. Springer Science & Business Media.

[42] H. S. Hippert, C. E. Pedreira, and R. C. Souza, "Neural networks for short-term load forecasting: A review and evaluation," IEEE Trans. Power Syst., vol. 16, no. 1, pp. 44-55, 2001, doi: 10.1109/59.910780.

[43] H. Akaike, "A new look at the statistical model identification," IEEE Trans. Autom. Control, vol. 19, no. 6, pp. 716-723, 1974.

[44] K. P. Burnham and D. R. Anderson, "Multimodel inference: understanding AIC and BIC in model selection," Sociol. Methods Res., vol. 33, no. 2, pp. 261-304, 2004.

[45] G. Schwarz, "Estimating the dimension of a model," Ann. Stat., vol. 6, no. 2, pp. 461-464, 1978.

[46] J. H. Friedman, T. Hastie, and R. Tibshirani, *The Elements of Statistical Learning*, 2nd ed. New York, NY, USA: Springer, 2009.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. A. Durusu, B. Karakoç, and İ. B. Kaya, "Assessment of the Effectiveness of Exponential Smoothing Methods for the Estimation of Electricity Consumption Patterns in University Campuses," in Proc. 3rd Bilsel Int. Truva Sci. Res. Innov. Congr., Çanakkale, Türkiye, May 2024, pp. 640-653.