

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**İSTATİSTİK VE YAPAY ZEKA TEKNİKLERİ İLE  
ENERJİ TÜKETİMİNİN TAHMİNİ: SAKARYA  
DOĞAL GAZ TÜKETİMİNİN UYGULAMASI**

**DOKTORA TEZİ**

**Mustafa AKPINAR**

**Enstitü Anabilim Dalı** : **BİLGİSAYAR VE BİLİŞİM  
MÜHENDİSLİĞİ**  
**Tez Danışmanı** : **Prof. Dr. Nejat YUMUŞAK**

**Şubat 2017**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK VE YAPAY ZEKA TEKNİKLERİ İLE  
ENERJİ TÜKETİMİNİN TAHMİNİ: SAKARYA  
DOĞAL GAZ TÜKETİMİNİN UYGULAMASI

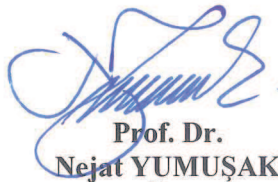
DOKTORA TEZİ

Mustafa AKPINAR

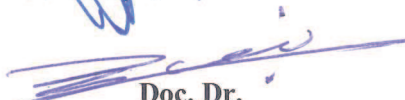
Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM  
MÜHENDİSLİĞİ


Bu tez 02 / 02 /2017 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.

  
Prof. Dr.  
Mehmet Ali EBEÖĞLU  
Jüri Başkanı

  
Prof. Dr.  
Nejat YUMUŞAK  
Üye

  
Doç. Dr.  
Kürşat AYAN  
Üye

  
Doç. Dr.  
Yılmaz Uyaroğlu  
Üye

  
Doç. Dr.  
Hamdi Melih SARAOĞLU  
Üye

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Mustafa AKPINAR

02.02.2017

## TEŐEKKÜR

Doktora alıŐmalarım sűresince, bilgi ve deneyimleri ile yol gűsteren, insanlara yaklaŐımıyla olumlu Őekilde motive eden ve yűnlendiren deęerli danıŐman hocam Prof. Dr. Nejat YumuŐak engin bilgilerini hibir zaman benden esirgememiŐtir. Verdięi bilgilerden, desteklerinden ve tez alıŐmam sűresince sabırla beni motive etmesinden dolayı kendisine teŐekkűrű bir bor bilirim.

Tez izleme komitesinde bulunan deęerli Do. Dr. KűrŐat Ayan ve Do. Dr. Yılmaz Uyaroęlu hocalarımın tez alıŐmam sűresince gűstermiŐ oldukları destek ve ilgiden dolayı kendilerine teŐekkűr ederim. Bu tez alıŐmasında kullanılan verilerin elde edilmesi ve dűzenlenmesinde katkı saęlayan baŐta AGDAŐ Genel Műdűrű Kenan Demir, Genel Műdűr Yardımcısı Mesut YaŐar Uzun, Ticari Hizmetler Műdűrű Faruk Gűrpınar ve Ticari Hizmetler Yűneticisi Ertan Ersűz'e katkılarından dolayı teŐekkűr ederim.

Doktora alıŐmalarım sırasında tűkenmez sabrı, desteęi, motivasyonu ile maddi, manevi desteęini esirgemeyen eŐim Kevser Ovaz Akpınar'a ve her zaman yanımda olan aileme teŐekkűrű bor bilirim.

## İÇİNDEKİLER

TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
SİMGELER VE KISALTMALAR LİSTESİ .....	v
ŞEKİLLER LİSTESİ .....	vii
TABLolar LİSTESİ .....	ix
ÖZET .....	xi
SUMMARY .....	xii

### BÖLÜM 1.

GİRİŞ .....	1
-------------	---

### BÖLÜM 2.

DOĞAL GAZ TALEP TAHMİNİ .....	5
2.1. Doğal Gaz Piyasası .....	5
2.1.1. Yıl öncesi kapasite rezervasyonu .....	7
2.1.2. Ay öncesi atıl kapasite rezervasyonu .....	7
2.1.3. Kapasite aktarımı .....	8
2.1.4. Gün öncesi doğal gaz talep tahmini .....	8
2.1.5. Gün sonrası doğal gaz dengelemesi .....	9
2.2. Literatür Çalışması .....	9

### BÖLÜM 3.

TALEP TAHMİNİNDE KULLANILAN YÖNTEMLER .....	15
3.1. Zaman Serilerinin Ayırıştırması .....	15
3.1.1. Eğilimin belirlenmesi .....	16
3.1.2. Konjonktür etkisi .....	18
3.1.3. Sezonallık (Mevsimsellik) etkisi .....	18
3.1.4. Düzensiz hareketler (Kalıntılar) .....	19
3.2. Holt Üstel Düzleştirme Yöntemi .....	19
3.3. Holt-Winters Üstel Düzleştirme Yöntemi .....	20
3.4. ARIMA/SARIMA (Box-Jenkins Yöntemi) .....	21
3.4.1. Kendiyle bağdaşımli modeller .....	24
3.4.2. Hareketli ortalamalı modeller .....	25
3.4.3. Durağanlık .....	26
3.4.4. Beyaz gürültü .....	28
3.5. Yapay Sinir Ağları .....	28
3.5.1. İleri doğru hesaplama .....	29
3.5.2. Geri yayılım algoritması .....	30
3.6. Yapay Arı Kolonisi .....	31
3.7. YSA – YAK Entegrasyonu .....	33

### BÖLÜM 4.

ARAŞTIRMA BULGULARI VE SONUÇLAR .....	37
4.1. Doğal Gaz Tüketim Verisinin Hazırlanması .....	37
4.2. Yıl Öncesi Aylık Talep Tahmini ve Sonuçları .....	39
4.2.1. Aylık veri üzerinden yıl öncesi talep tahmini .....	40
4.2.1.1. Zaman serilerinin ayırıştırma sonuçları .....	40
4.2.1.2. Holt-Winters üstel düzleştirme sonuçları .....	41
4.2.1.3. ARIMA/SARIMA yöntemi sonuçları .....	43
4.2.2. Günlük veri üzerinden aylık tahmin.....	48
4.2.2.1. Zaman serilerinin ayırıştırma sonuçları .....	49
4.2.2.2. Holt-Winters üstel düzleştirme sonuçları .....	49

4.2.2.3. ARIMA/SARIMA yöntemi sonuçları .....	51
4.2.3. Yıl öncesi aylık talep tahmininin genel değerlendirmesi .....	57
4.3. Gün Öncesi Talep Tahmini ve Sonuçları .....	58
4.3.1. Zaman serilerinin ayrıştırma sonuçları .....	58
4.3.2. Holt-Winters üstel düzeltirme sonuçları .....	59
4.3.3. ARIMA/SARIMA yöntemi sonuçları .....	61
4.3.4. Kayan pencere yöntemi sonuçları .....	62
4.3.4.1. Holt-Winters üstel düzeltirme yöntemi sonuçları ...	63
4.3.4.2. Yapay sinir ağları sonuçları .....	65
4.3.5. Gün öncesi talep tahmininin genel değerlendirmesi.....	75
BÖLÜM 5.	
TARTIŞMA VE ÖNERİLER .....	78
KAYNAKLAR .....	83
ÖZGEÇMİŞ .....	93

## SİMGELER VE KISALTMALAR LİSTESİ

ACF	: Autocorrelation function (Kendiyle ilgileşim fonksiyonu)
ADF	: Augmented Dickey Fuller (Genişletilmiş Dickey Fuller)
AGDAŞ	: Adapazarı Gaz Dağıtım A.Ş.
ANFIS	: Adaptive neuro fuzzy inference system (Uyarlamalı ağ temelli bulanık arayüz sistemi)
ARIMA	: Autoregressive integrated moving average (Tümleşik kendiyle bağlaşımlı hareketli ortalama)
ARIMAX	: ARIMA with eXogenous variable (Dışsal değişken içerebilen ARIMA)
BOTAŞ	: Boru Hatları ile Petrol Taşıma A.Ş.
ÇES	: Çarpımsal eğilim sezonsal
ÇS	: Çarpımsal sezonsal
DEA	: Differential evolution algorithm (Diferansiyel gelişim algoritması)
EBT	: BOTAŞ elektronik bülten tablosu
EPDK	: Enerji Piyasası Düzenleme Kurumu
FDEA	: Fuzzy data envelopment analysis (Bulanık veri zarflama analizi)
GA	: Genetik algoritma
GM	: Grey modeli
GST	: Gün sonrası ticaret
GY	: Geri yayılım algoritması
KPT	: Kayan pencere tekniği
LNG	: Liquid natural gas (Sıvılaştırılmış doğal gaz)
MAK	: Maksimum ayrılabilir kapasite
MAPE	: Mean absolute percent error (Bağıl mutlak yüzdesel hata)



MSE	: Mean square error (Ortalama kare hata)
PACF	: Partial autocorrelation function (Kısmi kendiyle ilgileşim fonksiyonu)
PP	: Philips Perron
RMS	: Reduce measurement station (Gaz basıncı düşürme ve ölçüm istasyonu)
SARIMA	: Seasonal autoregressive integrated moving average (Sezonsal tümleşik kendiyle bağlaşımlı hareketli ortalama)
SVM	: Support vector machine (Destek vektör makinası)
ŞİD	: Şebeke işleyiş düzenlemeleri
TES	: Toplamsal eğilim sezonsal
TKH	: Toplam kare hata
TMB	: Taşıma miktar bildirim
TMDB	: Taşıma miktar düzeltme bildirim
TS	: Toplamsal sezonsal
WÇ0.2	: Winters çarpımsal 0.2 parametre değerleri
WÇE'	: Winters çarpımsal eğilimsiz
WÇO	: Winters çarpımsal optimize edilmiş parametreler
WT0.2	: Winters toplamsal 0.2 parametre değerleri
WTE'	: Winters toplamsal eğilimsiz
WTO	: Winters toplamsal optimize edilmiş parametreler
YAK	: Yapay arı kolonisi
YSA	: Yapay sinir ağları

## ŞEKİLLER LİSTESİ

Şekil 2.1. Enerji Piyasası ve Doğal Gaz Sektörü [3] .....	5
Şekil 2.2. Doğal gaz piyasası ve sektörü .....	6
Şekil 3.1. Zaman serisinin ayrıştırması [44], [45] .....	16
Şekil 3.2. Box-Jenkins yaklaşımı .....	23
Şekil 3.3. Örnek bir yapay sinir ağı .....	28
Şekil 3.4. Örnek bir YSA modeli .....	33
Şekil 3.5. YSA-YAK entegrasyonu akış diyagramı .....	35
Şekil 4.1. Talep tahmini için model oluşturulması .....	38
Şekil 4.2. Aylık ve günlük doğal gaz tüketimi .....	38
Şekil 4.3. Aylık doğal gaz tüketim alt grafiği .....	39
Şekil 4.4. Yıl öncesi aylık talep tahmininde aylık veri üzerinden zaman serilerinin ayrıştırmasının sonuçları .....	40
Şekil 4.5. Yıl öncesi aylık talep tahmininde aylık veri üzerinden Winters üstel düzleştirme yöntemi sonuçları .....	43
Şekil 4.6. Aylık doğal gaz tüketimi ve fark alma sonucu doğal gaz tüketimi ...	43
Şekil 4.7. Logaritmik dönüştürülmüş ve farkları alınmış tüketimlerin ACF ve PACF grafikleri .....	47
Şekil 4.8. Yıl öncesi aylık talep tahmininde aylık veri üzerinden ARIMA/SARIMA sonuçları .....	48
Şekil 4.9. Yıl öncesi aylık talep tahmininde günlük veri üzerinden zaman serilerinin ayrıştırmasının sonuçları .....	49
Şekil 4.10. Yıl öncesi aylık talep tahmininde günlük veri üzerinden Winters üstel düzleştirme yöntemi sonuçları .....	50
Şekil 4.11. Günlük doğal gaz tüketimi ve fark alma sonucu doğal gaz tüketimi	51
Şekil 4.12. Logaritmik dönüştürülmüş ve farkları alınmış tüketimlerin ACF ve PACF grafikleri .....	54

Şekil 4.13. Yıl öncesi aylık talep tahmininde günlük veri üzerinden ARIMA/SARIMA sonuçları .....	56
Şekil 4.14. Gün öncesi talep tahmininde zaman serilerinin ayrıştırmasının sonuçları .....	59
Şekil 4.15. Gün öncesi talep tahmininde Winters üstel düzleştirme yöntemi sonuçları .....	60
Şekil 4.16. Gün öncesi talep tahmininde günlük veri üzerinden ARIMA/SARIMA sonuçları .....	62
Şekil 4.17. Kayan pencere ve gün öncesi talep tahmini.....	62
Şekil 4.18. Gün öncesi kayan pencere yöntemi Winters üstel düzleştirme parametrelerinin değişimi .....	64
Şekil 4.19. Gün öncesi kayan pencere yöntemi Winters üstel düzleştirme sonuçları .....	65
Şekil 4.20. Doğal gaz talep tahmini için hazırlanan YSA modeli .....	67
Şekil 4.21. En düşük MAPE değerlerine sahip YSA'nın eğitim durumları .....	71
Şekil 4.22. Gün öncesi kayan pencere yöntemi YSA sonuçları .....	73
Şekil 4.23. Gün öncesi kayan pencere yöntemi en iyi performans gösteren YSA model sonuçları .....	75

## TABLolar LİSTESİ

Tablo 4.1. Aylık tüketim ile Winters üstel düzleştirme yöntemi ile aylık tahmin sonuçları .....	42
Tablo 4.2. Fark alınmış serilerin tanımlayıcı istatistikleri .....	44
Tablo 4.3. Tüketim serilerinin durağanlık test sonuçları .....	45
Tablo 4.4. ARIMA/SARIMA yöntemi için en iyi sonuçlar ve tahmin hata durumları .....	46
Tablo 4.5. Günlük tüketim ve Winters üstel düzleştirme yöntemi ile aylık tahmin sonuçları .....	50
Tablo 4.6. Fark alınmış serilerin tanımlayıcı istatistikleri .....	52
Tablo 4.7. Tüketim serilerinin durağanlık test sonuçları .....	53
Tablo 4.8. ARIMA/SARIMA yöntemi için en iyi sonuçlar ve tahmin hata durumları .....	56
Tablo 4.9. Günlük tüketim ve Winters üstel düzleştirme yöntemi ile günlük tahmin sonuçları .....	60
Tablo 4.10. ARIMA/SARIMA yöntemi için en iyi sonuçlar ve tahmin hata durumları .....	61
Tablo 4.11. YSA eğitiminde kullanılan GY ve YAK algoritmalarının parametreleri .....	66
Tablo 4.12. Günlük doğal gaz tüketimi ve normalize edilmiş doğal gaz tüketiminin tanımlayıcı istatistikleri .....	68
Tablo 4.13. Performans kriterine göre hazırlanan ağ yapısı sayıları .....	69
Tablo 4.14. En düşük MAPE' ye sahip ağ modelleri ve kısaltmaları .....	70
Tablo 4.15. Gün öncesi YSA yöntemi için en iyi sonuçlar ve tahmin hata durumları .....	74
Tablo 4.16. Gün öncesi modellerin tahminleri için ceza bedelleri .....	77
Tablo 5.1. Yıl öncesi aylık doğal gaz talep tahmin sonuçları .....	79

Tablo 5.2. Gün öncesi doğal gaz talep tahmin sonuçları .....	80
--	----

## ÖZET

Anahtar kelimeler: Enerji talep tahmini, zaman serilerinin ayrıştırılması, Winters üstel düzleştirme yöntemi, SARIMA, kayan pencere yöntemi

Ülke yönetimleri, enerji talep tahminlerini güvenilir, doğru ve düşük hata ile yaparak ekonomik ve sosyal kayıpları azaltmak için çalışmaktadırlar. Bu tez çalışması kapsamında, enerji sektöründeki önemli alt sektörlerden biri olan doğal gaz üzerine yıl öncesi aylık talep tahmini ve gün öncesi talep tahmini, farklı yöntemler kullanarak en düşük hata ile gerçekleştirilmeye çalışılmıştır. Önerilen yöntemler, tek değişkenli olup, kendi tüketim verisinden başka hiçbir veriye ihtiyaç duymamaktadır. Tez çalışması kapsamında getirilen yenilik; yanlış tahminden kaynaklanan cezaları en aza indirecek model ve yaklaşımın bulunması olup, bunların günlük yaşamda kullanılabileceğini göstermektedir.

Bu çalışmada doğal gaz talep tahmini için iki farklı durum ele alınmıştır. İlk durumda yıl öncesi aylık talep tahmini yapılırken, ikinci durumda gün öncesi talep tahmini yapılmıştır. Dört yıllık doğal gaz tüketim verisi üzerinden önce yıl öncesi aylık talep tahminleri aylık ve günlük olarak iki farklı veri yoğunluğunda. Zaman serilerinin ayrıştırılması (ZSA), Winters üstel düzleştirme (WÜD) yöntemi, tümleşik kendiyile bağlaşımlı hareketli ortalama (ARIMA), sezonsal ARIMA (SARIMA) yöntemleri kullanılarak gerçekleştirilmiştir. Bu yöntemler ile yapılan tahminler sonucunda, günlük veri ile günlük olarak yılın tahmin edildikten sonra aylık tüketime dönüştürülmesinin aylık veri ile tahmine göre, hata oranında %12,9 MAPE'den %11,9 MAPE'ye düşüş sağladığı ortaya çıkartılmıştır. Günlük talep tahmininde ise iki farklı şekilde gün öncesi tahminler gerçekleştirilmiştir. İlk durumda, bir yılın bir anda tahmini için oluşturulan ZSA, WÜD, ARIMA ve SARIMA modellerin sonuçları %27 MAPE ve 0,8 R<sup>2</sup> civarında sonuçlar bulmuştur. İkinci durumda ise kayan pencere tekniği (KPT) kullanılarak WÜD ve yapay sinir ağları (YSA) ile gün öncesi talep tahmini gerçekleştirilmiştir. Burada ilk üç yıllık veri ile her gün için farklı  $\alpha, \beta, \gamma$  parametreleri bulunarak WÜD ile tahmin yapılırken, YSA' da yine üç yıllık veri kullanılarak geri yayılım (GY) ve yapay arı kolonisi (YAK) algoritmalarının eğitimde kullanılması ile tahminler yapılmıştır. KPT ile WÜD ve YSA-YAK sırasıyla en düşük %15 ve %14,9 MAPE elde ederken, en yüksek 0.94 ve 0.89 R<sup>2</sup> değeri elde ederek gün öncesi talep tahminini gerçekleştirmişlerdir.

Sonuç olarak, önerilen tahmin modellerinin, literatürde sıklıkla kullanılan doğal gaz tüketim talep tahmini için kabul edilebilir uygun sonuçlar üretebildiği görülmüştür. Önerilen modeller ile geçmiş verisinden başka bağımsız değişken ihtiyacı olmayan tahminlerin gerçek yaşamda da ödenen talep tahmin cezalarını azaltabileceği görülmüştür.

# DEMAND FORECASTING OF ENERGY CONSUMPTION WITH STATISTICAL AND ARTIFICIAL INTELLIGENT TECHNIQUES: SAKARYA NATURAL GAS CONSUMPTION APPLICATION

## SUMMARY

Keywords: Energy demand forecasting, time series decomposition, Winters exponential smoothing, SARIMA, sliding window method

Country governments are working on reducing economic and social losses by making energy demand forecasts with low error rates, reliable and accurate. In this thesis, the year-ahead monthly and the day ahead demand forecasting of natural gas which is one of the major sub-sectors of the energy sector, are completed using different methods to achieve the least errors. Suggested methods are univariate and do not need any data other than the consumption data. The originality of the thesis is that we attempt to detect the best model and approach that reduce penalties caused by inaccurate forecasting, and show that they are applicable in everyday life.

In this study, two different cases are considered for natural gas demand forecasting. In the first case, the year ahead monthly whereas in the second case the day ahead demand forecasting is done. Firstly, based on the four-year natural gas consumption data, year ahead monthly demand forecasts are done on monthly and daily data volumes by applying the time series decomposition (TSD), Winters exponential smoothing (WES), autoregressive integrated moving average (ARIMA) and seasonal ARIMA (SARIMA) methods. It is observed that conversion of the daily forecasting into monthly consumptions decreases %12.9 MAPE to %11.9 MAPE in year ahead monthly forecasting by comparing monthly consumption based forecasting. In the daily demand forecasting, two different day ahead forecasts are done. In the first forecasting, TSD, WES, ARIMA and SARIMA model results are found %27 MAPE and 0,8 R<sup>2</sup> for forecasting the year in one step. In the second forecasting, WES and artificial neural networks (ANN) are applied with the sliding window technique (SWT) for the day ahead forecasting. Here, the WES method is applied by computing  $\alpha, \beta, \gamma$  parameters for each day of the first three years data. In the ANN method, backpropagation (BP) and artificial bee colony (ABC) algorithms are used to train the networks by using the same first three years daily data. Best results for SWT used WES and ANN-ABC models in the day ahead consumption forecasts are found %15, %14,9 MAPE and 0,94, 0,89 R<sup>2</sup> value, respectively.

To conclude, it is shown that the proposed forecasting methods are able to generate acceptable appropriate results on the natural gas consumption demand forecasting used frequently in the literature. With the proposed models, it is shown that forecasts, do not require any variables than historical data, is able to reduce the demand forecasting penalties paid in the real life.

## BÖLÜM 1. GİRİŞ

Enerji sektörü, günümüzünde diğer sektörlerin ihtiyaçlarını karşılamakta önemli role sahiptir [1]. Enerji sektörü; elektrik, petrol, doğal gaz, kömür, hidrolik, rüzgâr, güneş, jeotermal, biyoyakıt ve nükleer olarak alt sektörlerle ayrılmaktadır. Enerji sektöründeki elektrik, doğal gaz ve petrol alt sektörlerinde piyasa yapısı bulunmaktadır [2]–[4]. Piyasa yapısı gereği bu alt sektörlerde kamu ve özel şirketler alım-satım işlemleri yapmaktadır. Bu alt sektörlerden olan elektrik sektöründe saatlik olarak yük tahmini yapılmaktadır [5]. Talep edilen ve piyasaya arz edilen elektrik miktarına göre piyasa fiyatı belirlenmektedir. 2015 yılında Türkiye'nin elektrik üretiminin %37.9'u doğal gaz, %29.1'i kömür, %25.6%'sı hidrolik, %4.5'si rüzgâr, %1.3'ü jeotermal kaynaklardan elde edilmiştir [3]. Doğal gazda ise 2015 yılında %99.22'si ithalat lisansına sahip şirketler tarafından ithal edilmiştir. İthal edilen doğal gazın 2015 yılında %55.13'ü Rusya Federasyonu'ndan, %16.16'sı İran'dan, %12.74'si Azerbaycan'dan boru gazı ile alınmıştır. Türkiye'ye 2015 yılında giren doğal gazın %15.79'u LNG (Liquid Natural Gas – Sıvılaştırılmış Doğal Gaz) olarak ve önemli ölçüde Cezayir, Nijerya, Katar'dan sağlanmıştır. İthal edilen doğal gaz termik santrallerde elektrik üretiminde; sanayide proses, kojenerasyon ve ısınma amaçlı; evsel tüketimde ise ısınma ve pişirme amaçlı kullanılmaktadır [3]. Dışa bağımlı olunan doğal gazın kullanımının artması çeşitli sorunları da beraberinde getirmektedir. 2012 yılının Şubat ayında tedarikçi ile transit ülkeler arasındaki sorunlar ve teknik problemlerden dolayı kış aylarında bazı dönemlerde gaz arzında sıkıntı olmuştur [6]. Gaz arzında yaşanan sıkıntılar nedeniyle teslim basıncı da düşmektedir. Teslim basıncının düşmesi termik santrallerin çalışmamasını (elektrik kesintileri) ve kullanıcıların cihazlarının tolerans dışı basınç sebebiyle arızalanmasını meydana getirmektedir.



Doğal gaz tüketiminin Türkiye'deki enerji sektöründeki büyük bir paya sahip olmasının yanında ithalat/ihracat şirketleri ve toptan satış şirketleri için de talebin düşük hata ile tahmini önemli rol oynamaktadır. 90'lı yılların başlarında kullanımı artan ve hızlı şekilde kabul gören doğal gaz [7]–[10] için ülkeler arasında anlaşmalar yapılmaktadır [3], [6]–[7]. Yapılan anlaşmalara göre uzun soluklu olarak doğal gaz tüketimi belirlenmeye çalışılarak, “al ya da öde” anlaşmalar imzalanmaktadır. “Al ya da öde” anlaşmaların özelliği olarak düşük tüketimde dahi, tahmin edilen tüketim kadar ücret ödenmektedir. Anlaşmanın diğer durumunda ise belirlenenden daha fazla tüketim gerçekleştiğinde vanaların kısılması ve gaz arzının azaltılması gibi durumlar söz konusu olabilmektedir. Benzer durumların yaşanmaması, ekonomik ve sosyal kayıpların azaltılması için talep tahmininin düşük hata ile yapılması gerekmektedir [5], [12]–[14]. Ülke yönetimleri enerji talep tahminlerini güvenilir ve doğru şekilde yapmalarını sağlamak amacıyla iller ve ilçelerin bölgesel tüketimleri hakkında bilgi ve öngörülere sahip olmalıdır [2]–[4]. Bölgesel tüketimler birleşerek ülkenin tüketim kapasitesi belirlenmektedir. Bölgesel tüketiciler doğal gazı farklı amaçlar ile kullanabilmektedirler. Büyük fabrikalar doğal gazı elektrik üretimi ve imalat için kullanmaktadırlar. Bu fabrikaların tüketimleri kış ve yaz aylarında aynıdır ve tekrar eden davranış gösterirler. Benzer şekilde elektrik üretim santralleri de günlük olarak elektrik üretiminden kaynaklanan yüksek tüketimlerini arıza durum olmadığı sürece aynı seviyede kalmaktadır. Yüksek tüketimli fabrikalar, kurumlar ve santraller dışında kalan tüketiciler düşük tüketimli kuruluşlar ve evsel tüketicidirler. Düşük tüketimli kuruluşlar ve evsel tüketiciler mevsimlerden etkilenmektedirler. Yazın tüketim miktarları düşük seviyelerde gerçekleşirken, kışın tüketimlerinde daha etkin olarak kendilerini gösterirler. Her bölgenin farklı tüketimleri olsa da, davranışları benzer olan düşük tüketimli kuruluşlar ve evsel tüketiciler, ulusal düzeyde önemli miktarda doğal gaz tüketimine sahiptirler. Bu tüketicilerin tükettikleri doğal gaz birim maliyetleri de ekstra yatırım maliyeti gerektirdiği için yüksek tüketimli sektörlerle göre birim metreküp ücretleri daha fazla olmaktadır. Birim ücretinin fazla olması ve mevsimlerden etkilenmesi (davranışının değişken olması) bu tüketici grubunun önemini ortaya koymaktadır [15]–[17].

Bu çalışmada, yıl öncesi kapasitelerin belirlenmesi için ve toptan satış şirketleri arasında yapılan sözleşmelerde belirtilen yıl öncesi aylık doğal gaz talep tahmini ve günlük program yapılarak doğal gaz tüketimlerinin sistem üzerinde dengelemesini sağlayan gün öncesi doğal gaz talep tahmini için uygun yöntemin belirlenebilmesi amaçlanmıştır. İlk olarak günlük doğal gaz tüketim verisi hazırlanmıştır. Daha sonra günlük doğal gaz verisi aylık tüketim verisine dönüştürülmüştür. Her iki hazırlanan doğal gaz tüketim serisinde temel istatistikler ve serinin davranışı incelenmiştir. Bu kapsamda serinin davranışı üzerinden kullanılacak tek değişkenli istatistiki ve yapay zeka yöntemleri belirlenmiştir. Çalışmada kullanılan modellerin en önemli özelliği tek değişkenli olmalarıdır. Bu durumda doğal gaz talebi, yalnızca geçmiş verisini kullanarak tahmin edilmeye çalışılmaktadır. Elde edilen sonuçlar incelenerek yıl öncesi aylık tahmin ve gün öncesi talep tahmini için en iyi sonuç veren modeller gösterilmiştir.

Ayrıca, literatürde yer alan çalışmaların [18]–[22] büyük çoğunluğunun gerçek yaşamdaki talep tahmini için uygulanması güçken, tez çalışmasında hazırlanan modellerin kullanılması basit, anlaşılır ve kullanılabilir performans sergilemektedir. Yine literatürde yer alan çalışmalarda aylık tahmin yapılırken bağımsız değişkenler kullanılmıştır [22]–[26]. Fakat aylık olarak önümüzdeki bir senede gerçekleşecek olan ve doğal gaz tüketimini etkileyebilecek değişkenlerin kullanımı ve gerçek yaşamda uygulanabilmesi güçtür [17]. Bunun sebebi bir yıl önceden tahmini yapılan bağımsız değişkenlerin de kendi içinde bir hataya sahip olması ve bu hatayı doğal gaz talep tahminine etki edecek şekilde göstermeleridir. Bu sebeple tez çalışması kapsamında tek değişkenli, kendi geçmiş verisini kullanan talep tahmin yöntemleri üzerinde durulmuştur.

Tez çalışmasının sonraki bölümlerinde, yıl öncesi aylık talep tahmini ve gün öncesi talep tahmini için hazırlanan modeller ayrıntılı şekilde anlatılmıştır. Tez çalışması 5 bölümde incelenmiştir. İkinci bölümde doğal gaz piyasası hakkında bilgiler verilmiş olup, doğal gaz talep tahmini ile ilgili yapılan alan yazı çalışmaları gösterilmiştir. Aynı bölümde şehir içi doğal gaz tüketim verisinin hazırlanışı detaylı olarak anlatılmıştır.

Üçüncü bölümde yıl öncesi aylık talep tahmini ve gün öncesi talep tahmini için kullanılan yöntemler gösterilmiştir. Bunlar; zaman serilerinin ayrıştırması, Holt üstel düzleştirme yöntemi, Winters üstel düzleştirme yöntemi, tümleşik kendiyle bağlaşımlı hareketli ortalama (ARIMA) ve sezonsal tümleşik kendiyle bağlaşımlı hareketli ortalama (SARIMA) istatistiki yöntemleridir. Yine aynı bölümde gün öncesi talep tahmini için önerilen yapay sinir ağları (YSA), yapay arı kolonisi (YAK) ve YSA-YAK entegrasyonu gösterilmiştir.

Dördüncü bölümde yapılan çalışmalar iki başlıkta yer almıştır. Bu başlıklardan ilki yıl öncesi aylık doğal gaz talep tahmini, ikinci başlık ise gün öncesi doğal gaz talep tahminidir. Yıl öncesi aylık doğal gaz talep tahmininde ise günlük veri ve aylık veri kullanılarak sonuçlar irdelenmiştir. YSA yöntemleri ise gün öncesi talep tahmininde uygulanmıştır.

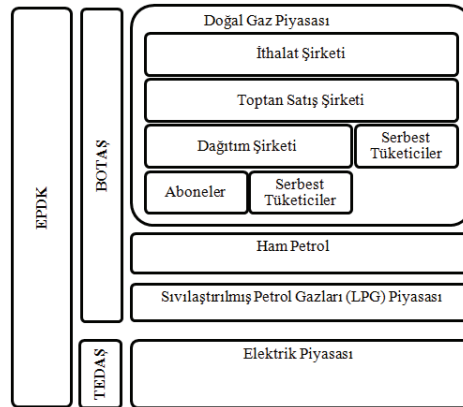
Beşinci bölümde uygulanan yöntemin sonuçları sunulmuş ve alan yazın ile karşılaştırılmıştır. Bu mukayese neticesinde çalışmanın zayıf ve güçlü yönleri vurgulanarak ileriye dönük yapılacak çalışmalar için öneriler sunulmuştur.

## BÖLÜM 2. DOĞAL GAZ TALEP TAHMİNİ

Bu bölümde Türkiye'deki doğal gaz sektörü ve piyasa yapısı hakkında bilgi verilecektir. Talep tahminin kullanımı ve günlük gaz çekiş miktarlarının bildirimini hakkında bilgi verildikten sonra doğal gaz tüketimi üzerine yapılmış olan çalışmalar gösterilecektir. Bu çalışmada kullanılan doğal gaz tüketim verisinin hazırlanması da bu bölümde detaylı şekilde açıklanmıştır.

### 2.1. Doğal Gaz Piyasası

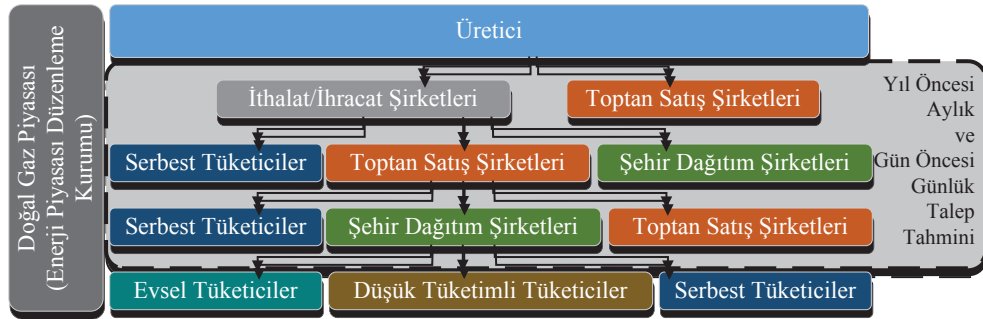
Doğal gaz piyasası için yasal düzenlemeler “İletim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar” ve 4646 sayılı Doğal Gaz Piyasası Kanunu ile tanımlanmıştır. Sistemin işletilmesi BOTAŞ tarafından gerçekleştirilmektedir ve “Taşıyıcı” olarak adlandırılmaktadır. Taşıyıcı doğal gaz piyasasını uzun, orta ve kısa vadede dengelemek ve tahsis işlemlerini doğru biçimde yapmak için çalışmaktadır [14]. İthalat Şirketi ve Toptan Satış Şirketi, sistemde “Taşıtan” olarak adlandırılmaktadır. İthalat Şirketi yurt dışından LNG veya boru gazı olarak yurtiçine doğal gaz temin eder. Bu gazı Dağıtım Şirketleri, Toptan Satış Şirketleri, Serbest Tüketiciler ve ihracat şirketlerine satmaktadır (Şekil 2.1.).



Şekil 2.1. Enerji Piyasası ve Doğal Gaz Sektörü [1].

Toptan Satış Şirketi ise şebeke üzerinde iletim veya dağıtım yapmamaktadır. Elinde bulunan gazı Serbest Tüketici veya Dağıtım Şirketlerine satmaktadır [1]. Dağıtım Şirketleri belirli bölge veya şehir için Enerji Piyasası Düzenleme Kurumundan (EPDK) lisans almış, bölgedeki abonelere doğal gaz dağıtmak ve şehir ana giriş istasyonlarından sonraki boru gazı hattını döşemekle yükümlülüğü olan şirketlerdir. Serbest Tüketici kavramı her sene EPDK tarafından değişmekle birlikte genel olarak yüksek tüketimli aboneler için kullanılmaktadır. Serbest Tüketiciler gaz arzını Dağıtım Şirketine bağlı olmaksızın İthalat Şirketi veya Toptan Satış Şirketinden temin edebilmektedir.

Doğal gaz tüketimi, Serbest Tüketici sınırının altında olan kullanıcılar, gazı sadece Dağıtım Şirketinden tedarik edebilirler. Doğal gaz fiziksel olarak çıkış istasyonları olan RMS-A adında basınç düşürme ve ölçme istasyonlarında teslim edilirler. RMS-A istasyonlarının kapasiteleri farklılık gösterebilmektedir. Her istasyonda doğal gaz tüketimi yapan dağıtım şirketi müşterileri olabileceği gibi toptan satış şirketi serbest tüketicileri de bulunabilmektedir (Şekil 2.2.).



Kısa dönem doğal gaz planlaması ve dengelemesi dört aşamadan oluşmaktadır. Bunlar yıl öncesi kapasite rezervasyonu, ay öncesi atıl kapasite rezervasyonu, kapasite aktarımı, gün öncesi doğal gaz talep tahmini ve gün sonrası doğal gaz dengeleme (gün sonu doğal gaz ticareti - GST) işlemleridir. Bu işlemler BOTAŞ Elektronik Bülten Tablosu (EBT) sistemi üzerinden yapılmaktadır [1], [14].

### 2.1.1. Yıl öncesi kapasite rezervasyonu

Taşıtan şirketler yıl öncesinde giriş çıkış noktalarında standart metreküp ( $Sm^3$ ) türünde kapasite rezervasyonunda bulunurlar. Kapasite rezervasyonu yapılırken her giriş için çıkış noktaları BOTAŞ'a bildirilir. Doğal gaz teslim istasyonları olan RMS-A fiziksel kapasiteleri rezervasyonlar için önemlidir. Bu fiziksel kapasiteler "Maksimum Ayrılabilir Kapasite" (MAK) olarak adlandırılır. İstasyona ayrılacak kapasite MAK ile sınırlıdır. Eğer taşıtan depolama faaliyeti de yapıyorsa istasyon için MAK sınırını geçebilecek şekilde kapasite rezervasyonu yapılabilir. Bir istasyonda farklı taşıtanların bulunabileceği göz önüne alındığında kapasitenin önemi ortaya çıkmaktadır. Yakın zamanda taşıtan şirketlerin yıl öncesi kapasite rezervasyonları artacaktır. Bu artış kapasite rezervasyonları için "kapasite marketi" oluşturabilecek ve ikinci el kapasite piyasası oluşturabilecektir [11]. Kapasite rezervasyonlarının maliyeti bulunmaktadır. Yıl öncesinde günlük azami çekiş miktarları 30 Eylül tarihine kadar BOTAŞ'a bildirilir.

### 2.1.2. Ay öncesi atıl kapasite rezervasyonu

Yıl öncesinde kapasite rezervasyonu yapıldıktan sonra RMS-A istasyonları için kullanılacak kapasiteler "Atıl Kapasite" olarak adlandırılmaktadır. Atıl kapasite rezervasyonu MAK ile sınırlıdır. En az bir aylık kullanılabilir. Genel olarak taşıtan şirketleri yıl genelinde ortalama değer kapasite rezervasyonu yaparak maliyetlerini düşürmeye çalışmaktadır. Atıl kapasite maliyeti 3 dönem olarak rezerve edilebilmektedir. 1 Kasım – 1 Nisan arası Kış dönemi, 1 Mayıs – 1 Eylül arası Yaz dönemi, Nisan ve Ekim ayları ise Ara dönem olarak adlandırılmaktadır [14]. Kış döneminde RMS-A istasyonlarında kullanılmayan atıl kapasiteler bir önceki ayın 25'ine kadar rezerve edilebilmektedir. Kışın atıl kapasite rezervasyon maliyeti yıl öncesi rezervasyonun 1.3 katı, ara dönem için 1.2 katı ve yazın 0.8 katıdır. Kapasite aşımı ile ilgili olarak EPDK'nın 2008 yılında aldığı kurul kararında "Taşıtan 1 Ocak – 31 Mart arasını kapsayan dönemde, her hangi bir Giriş veya Çıkış noktasında bir ay içerisinde rezerve kapasiteyi sekiz veya daha fazla aşması halinde, ilgili ayda girdiği veya çektiği, günlük azami doğal gaz miktarı ile o noktadaki rezerve kapasite miktarı

arasındaki fark kadar kapasiteyi, o noktadaki atıl kapasite ile sınırlı olmak üzere, standart taşıma sözleşmesi başından itibaren standart taşıma sözleşmesi sonuna kadar almak ve atıl kapasite katsayı bedeli ile ödeme yapmakla yükümlü olacaktır.” maddesi eklenmiştir [13]. Bu madde gereği doğru yapılmayan kapasite rezervi tüm yıl için yüksek maliyeti beraberinde getirecektir.

### **2.1.3. Kapasite aktarımı**

Yıl öncesi yapılan kapasite rezervasyonu ile tanımlanan istasyon kapasiteleri gelecek dönemler için aktarılabilir. Bir istasyondaki tüketimin rezerve edilen kapasiteden daha düşük olacağı öngörüldüğünde, yüksek kapasite rezervi bulunan istasyondan aktarım yapılabilir. Bunun için Taşıyıcının uygun görmesi ve MAK'ın yeterli olması gerekmektedir. Kapasite aktarımı aylık olarak yapılır. Kapasite devrinde ücret alınmamaktadır [12]. Taşıtanlar da kendi aralarında kapasite aktarımı yapabilirler. Böylece kapasite aktarımı şirketlerin kendi aralarında ticaret ortamının gelişmesine katkı sağlamaktadır. Kapasite olmadan doğal gaz talep tahmini söz konusu olmamaktadır ve talep tahmini MAK ile sınırlıdır.

### **2.1.4. Gün öncesi doğal gaz talep tahmini**

Doğal gaz sektöründe talep tahmini “Program” olarak adlandırılmaktadır ve EBT üzerinde Taşıma Miktar Bildirimi (TMB) ve “Taşıma Miktar Düzeltme Bildirimi” (TMDB) olarak yapılmaktadır. TMB ve TMDB üzerinde giriş ve çıkış programları günlük olarak yapılmaktadır. İşlemin yapıldığı günden sonraki günün (G-1) tüketim taleplerinin tahmini saat 11:00 veya öncesinde bitirilmelidir. TMB işlemi yapıldıktan sonra programın onaylanmaması veya düzeltilmesi gerektiğinde TMDB işlemi yapılmaktadır. Günlük toleranslar giriş – çıkış değerlerine göre değişmekte olup  $\pm\%12$  ile  $\pm\%4$  arasında değişmektedir. Günlük tolerans miktarı aşıldığında günlük dengesizlik ücreti ceza olarak kesilmektedir. Gün öncesi doğal gaz talep tahmini en önemli aşamadır. Burada hata düzeyinin düşük olması ile kapasite aşım cezaları, gün sonrası dengeleme fiyatından gaz alınması ve tolerans cezalarının önüne geçilmektedir.

### 2.1.5. Gün sonrası doğal gaz dengelemesi

Gerçekleşen gün için talep tahmini ile gerçekleşen gaz çekişi arasında farklılıklar bulunacaktır. Bu farklılıkların toleranslar dâhilinde olmaması sistemi dengesizleştirecektir. Bunu önlemek ve sistemdeki taşıtanların kendi aralarında dengesizlikleri gidermeleri için Ulusal Dengeleme Giriş ve Çıkış noktaları tanımlanmıştır. Her ayın ilk 20 günü için, ilgili ayın 26'sına kadar tedarikçi şirketlerin kendi aralarında ticaret yapmalarına izin verilmektedir ve bu işlemler EBT üzerinden takip edilmektedir. Gün sonrası doğal gaz dengeleme işleri G+1, G+2 şeklinde ifade edilir ve kaç gün öncesinin dengeleme işlemi yapıldığı belirtilmiş olur. Bu yapılan ticaretler Gün Sonrası Ticareti (GST) olarak adlandırılmaktadır. Gün sonrası ticaretini toptan satış şirketleri ve ithalatçı şirketler kendi aralarında BOTAS'ın denetimi altında yaparlar.

## 2.2. Literatür Çalışması

Zaman serisi tahmini, tahminlemenin önemli alt alanlarından biri olup, aynı değişkenin zaman içindeki gözlemlerinin toplanarak geçmişle olan ilişki modelinin oluşturması ve analizini içermektedir [27]. Doğal gaz tüketim tahmini çeşitli yaklaşımlar ile farklı alanlarda yapılmaktadır. Bu çalışmalar zaman aralığına göre günlük, aylık; tüketim alanına göre bölgesel, yerel; tüketim grubuna göre evsel, endüstriyel; bağımsız değişken durumuna göre tek değişkenli (bağımsız değişken içermeyen), çok değişkenli olarak (bağımsız değişken içerebilen) olarak gruplandırılabilir [21]-[22].

İlk grup yayınlar kullanılan zaman ölçeğine göre günlük [8]-[11], [20]-[29] ve aylık [12]-[16] periyodlar olarak ayrılabilir. İkinci grup yayınlar bölgesel [9], [12], [14]-[16], [21]-[24], [26], [28]-[29] ve ulusal [8], [10], [12]-[13], [25], [30]-[36] olarak tüketim olarak ayrılabilir. Üçüncü grupta, tüketim grubuna göre ayırım yapılabilir. Bu grupta evsel tüketiciler [8]-[9],[20]-[24], şirketler (fabrika, endüstri) [31], [33], [38] ve tüm tüketim sektörleri (evsel ve şirketler) [10]-[12], [26]-[28], [30]-[36] yer alabilmektedir. Dördüncü gruplandırma kullanılan veriye göre



olmaktadır ve bu tez çalışması kapsamında da kullanılan tek değişkenli yaklaşımlar [8]–[10], [40] ve bağımsız değişken içeren çalışmalar [8]-[13], [15]-[16], [20]-[28], [30]-[32] olmaktadır. Bu çalışmalarda bölgesel bazlı bağımsız değişken içeren doğal gaz tahmininin sıklıkla yapıldığı görülmektedir. Bu araştırmaların özeti Soldo tarafından yayınlanmıştır [41].

Tek değişkenli tahmin teknikleri zaman serileri tahminlerde sıklıkla kullanılmaktadır. Ediger ve arkadaşları tümleşik kendiyle bağdaşimli hareketli ortalama metodu (ARIMA), sezonsal ARIMA (SARIMA) ve karşılaştırmalı regresyon teknikleri kullanarak Türkiye'nin fosil kaynak üretimini doğal gazı da içerecek şekilde tahmin etmeye çalışmışlardır [42]. 2004-2038 arası yıllık tahminler yapmışlardır ve doğrusal, logaritmik, ters, karesel, kübik, bileşik, üstel, büyüme ve lojistik regresyon yöntemlerini kullanmışlardır. ARIMA tekniğinin doğal gaz tüketim tahmininde uygun olduğunu belirtmişlerdir. Gutiérrez ve arkadaşları stokastik büyüme modelinde Gompertz tipi yenilik yayılım sürecini kullanarak İspanya'nın 1973'den 1997'ye yıllık doğal gaz tüketimini tahmin etmişlerdir [9]. 1997-2000 yılları arası sonuçları karşılaştırmışlardır ve lojistik yenilik modeli ile Gompertz modelinin uygun olduğunu göstermişlerdir. Ma ve Wu, Çin'in yıllık doğal gaz tüketim ve üretimini Grey modeli ile tahmin etmişlerdir. 1990-2003 yılları arasındaki veriyi kullanarak 2004'den 2007'e kadar tahminler üretmişlerdir [10]. Tek değişkenli ve birinci dereceden diferansiyel denklemlili Grey model (GM(1,1)) ile Grey-Markov modelini karşılaştırmışlar ve Grey-Markov modelinin daha iyi sonuçlar verdiğini göstermişlerdir. Xie ve Li de Çin'in doğal gaz tahmini için Grey model kullanmışlardır. Ma ve Wu'dan farklı olarak GM(1,1) modelinde optimizasyon için genetik algoritmaları kullanmışlardır [40]. 1996-2002 arasındaki veriyi kullanarak 2003'den 2005'e kadar olan yılları tahmin etmişler ve genetik optimizasyonun daha iyi sonuç verdiğini göstermişlerdir. Literatürde aylık doğal gaz tahmini Liu ve Lin tarafından çalışılmıştır [43]. Ulusal seviyede yapılan tahminde aylık ve çeyreklik periyodlar kullanılmıştır. Sıcaklık ve fiyatı ARIMA modellerine ekleyerek ARIMAX (ARIMA with eXogenous – Dışsal değişken içerebilen ARIMA) modeli oluşturmuşlardır.

Tek deęişkenli tahminler elektrik, su, güneş ve rüzgar gibi dięer enerji sektörlerinde de yapılmaktadır. Yalçıntaş ve arkadaşları İstanbul şehri için talep ve arz taraflı tahmin ile su yönetimini sağlamışlardır [44]. 2015'den 2018'e kadar yıllık talebi 2006-2014 arasındaki veriyi kullanarak gerçekleştirmişlerdir ve verimli su teknolojileri kullanarak evsel su tüketimlerinin azaltılması sağlanarak sürdürülebilir yönetimin olabileceğini önermişlerdir. Gelažanskas ve Gamage zaman serilerinin sezonsal ayrıştırması, üstel düzleştirme ve SARIMA yöntemlerini kullanarak sıcak su talebini tahmin etmiştir [45]. Tahminlerde en doğru sonucu zaman serilerinin sezonsal ayrıştırmasının verdiğini göstermişlerdir. Prema ve Rao rüzgar hızını zaman serilerinin ayrıştırması, üstel düzleştirme ve geri yayımlı (GY) yapay sinir aęları ile tahmin etmişlerdir [46]. Zaman serilerinin ayrıştırması ve ARIMA yönteminin daha iyi tahminler ürettiğini göstermişlerdir. ARIMA yöntemi günlük ve saatlik elektrik tüketiminde sıkça kullanılmaktadır. Zaman serileri kullanılarak elektrik yük tüketim tahmini üzerine derleme çalışması [47]'de gösterilmiştir. Bu çalışmada ARIMA yönteminin en çok kullanılan doğrusal tahmin teknięi olduğunu göstermişlerdir. Elektrik fiyat tahmininde de yine tek deęişkenli tahmin yöntemlerinden Winters üstel düzleştirme ve SARIMA yöntemi Wang ve arkadaşları tarafından kullanılmıştır [48].

Günlük doğal gaz talep tahmini üzerine de birçok çalışma yapılmıştır [9], [21], [24]-[25], [27], [29], [45]-[52]. Khotanzad ve arkadaşları şehir dağıtım sisteminin doğal gaz talebini yapay sinir aęlarının türleri olan tahminleyici üzerine çalışmışlardır [49]. Görücü bölgesel seviyede doğal gaz tahmini için yapay sinir aęlarını kullanmıştır [50]. Potočnik ve arkadaşları saatlik tüketim verisi ile bölgesel seviyede tahmin riskini belirlemek için strateji önermişlerdir [51]. Akpınar ve Yumuşak günlük tüketim verisini sezonsal olarak aylık bölmüş ve tüketimi tahmin etmişlerdir [16]. Sánchez-Úbeda ve Berzosa İspanya için, orta vadeli seviyede endüstriyel son kullanıcı yüksek çözünürlükteki tüketim verileri ile (günlük) ayrıştırma temelli yeni tahmin modeli geliştirmişlerdir [33]. Yokoyama ve arkadaşları parametrelerin belirlenmesinde model kırpma yöntemi adında evrensel optimizasyon yöntemi önermişlerdir [52]. Tahmin edilmiş hava sıcaklığı ve baęıl nemi baęımsız deęişken olarak kullanarak enerji talebini tahmin etmişlerdir. Akpınar ve Yumuşak kayan pencere teknięi ile doğrusal regresyon kullanmışlardır [32]. Farklı pencere

boyutlarında veriler kullanarak en iyi doğal gaz talep tahmin sonucunu veren veri boyutunu bulmaya çalışmışlardır. Günlük doğal gaz tüketimi SARIMAX, çok katmanlı perseptron ile radyal temelli fonksiyonlara sahip yapay sinir ağları ve çok değişkenli sıralı en küçük kareler yöntemleri ile [29]'de tahmin edilmiştir. SARIMAX yönteminin diğer yöntemlere göre daha iyi sonuç verdiğini görmüşlerdir. Soldo ve arkadaşları ise doğrusal modeller, yapay sinir ağları ve destek vektör makinası (SVM) kullanarak günlük doğal gaz tüketimini güneş radyasyonunu kullanarak tahmin etmişlerdir [19]. Tahmin sonuçlarında, kullanılan güneş radyasyonu verisinin modellerine olumlu yönde etki ettiğini görmüşlerdir.

Enerji sektöründe yapay sinir ağları (YSA) ve hibrit yöntemler de sıkça kullanılmaktadır [9], [21], [26]-[27], [29], [45]-[46], [50]-[79]. Azadah ve arkadaşları geçmiş tüketim verisi ile uyarlamalı ağ temelli bulanık arayüz sistemini (ANFIS) kullanarak doğal gaz talep tahmini yapmışlardır [53]. Karimi ve Dastranj genetik algoritma (GA) tabanlı YSA modelini doğal gaz tahmininde kullanmışlardır ve ağ topolojisindeki parametreleri GA ile optimize etmişlerdir [54]. Başka bir çalışmada Shanghai şehri için doğal gaz yük tahmininde GA ile optimize edilmiş YSA'yı kullanılmıştır ve GY ağındaki eğitimde daha yüksek yakınsama gerçekleştirilmiştir [35]. Yalçınöz ve Eminoğlu Niğde ili için elektrik yük tahminini YSA kullanarak yapmışlardır ve orta vadeli aylık tahmin için geçmiş veri, günlük yüklerin tahmini için meteorolojik veri kullanmışlardır [57]. Amjady bulanık YSA kullanarak elektrik marketleri için gün öncesi saatlik fiyat tahminini çalışmıştır ve kullandıkları yöntemin İspanya elektrik pazarı için ARIMA, dalgacık-ARIMA, çok katmanlı perseptron ile radyal temelli fonksiyon YSA'ya göre daha doğru sonuç verdiğini belirtmiştir [60]. Ying ve Pan ANFIS hibrid yöntemini kullanarak elektrik yükünü tahmin etmiştir ve regresyon modeli, YSA, GA ile tekrarlayan GA temelli SVM sonuçları ile karşılaştırmışlardır [69]. ANFIS'in diğer yöntemlere göre daha iyi sonuç verdiğini göstermişlerdir. Saini, dik iniş yöntemi ile ileri beslemeli YSA modeli, Bayes dengelemesi, esnek ve uyarlanabilir GY öğrenme yöntemlerini kullanarak yedi gün öncesi uç yük tahminini, geçmiş uç yük değerleri ve meteorolojik veri kullanarak yapmıştır [70]. En iyi sonucu uyarlanabilir GY'lı YSA modelinin verdiğini göstermiştir. Lauret ve arkadaşları Bayesyen teknik kullanarak en uygun

YSA modelini kısa dönemli yük tahmini için tasarlamışlardır ve tekniğin etkili olduğunu göstermişlerdir [71]. Çınar ve arkadaşları GA temelli YSA modeli geliştirmişlerdir ve Türkiye'deki hidroelektrik santralindeki üretimi tahmin etmişlerdir [76]. Azadeh ve arkadaşları ANFIS-bulanık veri zarflama analizi (FDEA) geliştirmişlerdir [78]. Gaz tüketim davranışını sınavan FDEA, hem karmaşıklığı hem de belirsizliği ele alabilmektedir. Szoplik, sezonsal ve günlük değişkenliği analiz etmiştir [34]. Çok katmanlı perseptron modeli tasarlamış ve eğittiği ağı saatlik şehir doğal gaz tüketiminin tahmininde kullanmıştır. Başka bir çalışmada ise Azadeh ve arkadaşları doğal gaz tüketiminde keskin iniş/çıkışların nasıl modelleneceğini göstermişlerdir [80]. Hassas sinirsel-bulanık eğitim arayüzü tasarlayarak en uygun eğitimi gerçekleştirmek ve doğal gaz tüketim tahmininde bulunmak için çalışmışlardır. Yeni ve etkin bir optimizasyon tekniği olan YAK çok geniş alanlarda kullanılabilir [82]. YAK algoritması genellikle başka algoritmalar ile birlikte hibrit şekilde kullanılmaktadır [37], [79], [81], [83]–[87]. Gün öncesi doğal gaz tüketimi için hibrid YSA-YAK ve YSA-GY üzerinden tahmini yapılmıştır [37]. Farklı YSA modelleri ve gizli katmanlar kullanarak %18 bağımlı mutlak yüzdesel hata ve 0,891 belirleme katsayı değeri bulunmuştur. Wu ve arkadaşları uyum belleğini geliştirmek için YAK ve değişkenlerini kullanmıştır [79]. Uzlu ve arkadaşları Türkiye için hidroelektrik üretiminde YSA'yı YAK ile kullanmışlardır [81]. YSA-YAK modelinin klasik YSA modeline göre daha iyi sonuç verdiğini göstermişlerdir. Li ve arkadaşları diferansiyel gelişim algoritması (DEA) ve YAK kullanarak en uygun güç akış problemini çözmeye çalışmışlardır ve DEA'nın YAK'dan farklı olarak büyük popülasyonları çözdüğünden bahsederek hibrid DEA-YAK algoritmasını önermişlerdir [83]. DEA-YAK modelinin yakınsama zamanının DEA'dan düşük olduğunu ve sağlam olduğunu göstermişlerdir. YAK algoritması bilgisayar ağlarında da kullanılmıştır [84]. Kümeleme ve YAK optimizasyonu hibrid olarak, genel kendini yönetebilen ağaç bazlı enerji dengeli (general self-organized tree-based energy-balance; GSTEB) yönlendirme protokolü oluşturularak kullanılmıştır. Kümeleme; veriyi azaltmak için kullanılırken, YAK ise kaynaktan hedefe ağaç bazlı yönlendirmede en kısa yolu bulmak kullanılmıştır. Gao ve arkadaşları bulanık esnek atölye tipi çizelgeleme ve yeniden çizelgeleme problemlerinde yeni bir görev eklenmesinde YAK algoritması kullanmışlardır [85].

Hashim ve arkadaşları kablosuz ağ sensörlerinin gecikme değerlerine bağlı optimal yerlerini YAK algoritması kullanarak belirlemeye çalışmışlardır [86]. Enerji etkinliğine bağlı olarak uygun dağılım stratejisi geliştirmeye çalışmışlardır. Adak ve Yumuşak dört meyve aromasının sınıflandırılmasında YAK algoritmasını kullanmışlardır. YSA'yı YAK ile eğittikten sonra aroma sınıflandırmasının başarılı olduğunu görmüşlerdir [87].

Suganthi enerji talep tahmini üzerine yapılan çalışmaları derlemiştir [88]. Zaman serileri temelli elektrik enerjisinin veri madenciliği yöntemleri üzerine derleme çalışması Alvarez ve arkadaşları tarafından yapılmıştır [47]. Binaların elektrik tüketimini öğrenme algoritmaları kullanarak belirleyen çalışmaların derlemesi ise [89] nolu referansta göstermiştir. Doğal gaz talep tahmini üzerine çalışmalar ise Soldo tarafından derlenmiştir [41]. YAK algoritması kullanan çalışmalar ise algoritmayı bulan Karaboğan tarafından derlenmiştir [82].

Bu çalışmada zaman serilerinin ayrıştırması, Holt-Winters üstel düzleştirme yöntemi, ARIMA/SARIMA yöntemleri, geri yayımlı algoritmasıyla eğitilmiş YSA modeli ve YAK algoritmasıyla eğitilmiş YSA modeli kullanılmıştır.

## BÖLÜM 3. TALEP TAHMİNİNDE KULLANILAN YÖNTEMLER

Tez çalışmasının bu bölümünde talep tahmini için kullanılan istatistiki ve yapay zeka teknikleri açıklanacaktır. Zaman serilerinin ayrıştırması, Holt üstel düzleştirme, Winters üstel düzleştirme, ARIMA/SARIMA istatistiki yöntemleri ile ileri beslemeli YSA, geri yayımlı YSA ve YSA-YAK yapay zeka yöntemleri tanıtılacaktır.


### 3.1. Zaman Serilerinin Ayrıştırması

Şartlarda büyük değişim olmadığı durumlarda gerçekçi tahmin yapmak için zaman serileri kullanılır. Zaman serileri dört farklı bileşenden meydana gelmektedir [90]–[95] (Şekil 3.1.).

- Eğilim Etkisi (T): Serinin doğrusal, parabolik vb. eğilimini gösterir. Zaman serisinin uzun dönemde belirli bir yöne doğru gösterdiği gelişmedir.
- Konjonktür Etkisi (C): Zaman serilerinde kendini tekrar eden fakat bu tekrarların düzeni belirli olmayan ve trendin etrafında oluşan değişimlerdir.
- Sezonallık Etkisi (S): Seride tekrar eden devir hareketinin tümüne mevsim dalgalanmaları denir. Serideki ölçütlere göre haftalık, aylık, yıllık olabilir.
- Düzensiz Hareketler (I): Trend, konjonktür ve sezonallık ile açıklanamayan sonuçlar düzensiz hareketleri göstermektedir. Bunların ne zaman, nasıl bir şiddette ortaya çıkacağı önceden belirlenemez.

Bu bileşenler zaman serilerinde iki farklı şekilde model oluşturulurken kullanılmaktadır.

- Toplamsal Model:  $Y = T + C + S + I$
- Çarpımsal Model:  $Y = T \times C \times S \times I$



Şekil 3.1. Zaman serisinin ayrıştırması [16], [15]

### 3.1.1. Eğilimin belirlenmesi

Trendin belirlenmesi için farklı yöntemler bulunmaktadır. Bunlar hareketli ortalamalar yöntemi ve en küçük kareler yöntemidir. En küçük kareler yönteminde farklı trend fonksiyonları bulunmaktadır. Bu fonksiyonlardan bazıları doğrusal, ikinci dereceden, üstel şeklinde belirtilebilir.

Hareketli ortalamalar yönteminde geçmiş dönem verilerinin ortalaması alınır [1,5]. Bu ortalama ya içinde bulunulan dönemin (merkezi hareketli ortalama) ya da bir sonraki dönemin (basit hareketli ortalama) tahmini olur. Doğrusal trend eğilimi Denklem (3.1) şeklinde hesaplanır.

$$T = a + bt + e \quad (3.1)$$

En küçük kareler yöntemi kullanılarak  $a$  ve  $b$  tahmin edilir.  $e$  ise gerçekleşme ile tahmin arasında kalan kalıntılardır.  $t$  zaman serisinin zaman adımını,  $Y$  ise bağımlı değişkenin (trend değişkeni) değerini göstermektedir. Hata gerçekleşen değer ile tahmin arasındaki farktır ve Denklem (3.2) gibi ifade edilir.

$$e = Y - T \quad (3.2)$$

Hatanın ( $e$ ) minimum olması istenmektedir. Diğer taraftan hatanın yönden bağımsız olması gerekmektedir [92], [94]. Bu sebeple Denklem (3.3) kullanılarak minimum hata belirlenmeye çalışılır.

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - T_i)^2 = \sum_{i=1}^n (Y_i - a - bt_i)^2 = \text{minimum} \quad (3.3)$$

Bu yönteme “en küçük kareler yöntemi” denmektedir. Bu denklemin minimum olması için  $a$  ve  $b$ 'ye göre türevlerinin sıfır olması gerekmektedir [92], [94].

$$\frac{de}{da} = 2 \sum_{i=1}^n -(Y_i - a - bt_i) = -\sum Y + na + b \sum t = 0 \quad (3.4)$$

$$\frac{de}{db} = 2 \sum_{i=1}^n -t_i(Y_i - a - bt_i) = -\sum Yt + a \sum t + b \sum t^2 = 0 \quad (3.5)$$

$$\sum t = na + b \sum t \quad (3.6)$$

İki bilinmeyenli iki denklem çözülerek  $a$  ve  $b$  bulunur. Böylece başlangıç anındaki kesme değeri olan “ $a$ ” ve denklemin trendini gösteren “ $b$ ” bulunmuş olur.



### 3.1.2. Konjonktür etkisi

Konjonktür etkisi bulunmadan önce verideki trend bulunmalıdır. Bu trend sayesinde konjonktür daha rahat anlaşılır. Konjonktürde; dönemsel olarak artış ve azalışlar olmaktadır. Bu etkinin süresi uzundur ve kendini seride belli eder. Doğal gaz tüketiminde kış ve yaz mevsimleri konjonktürel etkiyi göstermektedir. Konjonktür bulunurken verinin çevrim zamanını belirlemek önemlidir. Çevrim zamanına göre yürüyen ortalamalar yöntemi kullanılarak bulunan ortalama değerler ile, ilgili zamandaki değerlerin oranı, konjonktürel etkiyi verecektir. 12 aylık merkezi hareketli ortalamaları hesabı Denklem (3.7) şeklinde olmaktadır.

$$Y'_{t+6_{H.O.}} = \frac{Y_t/2 + Y_{t+1} + Y_{t+1} + \dots + Y_{t+11} + Y_{t+12}/2}{12} \quad (3.7)$$

Konjonktür etkisini bulmanın yöntemi de hareketli ortalamaların ( $\overline{Y'_{H.O.}}$ ) trende bölünmesidir (Denklem (3.8)).

$$C = \frac{\overline{Y'_{H.O.}}}{T} \quad (3.8)$$

### 3.1.3. Sezonsallık (Mevsimsellik) etkisi

Mevsimsel etki, konjonktür etkisine göre kısa sürede ve daha sık görünür. Mevsimsel etki; konjonktür etkisine göre daha küçük değişimlere sebep olur [90], [92], [93]. Buna doğal gaz tüketimi üzerinden örnek verecek olursak, hafta sonu oluşan tüketim değişimleri sezonsallık ile ifade edilir. Mevsimselliği ayırtırmak için gerçek serinin, hareketli ortalamalar serisine bölümüyle bulunmaktadır (Denklem (3.9)).

$$SI = \frac{TCSI}{TC} \quad (3.9)$$

### 3.1.4. Düzensiz hareketler (Kalıntılar)

Zaman serisinde trend, sezonsallık, konjonktür bileşenleri ile açıklanamayan ve gerçek değer ile bileşenlerin arasında kalan değerler düzensiz bileşenleri oluşturmaktadır. Her zaman serisinde düzensiz bileşen bulunur [90], [92], [93].

### 3.2. Holt Üstel Düzleştirme Yöntemi

Holt Üstel Düzleştirme Yöntemi (HÜSDY) iki katsayı ile eğilimi yumuşatarak tahmin etmeye çalışmaktadır. (Denklem (3.10)) tahmin için oluşturulurken, (Denklem (3.11)) yumuşatılmış değeri, (Denklem (3.12)) eğilimi vermektedir. Yöntem toplamsal hesaplamalıdır. [91], [93], [94], [96].

$$F_{t+m} = S_t + b_t m \quad (3.10)$$

$$S_t = \alpha Y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (3.11)$$

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (3.12)$$

Buradaki simgelerin tanımı aşağıda belirtilmiştir;

$\alpha$  : Ortalama düzeyin düzleştirme katsayısı

$\beta$  : Eğimin düzleştirme katsayısı

$S_t$  : t periyot sonunda yumuşatılmış değer

$b_t$  : t periyotta yumuşatılmış eğilim

$m$  : Tahmin seviyesi

Holt İki-Parametre yönteminde sezonsal etki bulunmamaktadır. Bu etkinin olmaması sadece artma ve azalma eğilimi bulunan serilerde doğru tahmin sonucu üretebilmesini beraberinde getirmektedir.

### 3.3. Holt-Winters Üstel Düzleştirme Yöntemi

Holt üstel düzleştirme yönteminin eksiği olan sezonsallık davranışının bulunmaması Holt-Winters üstel düzleştirme yöntemi ile giderilmiştir. HÜDY'ne ek olarak  $\gamma$ , t periyoddaki sezonsal katsayısı düzleştirme sabiti modele eklenir. Böylece model sezonsallık da içeren davranışa sahip olur.

$$Y_{t+1} = (S_t + b_t)I_{t-L+1} + e_{t+1} \quad (3.13)$$

$$S_t = \alpha \frac{Y_t}{Y_{t-L}} + (1-\alpha)(S_{t-1} + b_{t-1}) \quad (3.14)$$

$$b_t = \beta(S_t + S_{t-1}) + (1-\beta)b_{t-1} \quad (3.15)$$

$$I_t = \gamma \frac{Y_t}{S_t} + (1-\gamma)I_{t-L} \quad (3.16)$$

$$\hat{Y}_{t+m} = (S_t + b_t m)I_{t-L+m} \quad (3.17)$$

Buradaki simgelerin tanımı aşağıda belirtilmiştir;

$\alpha$  : Ortalama düzeyin düzleştirme katsayısı ( $S_t$  nin düzleştirilmesi)

$\beta$  : Eğimin düzleştirme katsayısı

$\gamma$  : t periyoddaki sezonsal katsayısı düzleştirme sabiti

$S_t$  : Sezonsallık için t periyot sonunda düzleştirilmiş değer

$b_t$  : t periyotta düzleştirme trendi

$I_{t-L+1}$  : t+1 periyottaki sezonsal düzleştirme katsayısı

$I_t$  : t periyottaki düzleştirilmiş sezonsal değer

$L$  : Sezonsal çevrim boyu

$m$  : Tahmin seviyesi

göstermektedir. Böylece  $\gamma$  sezonsallık etkisini barındıran tahmin yöntemini oluşturmada kullanılmıştır. Burada bir sezonsal çevrim, başlangıç parametrelerini belirlemede kullanılmaktadır. Yöntemde sezonsal değerin ( $I_t$ ) çarpımsal ve toplamsal kullanımını bulunmaktadır.

### 3.4. ARIMA/SARIMA (Box-Jenkins Yöntemi)

ARIMA (Autoregressive Integrated Moving Average) tek değişkenli tahmin yöntemleri içerisinde sık kullanılan bir yöntemdir. ARIMA çok farklı disiplinler tarafından kullanılmaktadır. Zamana bağlı değişimin olduğu tüm çalışmalarda ARIMA yönteminden söz edilebilmektedir. Box-Jenkins tarafından ortaya konulan ARIMA'da model kurma 4 adımdan oluşmaktadır [90], [93], [94], [97];

- Model tanımlama
- Parametre belirleme
- Model teşhisi
- Tahmin doğrulama ve makullük belirleme

Genel olarak gösterimi;

$$(AR \ I \ MA) \ C, \ T \ (AR \ I \ MA)^s \ (AR \ I \ MA)^S$$

$$p \ d \ q \ \ C \ T \ P \ D \ Q \ \ P \ D \ Q$$

şeklindedir. Buradaki simgelerin tanımı aşağıda belirtilmiştir;

- p: Otoregresyon seviyesi
- d: Fark alma seviyesi
- q: Hareketli ortalamalar seviyesi
- P: Sezonsal otoregresyon seviyesi
- D: Sezonsal fark alma seviyesi
- Q: Sezonsal hareketli ortalamalar seviyesi
- s: Sezonsallığın ilk periyodu

S: Sezonallığın ikinci periyodu

C: Eğer sabit katsayı varsa 1, aksi halde 0

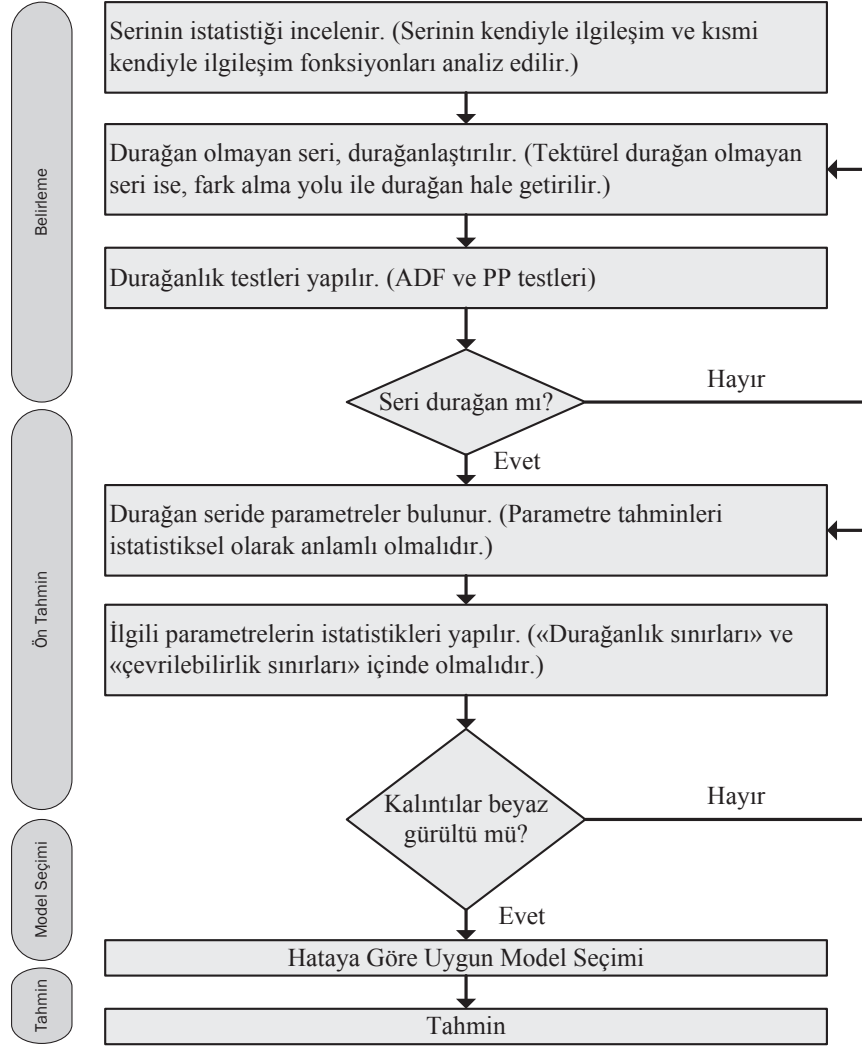
T:  $Y_t$  üs dönüşümü, 0 = dönüşüm yok, 1=log, #=üst

ARIMA yönteminde tahmin için üç kısım bulunmaktadır. Bunlar kendiyle bağdaşım (autoregressive), hareketli ortalama (moving average) ve tümleşik (integrated) kısımlardır. Bu üç kısımdan ikisi aşağıda anlatılmıştır. Tümleşik kısımda verinin duruğanlaştırılması için farkları alınmaktadır ve ilk fark alma işlemi  $I(1)$  veya  $ARIMA(0,1,0)$  şeklinde ifade edilmektedir. Box-Jenkins yaklaşımında serinin ilk olarak istatistikleri incelenir (Şekil 3.2). Bu kısımda serinin zamana bağlı grafiğine, kendiyle ilgileşim işlevine (ACF), kısmi kendiyle ilgileşim işlevine (PACF) bakılır. Serinin durağan olması istenmektedir. İncelenen istatistikler sonucunda durağan olmadığı anlaşılan seride fark alma işlemi yapılarak duruğanlaştırılma adımına gidilir ( $I(1)$ ). Tekrar serinin istatistiklerine bakılır. Durağanlık testleri yapılır. Bu kısma kadar yapılan çalışmalar “Belirleme” olarak adlandırılmaktadır. Serinin durağan olduğu belirlendikten sonra AR ve MA parametrelerinin belirlenmesi gerekmektedir. Parametre tahmininde bulunan AR ve MA katsayılarının istatistikleri incelenir ve uygun olmayan modeller ön tahmin işleminde elenir. Bu kısım “Ön tahmin” olarak adlandırılmaktadır. Uygun bulunan modeller için ise kalıntıların beyaz gürültü olup olmadığı incelenir. Kalıntıların beyaz gürültü olması halinde bulunan modellerden seçim yapma aşamasına geçilir. Burada istenen hata kıstasına göre uygun model belirlenir ve bu aşama “Model seçim” aşaması olarak adlandırılır. Seçilen model kullanılarak yapılan geleceği ön görme aşaması “tahmin” olarak adlandırılmaktadır.

ARIMA yönteminde iyi model genel olarak şöyle tanımlanır [94];

- Geçmiş veriye iyi oturur.
  - Gerçekleşen ile uydurulan verileri iyidir.
  - $\check{R}^2$  yüksektir.
  - Diğer modellere göre RSE düşüktür.
  - MAPE iyidir.
- Sezgisel yapıya uygundur.
- Gelecek ve/veya görülmemiş veride tahmini iyidir.

- Cimridir, basittir fakat etkilidir. Çok katsayı yoktur.
- Belirlenen parametreler anlamlıdır. Gereksiz ve önemsiz deęillerdir.
- Model duraęandır ve tersinirdir.
- ACF ve PACF’de örüntü kalmaz.
- Kalıntılar beyaz gürültüdür. Model eksiklięini belirten örüntü kalmaz.



Şekil 3.2. Box-Jenkins yaklaşımı

### 3.4.1. Kendiyle bağımlı modeller

Bu yöntemde regresyon analizinin zaman serilerine uygulanması söz konusudur. Regresyon analizinde bağımlı değişken olan  $Y$ ;  $X_1, X_2, X_3, \dots, X_n$  gibi bağımsız değişkenler ile temsil edilirken (Denklem (3.18)), zaman serilerinde  $Y_t$  kendinden geçmiş dönemlerin  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-n}$  değerleri ile temsil edilir (Denklem (3.19)) [90], [92], [94].

$$Y = a + bX_1 + cX_2 + \dots + kX_n \quad (3.18)$$

$$Y_t = a + bY_{t-1} + cY_{t-2} + \dots + kY_{t-k} + e_t \quad (3.19)$$

Bu denklemler t-1; t anına göre bir periyodluk bekleme (lag) ifadesidir. Bu bekleme; periyodik farkı arttıkça değişecektir. Denklem (3.20), AR(p) kısmını göstermektedir.

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t \quad (3.20)$$

Denklem (3.21) bu ifadeyi geri kaydırma işlemcisi (backward shift operator) ile göstermektedir.

$$(1 - \phi_1 B - \phi_2 B^2 + \dots - \phi_p B^p) y_t = e_t, \quad Y_t - \mu = y_t, \quad |\phi_p| < 1 \quad (3.21)$$

Burada a,b,c gibi katsayılar yerine  $\phi$  üzerinden katsayılar gösterilmektedir. İki denklem arasındaki temel fark B ifadesinin bulunmasıdır. Bu operator aslında kendisinden önceki zamandaki değeri göstermektedir.  $\phi$  katsayıları -1 ile 1 arasında olmaktadır ve durağanlık sınırı olarak adlandırılmaktadır. ARIMA(1,0,0) – AR(1) için Denklem (3.22) elde edilmektedir.

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + e_t \quad (3.22)$$

### 3.4.2. Hareketli ortalamalı modeller

Bu yöntemde (k) sayıda geçmiş dönem verisinin aritmetik ortalaması alınarak, bir sonraki değerin tahmini olarak kullanılmaktadır. Burada dönem geçtikçe bir sonraki dönemi içinde barındırırken, kendinden önceki k. dönemi dışlar [90], [92], [94].

$$Y_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i + e_i \quad (3.23)$$

Denklem q sayıda geçmiş veri için özelleştirilirse MA(q) şeklinde gösterilir ve Denklem (3.24) ile ifade edilir.

$$Y_t = e_t - \theta_1 Y_{t-1} - \dots - \theta_q e_{t-q} \quad (3.24)$$

Denklem (3.25) ile bu ifadenin geri kaydırma işlemcisi ile temsili gösterilmiştir.

$$(1 - \theta_1 B - \theta_2 B^2 + \dots - \theta_q B^q) e_t = y_t, \quad |\theta_q| < 1 \quad (3.25)$$

$\theta$  katsayıları -1 ile 1 arasında olmaktadır ve evrilebilirlik sınırı olarak adlandırılmaktadır. ARIMA(0,0,1) – MA(1) için Denklem (3.26) oluşturulmaktadır.

$$Y_t = e_t - \theta_1 e_{t-1} \quad (3.26)$$

Bir önceki değer için Denklem (3.26) tekrar ifade edilirse Denklem (3.27) bulunur.

$$Y_{t-1} = e_{t-1} - \theta_1 e_{t-2} \quad (3.27)$$

Denklem (3.26) ve (3.27) kullanılarak Denklem (3.28) bulunur.

$$Y_t = e_t - \theta_1 (Y_{t-1} + \theta_1 e_{t-2}) \quad (3.28)$$

İç içe  $e_{t-2}$  hatası  $e_{t-3}$  cinsinden ifade edilirse Denklem (3.29) bulunmuş olur.



$$Y_t = e_t - \theta_1 Y_{t-1} - \theta_1^2 e_{t-2} - \theta_1^3 e_{t-3} \quad (3.29)$$

MA(2) için durum ise Denklem (3.30)'da görülmektedir.

$$Y_t = e_t - \theta_1 Y_{t-1} - \theta_2 e_{t-2} \quad (3.30)$$

Benzer şekilde MA(3) için Denklem (3.31) ifade edilir.

$$Y_t = e_t - \theta_1 Y_{t-1} - \theta_2 e_{t-2} - \theta_3 e_{t-3} \quad (3.31)$$

SARIMA yöntemi, tıpkı ARIMA yöntemi gibidir. ARIMA ile arasındaki temel fark AR, MA ve I kısmının sezonsal kısım ile irdelenmesidir. Sezonsal kısımda kendinden bir önceki veriden kasıt bir sezon önceki veridir.

### 3.4.3. Durağanlık

ARIMA yönteminde serinin durağan olması istenmektedir. Durağanlık belirlenmesi için birim kök testleri adı verilen testler bulunmaktadır. Bu testler yapısal kırılmaların olup olmadığını sınamaktadır. Yapısal kırılmaların bulunması serinin durağan olmadığını göstermektedir. Bu testlerden iki tanesi - “Genişletilmiş Dickey Fuller” ve “Philips Perron” – literatürde kabul görmüştür ve kullanılmaktadır.

Dickey Fuller testi Denklem (3.32)'de ifade edilmiştir [98], [99].

$$Y_t = \alpha + \rho Y_{t-1} + \varepsilon, \quad H_0 : \rho = 1 (\text{Durağan değil}), \quad H_1 : \rho < 1 (\text{Durağan}) \quad (3.32)$$

Burada  $\alpha=0$  ise Rastsal yürüyüş sürecini göstermektedir. Hipotezde  $\rho=1$  ise serinin durağan olmadığı gösterilmektedir.  $\rho < 1$  ise seri durağandır. Burada denklem fark alınarak sırasıyla Denklem (3.33), ardından (3.34) ve son olarak (3.35) şekline gelir.

$$Y_t - Y_{t-1} = \alpha + \rho Y_{t-1} - Y_{t-1} + \varepsilon \quad (3.33)$$

$$Y_t - Y_{t-1} = \alpha + (\rho - 1)Y_{t-1} + \varepsilon \quad (3.34)$$

$$\Delta Y_t = \alpha + \delta Y_{t-1} + \varepsilon \quad (3.35)$$

Burada fark kendinden önceki değer ile arasındaki değerdir. Böylece  $(\rho - 1)$  yerine  $\delta$  gelir ve hipotez;  $H_0: \delta = 0$  ise durağan değil, alternatif hipotez  $H_1: \delta < 0$  ise durağandır şeklinde değişir. Bu aslında AR(1) modelidir. Denkleme zamana bağlı eğilimden kaynaklanan düşüş ve yükselişleri durağanlıktan ayırmak için yeni bir katsayı eklenir. Bu katsayı gecikme değerleri  $\beta$  ile gösterilen terimde bulunmaktadır (Denkleme (3.36)). Böylece hata terimi olan  $\varepsilon$  üzerinde seri otokorelasyon barındırmaz.

$$\Delta Y_t = \alpha + \delta Y_{t-1} + \beta Y_{t-1} + \varepsilon \quad (3.36)$$

Bu testin dışında durağanlık belirlemede kullanılan bir diğer test ise Philips-Perron (PP) testidir [100]. Bu test Denklem (3.37)'de gösterilmiştir.

$$\Delta Y_t = \alpha + \beta_i Y_{t-i} + \sum_{k=1}^h \gamma_k \Delta Y_{t-k} + \varepsilon_t \quad (3.37)$$

Bu denklem parametrik değildir. Çok sayıda veri olduğunda kullanılması daha uygundur.  $\beta$  katsayısı ADF'de olduğu gibi eğilimi göstermektedir. Burada da hipotezler Genişletilmiş Dickey-Fuller (ADF) testi gibidir. Yapı olarak da Dickey-Fuller testine çok benzemektedir. Gecikme değeri almadığı için serbestlik derecesinde azalma olmaz.

Dickey Fuller testinde otokorelasyon sorununu ortadan kaldırmak için bağımlı değişkenin gecikme uzunlukları eklenir. Bu da serbestlik derecesinin düşmesine neden olur. Philips Perron testinde ise ilave gecikme eklemek yerine, parametrik

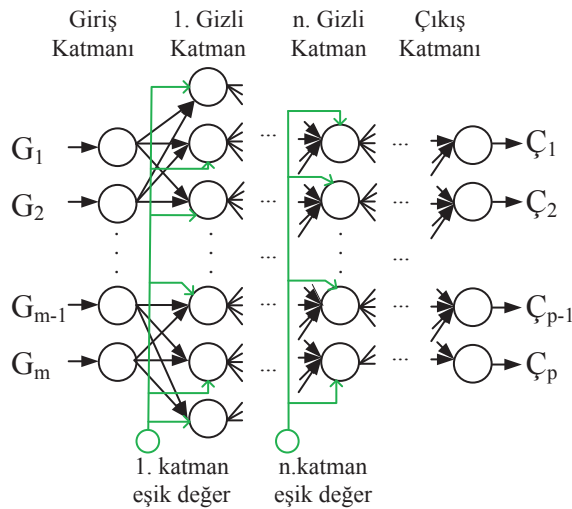
olmayan düzeltme yapılmaktadır. Böylece serbestlik derecesi kaybedilmez. PP Testinin en temel avantajı büyük örneklerde ADF'ye göre daha iyi sonuç vermesidir.

### 3.4.4. Beyaz gürültü

Yapılan tahminden sonra kalan hataların ortalamasının sıfır, varyansının sabit, normal dağılmış ve bağımsız olması gerekmektedir [94]. Bu durum beyaz gürültü olarak adlandırılmaktadır.

### 3.5. Yapay Sinir Ağları

Beynin çalışma biçimini hesaplamalı olarak insanlar tarafından farklı amaçlarda kullanılması yapay sinir ağları (YSA) ile gerçekleşmektedir. YSA'da insan sinir hücreleri olan nöronlara karşılık bilginin tutulduğu nöronlar, elektriksel olarak bilginin aktarıldığı dendritler yerine de aktivasyon fonksiyonları bulunmaktadır [101]–[103]. YSA'da yatay hiyerarşide birbiri ile bağlı olan nöronlar katmanları oluştururken, dikey hiyerarşide birbirleri arasında bağlantı olmayan nöronlar aynı katmanı oluşturmaktadır. Her nöron yatay hiyerarşide birbirlerine ağırlıklar ile bağlıdır. Şekil 3.3.'de m girişli, p çıkışlı, n gizli katmanlı bir yapay sinir ağı modeli gösterilmiştir.



Şekil 3.3. Örnek bir yapay sinir ağı

Yuvarlak şekiller nöronları temsil etmektedir. Nöronlar arasındaki oklar ise ağırlıkları göstermektedir. Yeşil renkteki nöronlara gelen oklar ise eşik değerleridir. Eşik değerleri aktivasyon fonksiyonun davranışını değiştirmeden nörona gelen girişin sonucunu düzeltmeyi sağlamaktadır. Gizli katman (ara katman) bir veya daha fazla sayıda olabilmektedir.

Yapay sinir ağlarında ağırlıkların hesaplanması farklı şekillerde olabilmektedir. Geri yayılım algoritması ileri hesaplamalı YSA modeline uygulanmaktadır. Tez çalışması kapsamında ileri doğru hesaplama (feed-forward) üzerine geri yayılım (back propagation) algoritması ve yapay arı kolonisi (YAK) algoritması kullanılmıştır.

### 3.5.1. İleri doğru hesaplama

İleri hesaplamalı YSA'da ağırlıklar ve eşik değerleri kullanılarak sonuçlar üretilmektedir. Şekil 3.4.'de gösterilen örnek YSA modeli ele alındığında giriş değerleri ilk katmanda bir değişikliğe uğramadan çıkar. Sonrasında birinci gizli katmanın ilk nöronuna gelecek değer hesaplanırken;  $a$  ağırlığı ile  $G_1$  çarpılır ve  $c$  ağırlığı ile  $G_2$  çarpılır. Bu çarpımlar  $b_1$  değerini de alarak toplanır. Bu hesaplama sonucu ara net değeri elde edilir. Bu yapılan işlem Denklem (3.38)'de genelleştirilmiştir. Bu formülde  $a$ ; kaçınıcı ara katman olduğunu,  $j$ ;  $a$ . arakatmandaki  $j$ . nöronu göstermektedir. Hesaplanan NET değeri bir önceki katmandaki çıkışlara bağlıdır. Bu sebeple önceki katmandaki  $k$ . nöronun çıkışı işlem yapılan ağırlık  $j$ . nöronuna gelen ağırlık ile çarpılmakta ve sonrasında kendisine gelen eşik değeri ile toplanmaktadır.

$$NET_j^a = b_j^a + \sum_{k=1}^n C_k^{a-1} A_{kj} \quad (3.38)$$

Hesaplanan NET değeri aktivasyon fonksiyonundan geçirilerek bir sonraki ara çıkış değeri hesaplanmaktadır. Sigmoid fonksiyonu kullanılmış aktivasyon fonksiyonu Denklem (3.39)'da gösterilmiştir.

$$C_j^a = \frac{1}{1 + e^{-(NET_j^a)}} \quad (3.39)$$

### 3.5.2. Geri yayılım algoritması

İleri doğru hesaplama sonrasında belirlenen ağırlık ve eşik değerleri sonucunda gerçekleşme ile tahmin arasında fark meydana gelecektir. Bu fark tahmin hatasıdır ve Denklem (3.40)'da gösterilmiştir. Denklemde  $m$  adet verinin her biri için  $G$  gerçekleşmesi ile  $T$  tahmini arasındaki farktan dolayı oluşan  $H$  hatası hesaplanmaktadır.  $T$ ; çıkış katmanından sonraki nihai tahmin değerini göstermektedir. Bu hataların kareleri toplanarak; toplam kare hatası ( $TKH$ ) hesaplanmaktadır (Denklem (3.41)). Bu hatanın azaltılması için hesaplanan hata geriye doğru aktarılmakta ve ağırlıkların güncelleştirilmesi işlemi geri yayılım algoritması yapmaktadır.

$$H_m = G_m - T_m \quad (3.40)$$

$$TKH = 1/2 \left( \sum_m H_m^2 \right) \quad (3.41)$$

$TKH$  değerinin her dönemde (epoch) düşmesi ve sifıra yaklaşması beklenmektedir. Bu yüzden tüm verinin ağa verilip algoritmanın çalıştırılması ile oluşan her dönemde, veri sayısı kadar iterasyon gerçekleştirilecektir. Her iterasyonda  $TKH$  kontrol edilir. Eğer bu hata değeri kabul edilebilir sınırlar içinde değil ise çıkış katmanından başlayarak geriye doğru ağırlıklar güncellenerek ilerlenmektedir. Bu güncelleme işleminin yapılabilmesi için ağırlıkların değişim miktarlarının bulunması gerekmektedir (Denklem (3.42)). Bu hesaplamada  $\lambda$  (öğrenme katsayısı) ve  $\alpha$  (momentum katsayısı) kullanılmaktadır.  $\lambda$  katsayısı her iterasyondaki öğrenme oranını belirlemektedir ve bu katsayının çok küçük değerler alması öğrenmeyi yavaşlatmaktadır.  $\alpha$  katsayısı ise ağın yerel en düşük değerlere takılmasını engellemek için kullanılmaktadır. Genellikle momentum katsayısı için büyük değerler verilmektedir. Böylece yerel bölgelerden kurtulmak kolaylaşmaktadır.

Denklemden yer alan  $\delta_m$  ise yerel eğikliği (gradient) göstermektedir ve Denklem (3.43)'de belirtilmiştir.

$$\Delta A_{jm}^a(t) = \lambda \delta_m C_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (3.42)$$

$$\delta_m = H_m f'(NET) \quad (3.43)$$

$f'(NET)$  ifadesi  $NET$  ağının aktivasyon fonksiyonunun türevidir ve aktivasyon fonksiyonu sigmoid olursa Denklem (3.44) şekline gelecektir.

$$\delta_m = H_m C_m (1 - C_m) \quad (3.44)$$

Ağırlık değişim miktarı olan  $\Delta A_{jm}^a(t)$  hesaplandıktan sonra, yeni değerler Denklem (3.45) ile güncellenmektedir.

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.45)$$

Ağırlıkların güncellenmesinde kullanılan Denklem (3.42) ve (3.45) denklemlerine benzer durum eşik değerleri için de yapılacak ve yeni eşik değerleri bulunmuş olacaktır.

### 3.6. Yapay Arı Kolonisi

Yapay arı kolonisi algoritması Karaboğa tarafından geliştirilmiştir ve arıların nektar arama davranışlarını sezgisel olarak simüle etmektedir [104]–[107]. Algoritma yapısında arılar, yaptıkları göreve göre işçi ve işçi olmayan arılar olarak ikiye ayrılmıştır. İşçi olmayan arılar da gözcü ve kaşif arı olarak iki türdür. Yapay arı kolonisi (YAK) algoritması başlangıçta çeşitli varsayımlara sahiptir. Algoritma başlangıcında rastgele yiyecek nektar kaynakları belirlenir ve işçi arılar bu kaynaklara gönderilir. Her nektar kaynağı için bir işçi arı bulunmaktadır. İşçi arıların sayısı toplam arı sayısının yarısı kadardır. İşçi arılar nektarları toplar ve elde ettikleri

bilgiyi dans ederek gözcü arılara iletirler. Gözcü arılar da elde ettikleri bilgi ile yeni nektar kaynakları aramaya çıkar. Buradaki diğer önemli nokta işçi arı nektar kaynağındaki nektarları bitirdiğinde kaşif arıya dönüşür. Kaşif arılar ise rastgele yeni nektar bölgeleri ararlar ve yeni nektar kaynağı bulduklarında tekrar işçi arıya dönüşürler. Arılar, bu şekilde algoritmadaki döngü sonlandırma kriteri sağlanıncaya kadar çalışmaya devam eder.

YAK algoritmasının ilk adımında rastgele değerler alt ve üst sınırlarda oluşturulur (Denklem (3.46)). Burada  $j$ , optimize edilecek parametre sayısını,  $i$ , yiyecek kaynağı sayısını göstermektedir.  $rand(0,1)$  fonksiyonu ise sıfır ile bir arasında rastgele sayı üretmektedir.

$$x_{ij} = x_{\min j} + rand(0,1)(x_{\max j} - x_{\min j}) \quad (3.46)$$

Gözcü arılarda yeni nektar kaynaklarına ait bilgiler bulunmaktadır. İşçi arılar nektar kaynağını tükettiklerinde kaşif arılara dönüşerek gözcü arılardan nektar bilgisini alır. Yeni kaynak bilgisi, eldeki kaynağa komşudur ve Denklem (3.47)'de gösterilmiştir. Burada  $i$ , yiyecek kaynağını,  $j$ , rastgele seçilerek optimize edilen parametreyi,  $v_i$ ,  $x_i$  komşuluğundaki kaynağı,  $\phi_{ij}$ ,  $[-1, 1]$  arasında değişen rastgele değeri,  $x_k$ ,  $x_i$  değerinin komşuluğundaki çözümü göstermektedir. Böylece  $x_i$  ile  $x_k$  arasındaki fark azaldıkça evrensel minimuma yaklaşılabacaktır.


$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (3.47)$$

Yiyecek kaynağının kalitesi uygunluk (fitness) fonksiyonu ile belirlenmektedir (Denklem (3.48)). Uygulanan yöntemde optimize edilmek istenen değer  $f_i$  bu fonksiyon ile ifade edilmektedir. Örneğin ileri hesaplamalı yapay sinir ağında  $f_i$  MSE değeridir. Yiyecek kaynağı olan  $i$  kadar uygunluk değeri bulunacaktır. Burada mevcut yiyecek kaynağındaki nektar miktarı, yeni bulunan kaynaktaki nektar miktarından yüksek ise değiştirilmez ve yeni yiyecek arıyışına devam edilir.

$$fitness_i = \begin{cases} 1/(1+f_i) & f_i \geq 0 \\ 1/|mutlak(f_i)| & f_i < 0 \end{cases} \quad (3.48)$$

### 3.7. YSA – YAK Entegrasyonu

Yapay sinir ağlarında kullanılan algoritmaların ezberleme, genelleme ve yerel minimuma takılma gibi problemleri bulunmaktadır. Bu problemlerin üstesinden gelmek için farklı teknikler uygulanmaktadır. Bu tekniklerin başında farklı algoritmalar ile yapay sinir ağlarının birleştirilmesi gelmektedir. Bu başlık altında bir önceki bölümde anlatılan yapay arı kolonisi algoritması kullanılarak yapay sinir ağının eğitimi gerçekleştirilecektir [87]. YAK ile YSA' nın eğitimi için ileri yönlü hesaplama kullanılmaktadır. Örneğin Şekil 3.4.'de gösterilen a, b, c, d, e, f, g, h ve  $b_1, b_2, b_3, b_4$  ağırlıkları bir diziye yerleştirilir. Bu dizi içindeki değerler kullanılarak yapay sinir ağı tahmin sonucu üretilecektir. YSA-YAK entegrasyonunun akış diyagramı Şekil 3.5.'de gösterilmiştir. Dizi içindeki ilk değerler başlangıçta rastgele üretilerek atanmaktadır. Daha sonra YAK algoritmasına yüklenen parametreler çalıştırılarak işçi arılar bu yeni popülasyonlara dağıtılmış olup yeni nektar bölgeleri bulunmaya çalışılmıştır. Yeni popülasyonlardaki ağırlık ve eşik değerleri ile tüm veri üzerinden hata değerleri ileri beslemeli hesaplama yöntemi ile bulunur.



Şekil 3.4. Örnek bir YSA modeli

Hata değeri doğal gaz tüketimine uygun olarak ortalama kare hata (MSE), bağıl mutlak yüzdesel hata (MAPE) ve  $R^2$  olarak belirlenmiştir.



Ortalama kare hata gerçekleşme (G) ile tahmin (Ç) arasındaki her bir farkın karesinin toplam eleman sayısına (n) bölünmesiyle oluşturulmaktadır.

$$MSE = \frac{1}{n} \sum (G - \hat{C})^2 \quad (3.49)$$

Bağıl mutlak yüzdesel hata (MAPE) ise gerçekleşme ile tahmin arasındaki her bir farkın mutlak değerinin, o anki gerçekleşme değerine bölünmesiyle elde edilir. YSA'daki eğitim aşamasında MAPE hesaplanırken, yüzdesel olarak çarpma işlemi gerçekleştirilmeden kullanılmıştır. Böylece hatanın sıfır olması hedeflenmiştir. Tahmin sonuçlarında ise yüzdesel olarak ifade edilmesi için değer yüz ile çarpılmaktadır.

$$MAPE = \% \frac{|G - \hat{C}|}{G} \quad (3.50)$$

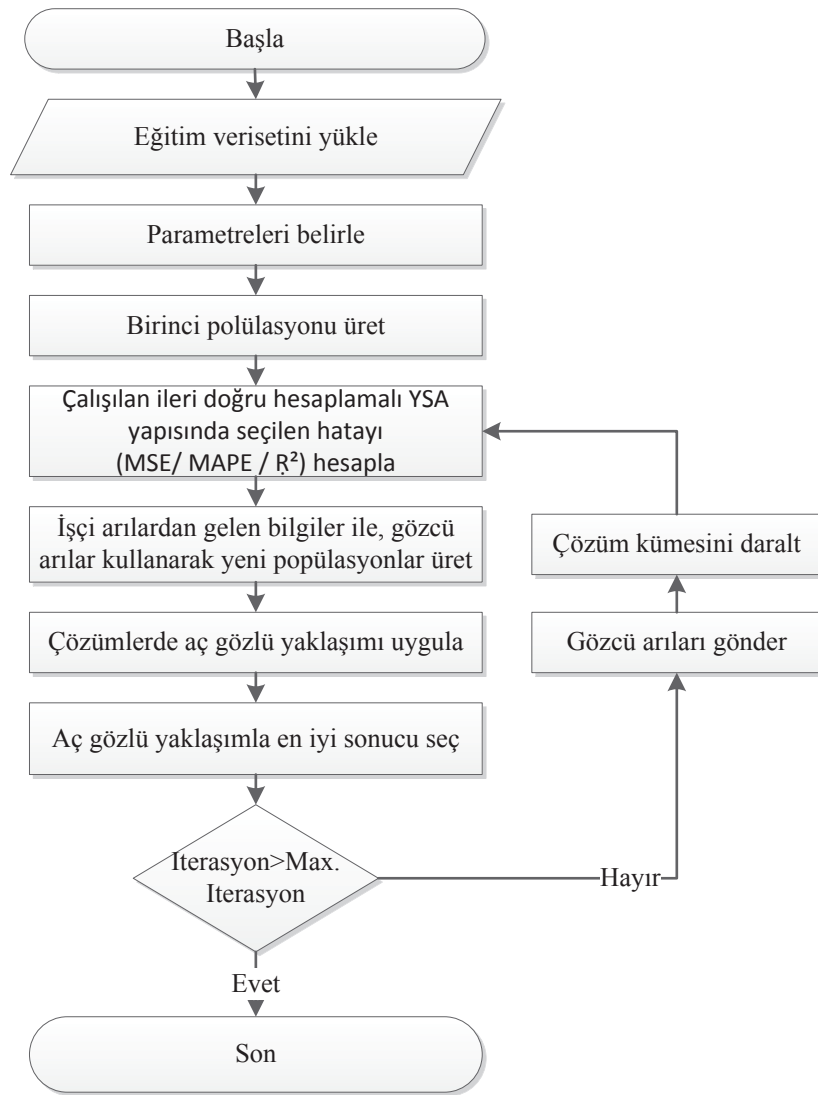
Eğitim ve talep tahmin sonuçlarında kullanılan bir diğer seçme kriteri ise belirleme katsayısı olan  $R^2$  değeridir. Bu katsayı gerçekleşme ile tahminin birbirleri arasındaki uyumu göstermektedir. Yani tahminin, gerçekleşmeyi ne kadar karşıladığını göstermektedir.  $R^2$  değeri 0 ile 1 arasında olabilmektedir. Sıfıra yakın olması tahmin ile gerçekleşme arasındaki örtüşmenin düşük olduğunu, bire yakın olması tahmin ile gerçekleşmenin tüm seri üzerinde örtüşüğünü göstermektedir.

$$R^2 = \frac{\sum (G - G_{ort})(\hat{C} - \hat{C}_{ort})}{\sqrt{\sum (G - G_{ort})^2 \sum (\hat{C} - \hat{C}_{ort})^2}} \quad (3.51)$$

$R^2$  değerinin bire yakın olması istenmektedir. Fakat YSA'da hatalar minimize edilmek istenmektedir. Bu sebeple  $R^2$  değeri birden çıkartılır ve sonuç sıfıra yaklaşmış olur (Denklem (3.52)). Formülün devamında bulunan katsayı ise düzeltme katsayısıdır. Düzeltme katsayısı; model içinde kullanılan bağımsız değişken sayısı artması ile artan  $R^2$  değerini bu etkiden arındırmak için kullanılmaktadır. Eğer gerekli olmayan değişken kullanılırsa  $R^2$  değeri bulunmasına rağmen  $R^2$  değeri düşük

çıkacaktır. Düzeltme katsayısında  $n$  eleman sayısı,  $k$  ise kullanılan bağımsız değişken sayısıdır. Tez çalışmasında 7 günlük tüketim verisi tahmin için girişte kullanıldığından dolayı bu katsayı  $(1096-1)/(1096-7-1) = 1,0064$  olarak bulunmuştur. Diğer bir ifadeyle  $R^2$  değerini %0,64 oranında arttırarak bulunacaktır.

$$R^2 = \frac{\sum (G - G_{ort})(C - C_{ort})}{\sqrt{\sum (G - G_{ort})^2 \sum (C - C_{ort})^2}} \left[ \frac{n-1}{n-k-1} \right] \quad (3.52)$$



Şekil 3.5. YSA-YAK entegrasyonu akış diyagramı

Seçilen hata yöntemine göre bulunan sonuçlardan açgözlü yaklaşım ile en düşük olan seçilir. Daha sonra işçi arılardan gelen bilgiye göre gözcü arılar kullanılarak yeni popülasyonlar üretilir. İterasyon sayısı, maksimum iterasyonu geçmediyse yeni popülasyonlar için gözcü arılar gönderilir ve çözüm kümesi daraltılır. Daraltılan çözüm kümesi kullanılarak tekrar YSA'nın hataları hesaplanır. Bu işlem maksimum iterasyon sayısı kadar devam eder.

## **BÖLÜM 4. ARAŞTIRMA BULGULARI VE SONUÇLAR**

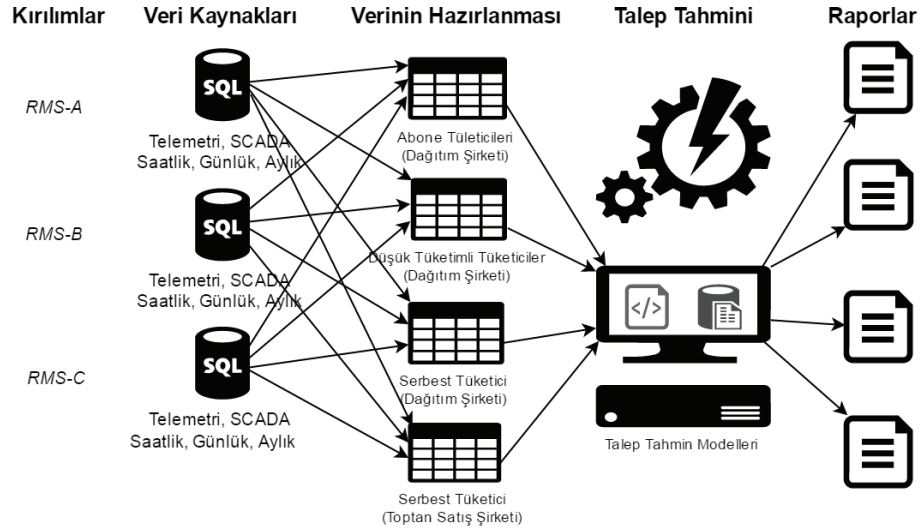
Tez çalışmasının bu bölümünde, doğal gaz ölçümü yapan sisteminin tanımlanması, talep tahmini tüketim verisinin hazırlanışı ve bir önceki bölümde gösterilen zaman serilerinde kullanılan tahmin yöntemleri ile doğal gaz talep tahmini sonuçları gösterilmiştir.

### **4.1. Doğal Gaz Tüketim Verisinin Hazırlanması**

Türkiye’de doğal gaz son kullanıcılara borular ile dağıtılmaktadır. Doğal gaz boruları şehirlere gaz basıncı düşürme ve ölçüm istasyonları (reducing and measuring station – RMS) yoluyla bağlanmaktadır. Bu istasyonlarda yüksek basınçlı doğal gazın iletim basıncı düşürülür ve hacim ölçümü yapılır. RMS’ler üç gruba ayrılır. Bunlardan birincisi RMS-A’dır ve ulusal dağıtım hattını bölgesel dağıtım hattına bağlar. Bu bağlantılar yüksek basınçtan dolayı çelik borular ile yapılmaktadır. 40-75 bar arasında değişen giriş basıncı istasyonda 12-25 bar’a düşürülür ve saatlik tüketim aralığı 10.000 ile 300.000 m<sup>3</sup> arasında değişmektedir. RMS-A istasyonları şehir doğal gaz dağıtım şirketleri tarafından yönetilirler. Diğer iki RMS türü B ve C’dir. RMS-B istasyonları da çelik hatlara sahiptirler ve basıncı 6-25 bar’dan 4 bar’a düşürürler. RMS-C istasyonları ise polietilen hatlara sahiptirler ve basıncı 1-4 bar’dan 0.3 bar’a düşürürler. Tüm RMS istasyonlarının tüketimleri saatlik olarak ölçülür ve hesaplanır. Bu tez çalışması kapsamında doğal gaz tüketim verisi Sakarya ilinde hizmet veren Adapazarı Doğal Gaz Dağıtım Şirketi’nin (AGDAŞ) veritabanları üzerinden hazırlanmış ve alınmıştır. AGDAŞ bünyesinde 9 RMS-A, 53 RMS-B, 70 RMS-C istasyonu, 82 bölge regülatörü, 79 vana odası bulunmaktadır.

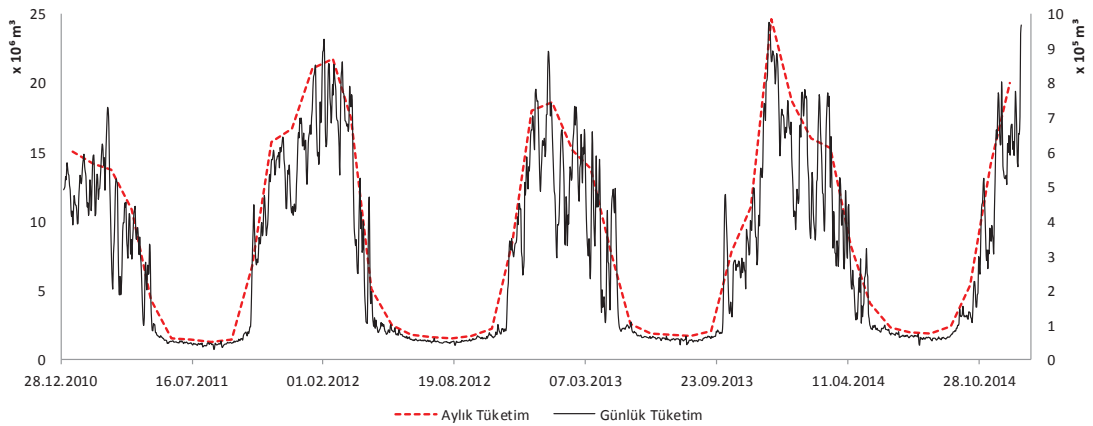
Doğal gaz tüketim tahmini gün öncesi günlük olarak ve yıl öncesi aylık olarak yapılmaktadır. Bu yüzden tüm RMS’lerdeki saatlik olarak bulunan veriler öncelik

günlük ve sonrasında aylık verilere dönüştürülmüştür. Serbest tüketicilerin 90%'nında RMS istasyonu bulunmaktadır ve telemetri sistemi için uzaktan okunmaktadır. RMS-B ve RMS-C'ye sahip serbest tüketicilerin uzaktan okuma verileri RMS-A tüketimlerinden çıkartılmıştır. Böylece evsel ve düşük tüketimli tüketicilerin doğal gaz kullanım verileri kalmıştır (Şekil 4.1.).



Şekil 4.1. Talep tahmini için model oluşturulması

Uzaktan okuma sistemi olan telemetri sistemi AGDAŞ tarafından 2011 yılında devreye alınmıştır. Çalışmada araştırma bulguları ve sonuçları 01.01.2011 tarihinden başlayarak 31.12.2014 tarihine kadar hazırlanan veri üzerinden gösterilmiştir (Şekil 4.2.).



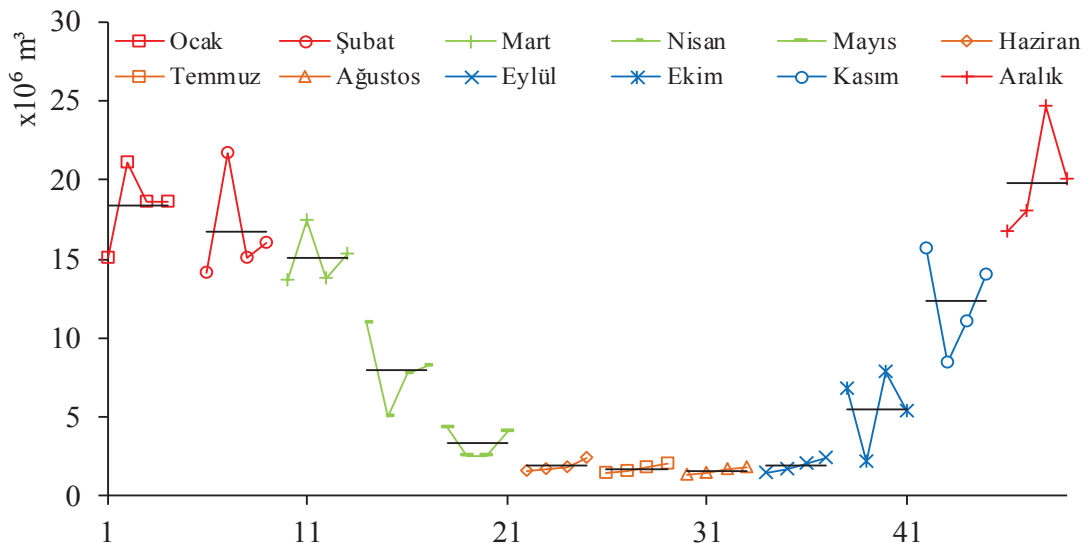
Şekil 4.2. Aylık ve günlük doğal gaz tüketimi

Grafiğin birincil eksen (sağ eksen) tarafı aylık tüketimler için, ikincil eksen (sol eksen) tarafı günlük tüketimler için hazırlanmıştır. Talep tahmininde tüketim verisinin 2011-2013 yılları arasındaki veriler 2014 yılının tahmininde kullanılmıştır.

Çalışmanın talep tahmin kısmı iki bölümden oluşmaktadır. Bunlardan ilki yıl öncesi kapasite rezervasyonu ve/veya “al ya da öde” anlaşmalar için gerekli olan yıl öncesi aylık doğal gaz talep tahminidir. Çalışmanın ikinci bölümünde gün öncesi doğal gaz talep tahmini yapılmıştır. Yıl öncesi aylık talep tahmininde iki farklı çözünürlükte veri kullanılmıştır. Bunlar sırasıyla günlük veri ve aylık veridir. Yıl öncesi aylık talep tahmininde zaman serilerinin ayrıştırması, Holt üstel düzleştirme, Winters üstel düzleştirme, ARIMA/SARIMA istatistikî yöntemleri kullanılırken gün öncesi talep tahmininde geri yayımlı YSA, YSA-YAK ve Winters üstel düzleştirme yöntemi kullanılmıştır. Yapılan çalışmalar sonucunda talep tahmin hataları irdelenmiş ve en iyi tahmin yöntemi belirlenmeye çalışılmıştır.

#### 4.2. Yıl Öncesi Aylık Talep Tahmini ve Sonuçları

Aylık tüketim verisi mevsimlere bağlı olarak değişken tüketim göstermektedir. Her ay için bir yıldaki tüketimleri gösteren yıllık alt tüketim grafiği Şekil 4.3.'de gösterilmiştir.



Şekil 4.3. Aylık doğal gaz tüketim alt grafiği

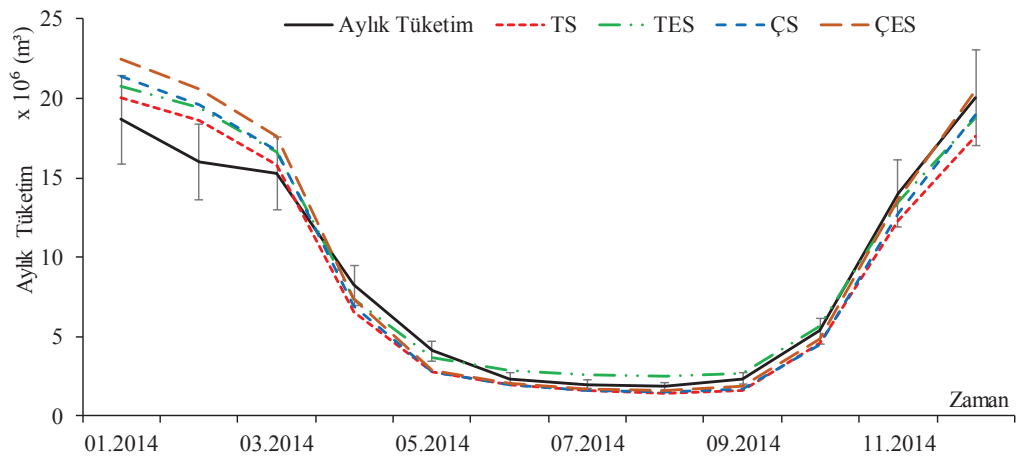
Bu grafik üzerindeki siyah çizgiler 4 yıldaki aynı ayın ortalamasını göstermektedir. Her senenin birbirinden farklı davranış sergilediği bu şekilde görülmektedir. Çalışmanın bu aşamasında yıl öncesi aylık talep tahmini üzerine çalışılmıştır. Bu bölümde yıl öncesi aylık doğal gaz talep tahmini için iki farklı yol kullanılmıştır. Bunlardan ilki aylık verinin kullanılarak aylık talep tahmininin yapılmasıdır. İkinci yolda ise günlük veriler kullanılarak aylık talep tahmini yapılmıştır. Böylece veri yoğunluğunun da tahmin üzerinde etkisinin ne olacağı görülecektir.

#### 4.2.1. Aylık veri üzerinden yıl öncesi talep tahmini

Bu bölümde yıl öncesi aylık talep tahmini aylık veri kullanılarak zaman serilerinin ayrıştırma, Holt üstel düzleştirme, Holt-Winters üstel düzleştirme ve ARIMA/SARIMA yöntemleri ile gerçekleştirilecektir.

##### 4.2.1.1. Zaman serilerinin ayrıştırma sonuçları

Zaman serilerinin ayrıştırma yöntemi etkilerin birbirleriyle toplamı ve çarpımı olarak hesaplanabilmektedir. Yöntemdeki diğer bir özellik ise eğilim ve sezonsallık beraber olabileceği gibi, sadece sezonsallık içeren model de oluşturulabilmektedir. Buradaki çalışmada iki farklı durum için dört farklı model oluşturulmuştur ve Toplamsal Sezonsal (TS), Toplamsal Eğilim Sezonsal (TES), Çarpımsal Sezonsal (ÇS), Çarpımsal Eğilim Sezonsal (ÇES) olarak ifade edilmektedirler (Şekil 4.4.).



Şekil 4.4. Yıl öncesi aylık talep tahmininde aylık veri üzerinden zaman serilerinin ayrıştırmasının sonuçları

Şekil 4.4.'de her ay üzerinde ilgili ay tüketiminin  $\pm\%15$ 'i kadar güvenlik bandı bulunmaktadır. Şekilde görüldüğü üzere TES yaz mevsimi dışında bu bandın içinde kalmıştır. TS, TES, ÇS ve ÇES'in 2014 yılı için yaptıkları tahminin MAPE'leri ve  $R^2$  değerleri sırasıyla %17,2, %15,06, %17,5, %15.14 ve 0,965, 0,9695, 0,9665, 0,9718 olmuştur. Zaman serilerinin ayrıştırma metodu için ÇES modelinin MAPE ve  $R^2$  değerleri üzerinden en iyi sonuçları verdiği görülmektedir.

#### 4.2.1.2. Holt-Winters üstel düzleştirme sonuçları

Holt ve Holt-Winters üstel düzleştirme yöntemi aynı temel üzerine kurulmuştur. Holt-Winters üstel düzleştirme yönteminin Holt üstel düzleştirme yönteminden tek farkı sezonsal etki barındıran modeller oluşturabilmesidir. Holt üstel düzleştirme yönteminde sadece toplamsal model bulunurken, Holt-Winters üstel düzleştirme yönteminde toplamsal ve çarpımsal olarak modeller kurulabilmektedir. Zaman serilerinin ayrıştırmasından farklı olarak burada Holt üstel düzleştirme yöntemi için  $\alpha$  ve  $\beta$  parametreleri; Holt-Winters üstel düzleştirme yöntemi için  $\alpha$  ve  $\beta$  parametrelerine ilave olarak  $\gamma$  parametresi eklenmiştir. Bu parametreler ve geçmiş tüketiminlerin etkisi alınarak geleceğin tahmin edilmesi hedeflenmektedir. Model kurma aşamasının başlangıcında her iki teknikte de tüm parametreler 0,2 olarak ele alınır. Fakat bu parameter değerleri en iyi sonucu vermez. Bu sebeple parameter değerlerinin uygun şekilde belirlenmesi tahmini doğrudan etkilemektedir. Doğru katsayıların bulunması için en küçük kareler yöntemi 500.000 adım ve 0,000001 yakınsama ile kullanılmıştır. Yüksek adım sayısı ve düşük yakınsama, parametrelerin daha hassas belirlenmesini sağlayacaktır.

Holt üstel düzleştirme yöntemi için  $\alpha$  ve  $\beta$  parametreleri 0,2 alınarak ve optimize edilmiş halde sonuçlar bulunmuştur. Optimizasyon sonrasında tahmin sonuçlarında iyileşmeler görülmüştür ve  $\alpha=1$ ,  $\beta=0,547$  bulunmuştur. Holt üstel düzleştirme yönteminde sezonsal etkiyi belirlemeyi hedefleyen  $\gamma$  parametresi bulunmamaktadır. Bu sebeple iki modelde de MAPE'ler çok yüksek ve  $R^2$  değerleri çok düşüktür. 2014 yılı tahmininde  $\alpha$ ,  $\beta=0,2$  ve optimize edilmiş durumdaki MAPE ve  $R^2$  değerleri sırasıyla %214, %2120 ve 0,036, 0,03664 olarak bulunmuştur.




Holt-Winters üstel düzleştirme yönteminde eklenen  $\gamma$  parametresi modelin sezonsallığı da içermesini sağlamıştır. Holt-Winters üstel düzleştirme yöntemi için sezonsallığın toplamsal ve çarpımsal modelleri mümkün olabilmektedir. Tablo 4.1.'de Winters üstel düzleştirme yönteminin sonuçları gösterilmiştir.

Tablo 4.1. Aylık tüketim ile Winters üstel düzleştirme yöntemi ile aylık tahmin sonuçları

	Yöntem	Kısaltması	Parametre değerleri	MAPE (%)	R <sup>2</sup>
Toplamsal	$\alpha, \beta, \gamma = 0,2$	WT0.2	$\alpha, \beta, \gamma = 0,2$	74,6	0,9510
Model	Optimize edilmiş	WTO	$\alpha=0,0001, \beta=0,01, \gamma=0,375$	14	0,9846
Çarpımsal Model	$\alpha, \beta, \gamma = 0,2$	WÇ0.2	$\alpha, \beta, \gamma = 0,2$	26,7	0,9584
	Eğilimsiz	WÇE'	$\alpha=0,00412, \gamma=0,0006$	93,5	0,9888
	Optimize edilmiş	WÇO	$\alpha=0,15, \beta=0,0001, \gamma=0,74$	15,05	0,9640

Sonuçlarda parametrelerin 0,2 olduğu durumda hataların en yüksek olduğu görülmektedir. Eğilimsiz çarpımsal modelde ( $\beta=0$ ) hatalar eğilimli modele göre daha yüksektir. Fakat eğilimsiz toplamsal modelde hatalar eğilimli modele göre daha düşüktür. Bu modelin çarpımsal model olması gerektiğini göstermektedir. Çarpımsal modelin toplamsal modele göre farklı, eğer  $I_t$  değeri birden büyükse, oranına göre daha yüksek tahmin yaparken, eğer  $I_t$  değeri birden küçükse, oranına göre daha düşük tahmin yapmaktadır. Çarpımsal sezonsal modelde tahmin sonuçlarını orantısal olarak değiştirmektedir. Toplamsal modelde ise sezonsal kısım toplanarak modele eklenmektedir. Bu yüzden orantısal olarak artış veya düşüş bulunmamaktadır. Bu durumda modelde eğilim olmasından dolayı çarpımsal modelin daha iyi sonuç verdiği görülmektedir.

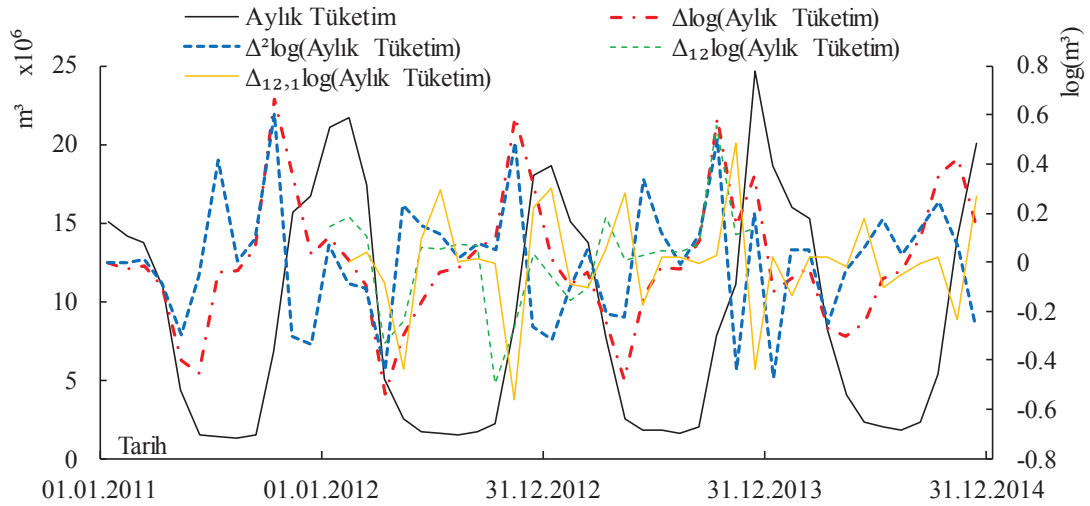
Şekil 4.5.'de Winters üstel düzleştirme yönteminin sonuçları gösterilmiştir. Optimize edilmemiş parametrelerin ilk 3 aydan sonra sınırların dışına çıktığı görülmektedir. Trend olmayan model olan WTE'de negative değerler tahmin etmiştir ve modelinin de çok yüksek sapma ile tahmin ettiği belirlenmiştir. Bu modelin yetersizliğini göstermektedir. Diğer hazırlanan modellerin tahminde yaklaşık sonuçlar verdiği görülmektedir. Tablo 4.1.'de düşük MAPE değerleri şeklindeki sonuçları doğrulamaktadır ve %15 civarında bulunmuştur.



Şekil 4.5. Yıl öncesi aylık talep tahmininde aylık veri üzerinden Winters üstel düzleştirme yöntemi sonuçları

#### 4.2.1.3. ARIMA/SARIMA yöntemi sonuçları

ARIMA/SARIMA yöntemleri zaman serileri ve tahminde bağımsız değişken olmaksızın geleceği öngörmeye güçlü bir araçtır. Bu güçlü aracın kendine özgü bazı özel durumları bulunmaktadır. Bu durumların başında serinin durağan olmasının gerekliliği gelmektedir. Eğer seride eğilim veya sezonsallık bulunuyorsa seri durağan değildir. Aylık doğal gaz tüketimi de durağan değildir (Şekil 4.6.).



Şekil 4.6. Aylık doğal gaz tüketimi ve fark alma sonucu doğal gaz tüketimi

Serinin durağanlaştırılması için öncelikle logaritması alınır. Böylece serideki uç noktalar belirli bir aralığa indirgenmiş olur. Daha sonra serinin farkları alınarak

durağan seri elde edilir. Oluşan yeni seride AR, MA, SAR (sezonsal AR) ve SMA (sezonsal MA) parametreleri belirlenir.

Fark alma işlemi “ $\Delta$ ” ile gösterilmektedir ve değer kendinden önceki değerden çıkartılması ile bulunmaktadır. İkinci dereceden fark ise ilk farklar serisinde tekrar fark alma işlemi yapılarak bulunur. Sezonsal fark alma işleminde ise sezonsallık boyutuna göre bir önceki sezon ile arasındaki fark alınmaktadır. Aylık veri ile aylık tahmin için 12 ay önceki değer ile arasındaki değişim sonucu sezonsal fark olarak bulunur ve “ $\Delta_{12}$ ” ile gösterilmektedir. Hazırlanan tüm serilerde farkları alınmış seriler şu şekilde ifade edilir;

- İlk farklar serisi;  $\Delta \log(\text{Aylık Tüketim})$ ; I(1)1 or ARIMA(0,1,0)1
- İkinci dereceden farklar serisi;  $\Delta^2 \log(\text{Aylık Tüketim})$ ; I(2)1, ARIMA(0,2,0)1
- İlk sezonsal farklar serisi;  $\Delta_{12} \log(\text{Aylık Tüketim})$ ; I(0)1(1), ARIMA(0,0,0)1(0,1,0)<sup>12</sup>
- İlk fark ve ilk sezonsal farklar serisi;  $\Delta_{12,1} \log(\text{Aylık Tüketim})$ ; I(1)1(1), ARIMA(0,1,0)1(0,1,0)<sup>12</sup>

Şekil 4.6.’deki ilk farklarda sezonsallığın hala etki ettiği görülmektedir. I(2)1, I(0)1(1)<sup>12</sup> ve I(1)1(1)<sup>12</sup> serilerinde ise bu fark gözle görülmemektedir. Oluşan fark alınmış serilerin tanımlayıcı istatistikleri, Tablo 4.2.’de gösterilmiştir.

Tablo 4.2. Fark alınmış serilerin tanımlayıcı istatistikleri

<i>Değişken</i>	<i>Gözlem Sayısı</i>	<i>Minimum</i>	<i>Maksimum</i>	<i>Ortalama</i>	<i>Std. Sapma</i>
<i>Aylık Tüketim</i>	48	1.281.594	24.651.621	8.854.694	7.203.095
<i>I(0)1(0)</i>	48	6,108	7,392	6,757	0,443
<i>I(1)1</i>	47	-0,537	0,665	0,003	0,263
<i>I(2)1</i>	46	-0,469	0,606	0,003	0,243
<i>I(0)1(1)<sup>12</sup></i>	36	-0,492	0,554	0,019	0,176
<i>I(1)1(1)<sup>12</sup></i>	35	-0,561	0,483	-0,007	0,21

Doğal gaz tüketim serisinin logaritması alınarak 6,108 ile 7,392 aralığına indirgenmiş olur. Böylece ortalaması ve standart sapması sıfıra yakın seriler fark alma işlemleri sonucunda bulunabilmektedir.

Serilerin durağanlığı gözle görülmesine rağmen bununla ilgili ADF ve PP testleri bulunmaktadır. Tablo 4.3.'de durağanlık testleri olan ADF ve PP testlerinin sonuçları görülmektedir. Bu testler basit olarak birim kök olup olmamasını sınamaktadır. Başlangıçta serinin durağan olmadığı kabul edilir ve buna göre  $H_0$  hipotezi oluşturulur. Hipoteze göre seride en az bir birim kök bulunmaktadır ve alternatif hipotezde seride birim kök bulunmamaktadır. Anlamlılık düzeyi olan p olasılığı 0,05 olarak alınmıştır ve p değeri bu değer altında ise seri durağandır denir. Birim kök sınaması sabit ve eğilim olmadan (yok durumu), sadece sabit olma durumu (s) ve sabit ile eğilim olma durumu için (S+E) gerçekleştirilmiştir. Test sonuçlarına göre aylık tüketimin düzenlenmemiş ilk hali dışındaki durumlarda serinin durağan olduğu görülmüştür.

Tablo 4.3. Tüketim serilerinin durağanlık test sonuçları

	ADF test			PP test		
	Yok	S	S+E	Yok	S	S+E
Aylık Tüketim	0,715	0,000	0,001	0,077	0,062	0,22
I(1)I	0,000	0,000	0,000	0,001	0,012	0,048
I(2)I	0,000	0,000	0,000	0,000	0,000	0,000
I(0)I(1) <sup>12</sup>	0,000	0,002	0,006	0,000	0,002	0,008
I(1)I(1) <sup>12</sup>	0,079	0,453	0,644	0,000	0,000	0,000

Serinin durağanlığını gösteren diğer bir yöntemde ACF ve PACF grafikleridir. Şekil 4.7. aylık doğal gaz tüketim serilerinin ACF ve PACF grafiklerini göstermektedir. Burada tüketim ve logaritması alınmış birincil fark serisinin sezonsal örüntüye sahip olduğu ACF grafiklerinde görülmektedir. İkinci fark, sezonsal fark, hem sezonsal hem de birincil fark serilerinin ACF grafiklerinde ise örüntü bulunmamaktadır. Fakat bu serilerde dikkat çeken nokta 12. gecikme değerlerinde, yani bir sezon öncesine göre, ilişkinin bulunması ve bunun anlamlı olmasıdır. İlişkinin varlığı hem ACF hem de PACF grafiklerinde net bir şekilde görülmektedir.

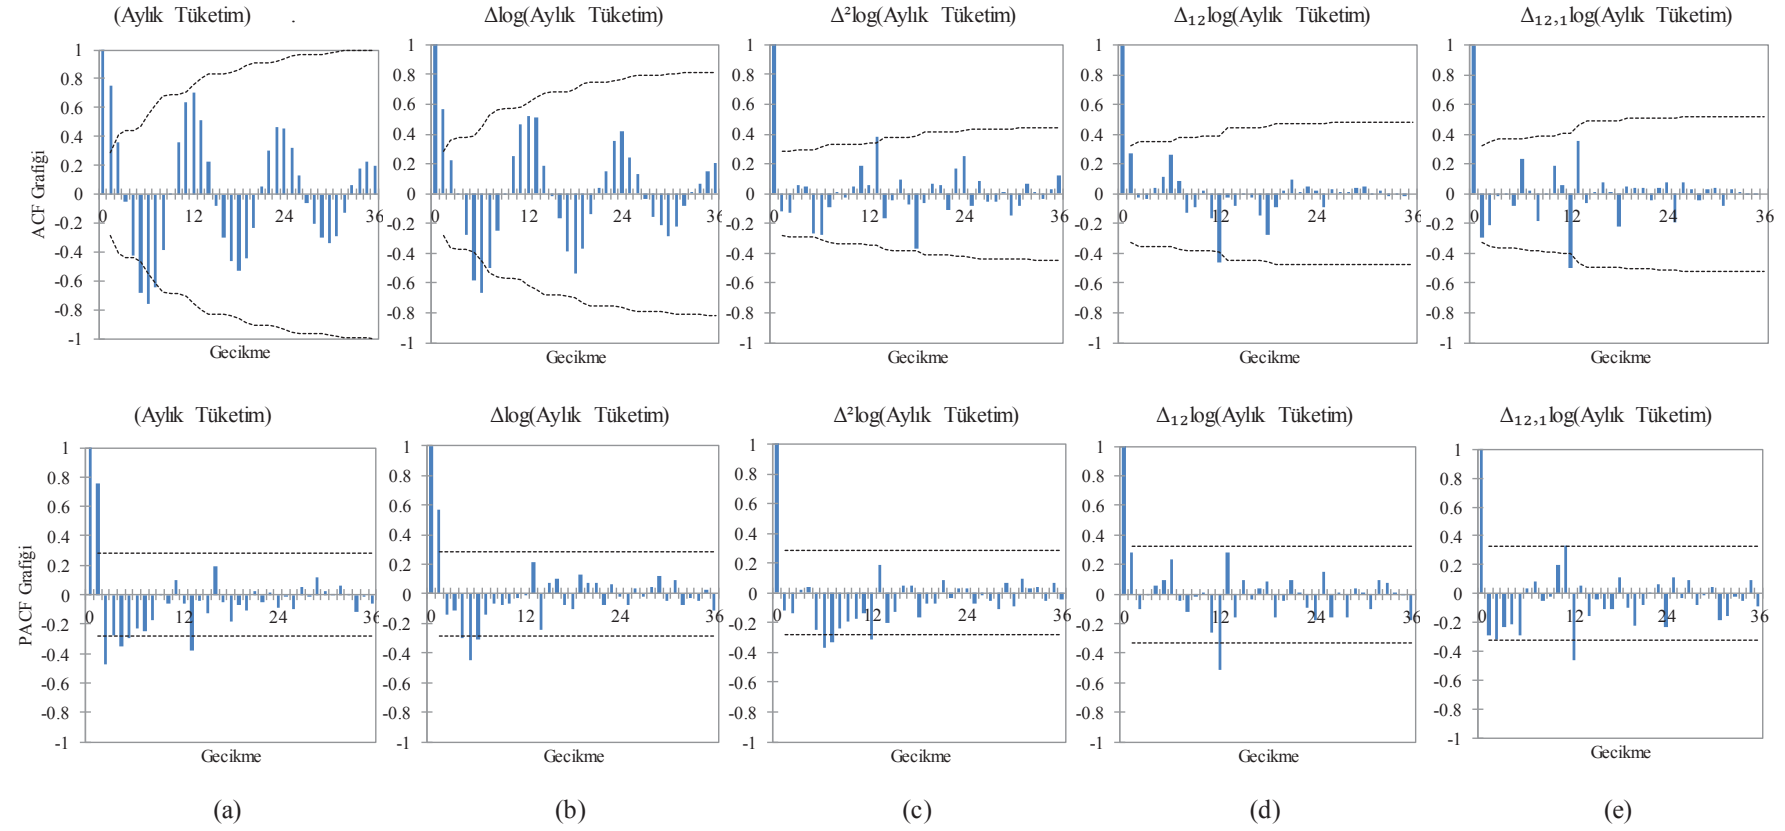
Yapılan bu durağanlaştırma çalışmaları sonucunda I(2)1, I(0)1(1) ve I(1)1(1) serilerinin durağan olduğu görülmüştür. Bu aşamadan sonra durağanlaştırılan seri üzerinde ARIMA/SARIMA yöntemi uygulanmıştır. Yöntemdeki AR, MA'nın sezonsal ve sezonsal olmayan katsayıları sıfır ile üç arasında farklı değerler için sonuçları bulunmaya çalışılmıştır. Böylece oluşturulmaya uygun her seri için en fazla 256 farklı tahmin modeli kurulmuştur. Bu modellerden bazıları fark almadan dolayı katsayıları yetmemiştir. Örneğin çift fark alınmasından dolayı I(1)1(1) serisinde ARIMA(0,1,0)1(1,1,3) modeli kurulamayacaktır. Çünkü kendisinden önce iki sezonsal seri bulunmaktadır. Yani sezonsal fark alınmış modellerde sezonsal parametreler en fazla iki olabilmektedir.

ARIMA/SARIMA yönteminde dört farklı ölçüt için en iyi tahmin sonuçları bulunmuştur. 2011-2013 arası MAPE ve  $R^2$ , 2014 yılı MAPE<sub>2014</sub> ve  $R^2_{2014}$  şeklinde gösterilmiştir (Tablo 4.4.).

Tablo 4.4. ARIMA/SARIMA yöntemi için en iyi sonuçlar ve tahmin hata durumları

<i>Kriter</i>	<i>Tanım</i>	<i>Parametre değerleri</i>	<i>MAPE (%)</i>	<i>R<sup>2</sup></i>
<i>MAPE</i>	AA1	ARIMA(3,0,3)1(1,1,1) <sup>12</sup>	27,44	0,8706
<i>MAPE<sub>2014</sub></i>	AA2	ARIMA(1,1,1)1(0,1,1) <sup>12</sup>	12,89	0,9841
<i>R<sup>2</sup></i>	AA1	ARIMA(3,0,3)1(1,1,1) <sup>12</sup>	27,44	0,8706
<i>R<sup>2</sup><sub>2014</sub></i>	AA3	ARIMA(0,1,1)1(0,1,1) <sup>12</sup>	14,99	0,9863

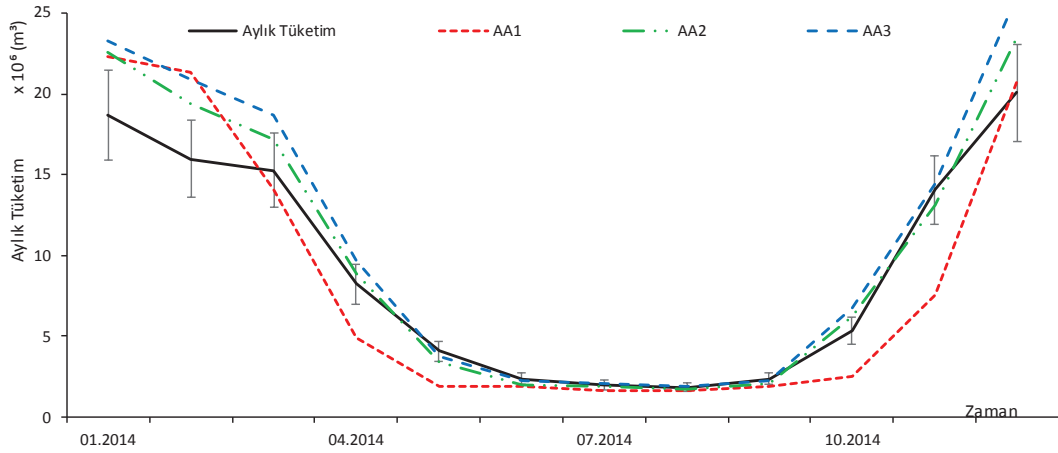
Tablodaki tanımda Aylık veri ile Aylık tahmin için “AA” kullanılmıştır. Sonrasında ise AAx şeklinde ifade edilmiştir. Buradaki x modelin numarasıdır ve detay parametre değerleri tabloda görülmektedir. 2011-2013 arasındaki seride  $R^2$  ve MAPE aynı modelin en iyi tahminde bulunabileceğini öngörürken, 2014 yılında yapılan tahminlere bakıldığında durum değişmektedir. Öncelikle 2014 yılı için yapılan tahminlerdeki en iyi durumlarda hem sezonsal hem de ilk fark bulunmaktadır. Fakat 2011-2013 arasındaki seride sadece sezonsal farkın bulunduğu model en iyi sonucu vermiştir. ACF ve PACF grafikleri incelendiğinde (Logaritmik dönüştürülmüş ve farkları alınmış tüketimlerin ACF ve PACF grafikleri.) her ne kadar sezonsal farkın daha yüksek ilişkisi olduğu görülse de ilk farklarında etkisinin olduğu görülebilmektedir. Hem sezonsal hem de sezonsal olmayan MA parametresinin



Şekil 4.7. Logaritmik dönüştürülmüş ve farkları alınmış tüketimlerin ACF ve PACF grafikleri

bulunması verinin hareketli ortalamasının anlamlı olduğunu göstermektedir. Sezonsal olmayan AR parametresinin de çoğu modelde bulunması geçmiş dönemle ilişkisinin ilk adımda bulunduğunu göstermektedir.

Şekil 4.8.'de ARIMA/SARIMA yönteminin yıl öncesi aylık tahmin sonuçları gösterilmektedir.



Şekil 4.8. Yıl öncesi aylık talep tahmininde aylık veri üzerinden ARIMA/SARIMA sonuçları


Burada dikkati çeken ilk nokta AA1 serisinin geçmiş veride en iyi durum olmasına rağmen 2014 yılı tahminindeki yetersizliğidir. AA2 ve AA3 modellerinde ise gerçekleşen tüketime yakın sonuçlar görülmektedir. Hatta MAPE'si %12,89 olan AA2'nin daha düşük hataya sahip olduğu rahatlıkla gözlemlenebilmektedir. AA1'in  $R^2$  değerinin AA2 ve AA3'den düşük olması grafik üzerinde de rahatlıkla görülebilmektedir. Yaz mevsimi dışındaki tahminlerde AA1'in performansı AA2 ve AA3'e göre yarı yarıya düşüktür.

#### 4.2.2. Günlük veri üzerinden aylık talep tahmin

Bu bölümde yıl öncesi aylık talep tahmini günlük veri kullanılarak önceki bölümdeki yöntemler ile yapılmıştır. Bu bölümde günlük veri ile aylık veri arasında performans sonuçları da gösterilecektir.

#### 4.2.2.1. Zaman serilerinin ayrıştırma sonuçları

Zaman serilerinin ayrıştırma yöntemi özellikleri 15. sayfada detaylı olarak açıklanmıştır. Uygulama üzerinde kullanımı ise 40. sayfada gösterilmiştir. Burada da iki farklı durum için dört farklı model oluşturulmuştur ve Toplamsal Sezonsal (TS), Toplamsal Eğilim Sezonsal (TES), Çarpımsal Sezonsal (ÇS), Çarpımsal Eğilim Sezonsal (ÇES) olarak ifade edilmektedirler (Şekil 4.9.).



Şekil 4.9. Yıl öncesi aylık talep tahmininde günlük veri üzerinden zaman serilerinin ayrıştırmasının sonuçları

Şekil 4.9.'da görüldüğü üzere TS ve TES ilk iki ay tahmininde bu bandın içinde ve civarında kalmıştır. TS, TES, ÇS ve ÇES'in 2014 yılı için yaptıkları tahminin MAPE'leri ve R<sup>2</sup> değerleri sırasıyla %16,8, %14,8, %16,2, %14 ve 0,9636, 0,9688, 0,9653, 0,9731 olmuştur. Zaman serilerinin ayrıştırma metodu için ÇES modelinin hem MAPE hem de R<sup>2</sup> değerler üzerinden en iyi sonuçları verdiği görülmektedir.

#### 4.2.2.2. Holt-Winters üstel düzeltirme sonuçları

Holt üstel düzeltirme yöntemi için  $\alpha$  ve  $\beta$  parametreleri 0,2 olarak ve optimize edilmiş halde sonuçları bulunmuştur. Optimizasyon sonrasında tahmin sonuçlarında iyileşmeler görülmüştür ve  $\alpha=1$ ,  $\beta=0,0057$  bulunmuştur. Yöntem sezonsallığı barındırmaması sebebiyle iki modelde de MAPE'ler çok yüksek ve R<sup>2</sup> değerleri çok düşüktür. 2014 yılı tahmininde  $\alpha$ ,  $\beta=0,2$  ve optimize edilmiş durumdaki MAPE ve R<sup>2</sup> değerleri sırasıyla %3233, %740 ve 0,035, 0,038 olarak bulunmuştur.

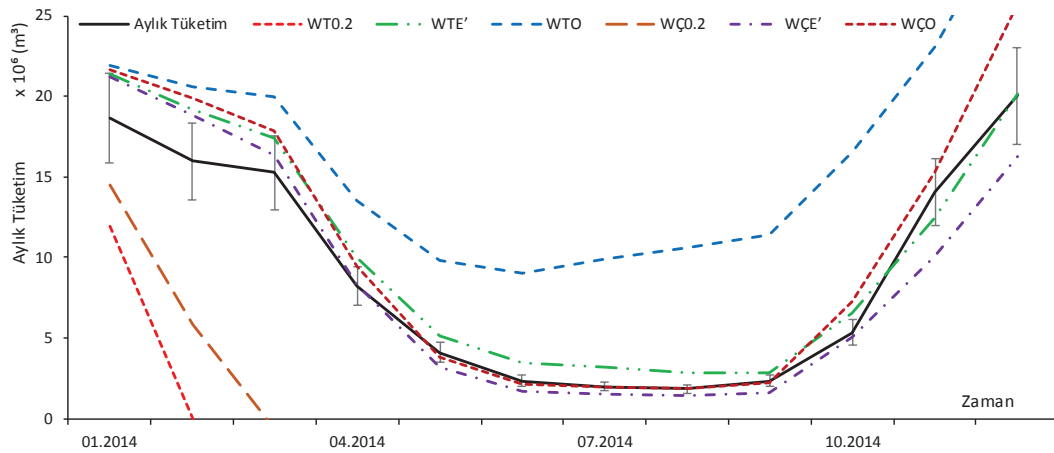


Holt-Winters üstel düzeltirme yönteminde eklenen  $\gamma$  parametresi, modelin sezonsallığı da içermesini sağlamıştır. Holt-Winters üstel düzeltirme yöntemi için sezonsallığın toplamsal ve çarpımsal modelleri mümkün olabilmektedir. Tablo 4.5.'de Winters üstel düzeltirme yönteminin sonuçları gösterilmiştir.

Tablo 4.5. Günlük tüketim ve Winters üstel düzeltirme yöntemi ile aylık tahmin sonuçları

	Yöntem	Kısaltması	Parametre değerleri	MAPE (%)	R <sup>2</sup>
Toplamsal	$\alpha, \beta, \gamma = 0,2$	WT0.2	$\alpha, \beta, \gamma = 0,2$	1858	0,1113
Model	Eğilimsiz	WTE'	$\alpha=0,9797, \gamma=0,0004$	25,7	0,9721
	Optimize edilmiş	WTO	$\alpha=0,9916, \beta=0,02, \gamma=0,062$	179,8	0,8562
Çarpımsal	$\alpha, \beta, \gamma = 0,2$	WÇ0.2	$\alpha, \beta, \gamma = 0,2$	243,1	0,1314
Model	Eğilimsiz	WÇE'	$\alpha=0,9797, \gamma=0,0004$	18,3	0,9265
	Optimize edilmiş	WÇO	$\alpha=0,9916, \beta=0,02, \gamma=0,062$	14,4	0,9905

Sonuçlarda parametrelerin 0,2 olduğu durumda hataların en yüksek olduğu görülmektedir. Eğilimsiz çarpımsal modelde ( $\beta=0$ ) hatalar eğilimli modele göre daha yüksektir. Fakat eğilimsiz toplamsal modelde hatalar eğilimli modele göre daha düşüktür. Bu durumda modeldeki eğilim olmasından dolayı çarpımsal modelin daha iyi sonuç verdiği görülmektedir. Şekil 4.10.'da Winters üstel düzeltirme yönteminin sonuçları gösterilmiştir.



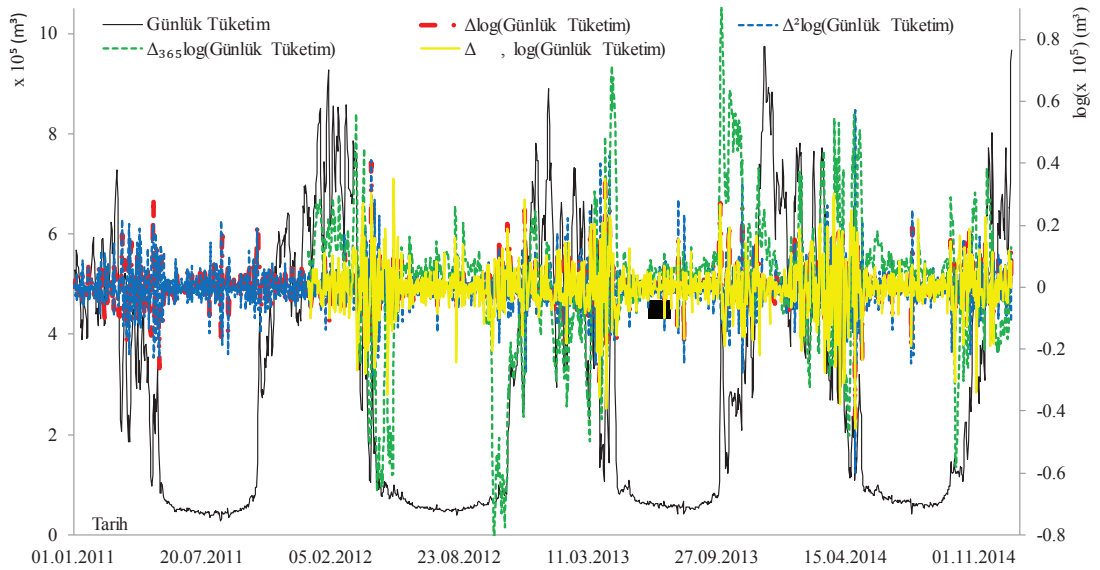
Şekil 4.10. Yıl öncesi aylık talep tahmininde günlük veri üzerinden Winters üstel düzeltirme yöntemi sonuçları

Optimize edilmemiş parametrelerin ilk 2 aydan sonra sınırların dışına çıktığı görülmektedir. WTO modelinin de çok yüksek sapma ile tahmin ettiği belirlenmiştir.

Diğer hazırlanan modellerin tahminde yaklaşık sonuçlar verdiği görülmektedir. Tablo 4.5.'de görülen yüksek  $R^2$  değerleri ( $>0,9$ ) şeklindeki sonuçları doğrulamaktadır.

#### 4.2.2.3. ARIMA/SARIMA yöntemi sonuçları

ARIMA/SARIMA yöntemleri tıpkı aylık veri ile aylık tahminde olduğu gibi günlük veri için de hazırlanmıştır. Günlük doğal gaz tüketimi de durağan değildir (Şekil 4.11.). Serinin durağanlaştırılması için öncelikle logaritması alınır. Böylece serideki uç noktalar belirli bir aralığa indirgenmiş olur. Daha sonra serinin farkları alınarak durağan seri elde edilir. Aylıkta olduğu gibi oluşan yeni seride AR, MA, SAR (sezonsal AR) ve SMA (sezonsal MA) parametreleri belirlenir.



Şekil 4.11. Günlük doğal gaz tüketimi ve fark alma sonucu doğal gaz tüketimi

Günlük veride sezonsal fark 365 gün olarak alınmıştır ve kendinden 365 gün önceki değer ile arasındaki fark “ $\Delta_{365}$ ” ile gösterilmektedir. Hazırlanan tüm serilerde farkları alınmış seriler şu şekilde ifade edilir;

- İlk farklar serisi;  $\Delta\log(\text{Aylık Tüketim})$ ; I(1)1 or ARIMA(0,1,0)1
- İkinci dereceden farklar serisi;  $\Delta^2\log(\text{Aylık Tüketim})$ ; I(2)1, ARIMA(0,2,0)1

- İlk sezonsal farklar serisi;  $\Delta_{365}\log(\text{Aylık Tüketim})$ ;  $I(0)1(1)$ ,  $\text{ARIMA}(0,0,0)1(0,1,0)^{365}$
- İlk fark ve ilk sezonsal farklar serisi;  $\Delta_{365,1}\log(\text{Aylık Tüketim})$ ;  $I(1)1(1)$ ,  $\text{ARIMA}(0,1,0)1(0,1,0)^{365}$

şeklinde ifade edilmektedir.

Şekil 4.11.'deki aylık tüketimden farklı olarak ilk fark alındığında sezonsallığın olmadığı görülmektedir.  $I(2)1$ ,  $I(0)1(1)^{365}$  ve  $I(1)1(1)^{365}$  serilerinde de sezonsallık olmadığı şekil üzerinden belirlenmiştir. Oluşan fark alınmış serilerin tanımlayıcı istatistikleri Tablo 4.6.'da gösterilmiştir. Doğal gaz tüketim serisinin logaritması alınarak 4,443 ile 5,989 aralığına indirgenmiş olur. Böylece ortalaması ve standart sapması sıfıra yakın seriler fark alma işlemleri sonucunda bulunabilmektedir.

Tablo 4.6. Fark alınmış serilerin tanımlayıcı istatistikleri

<i>Değişken</i>	<i>Gözlem Sayısı</i>	<i>Minimum</i>	<i>Maksimum</i>	<i>Ortalama</i>	<i>Std. Sapma</i>
<i>Günlük Tüketim</i>	1461	27765	974960	290914	252416,7
<i>I(0)I(0)</i>	1461	4,44349	5,988987	5,253828	0,453635
<i>I(1)1</i>	1460	-0,42328	0,402571	0,000202	0,061085
<i>I(2)1</i>	1459	-0,59924	0,570782	0,000005	0,078176
<i>I(0)I(1)<sup>365</sup></i>	1096	-0,86111	0,908935	0,020006	0,231417
<i>I(1)I(1)<sup>365</sup></i>	1095	-0,45898	0,351911	0,000023	0,085488

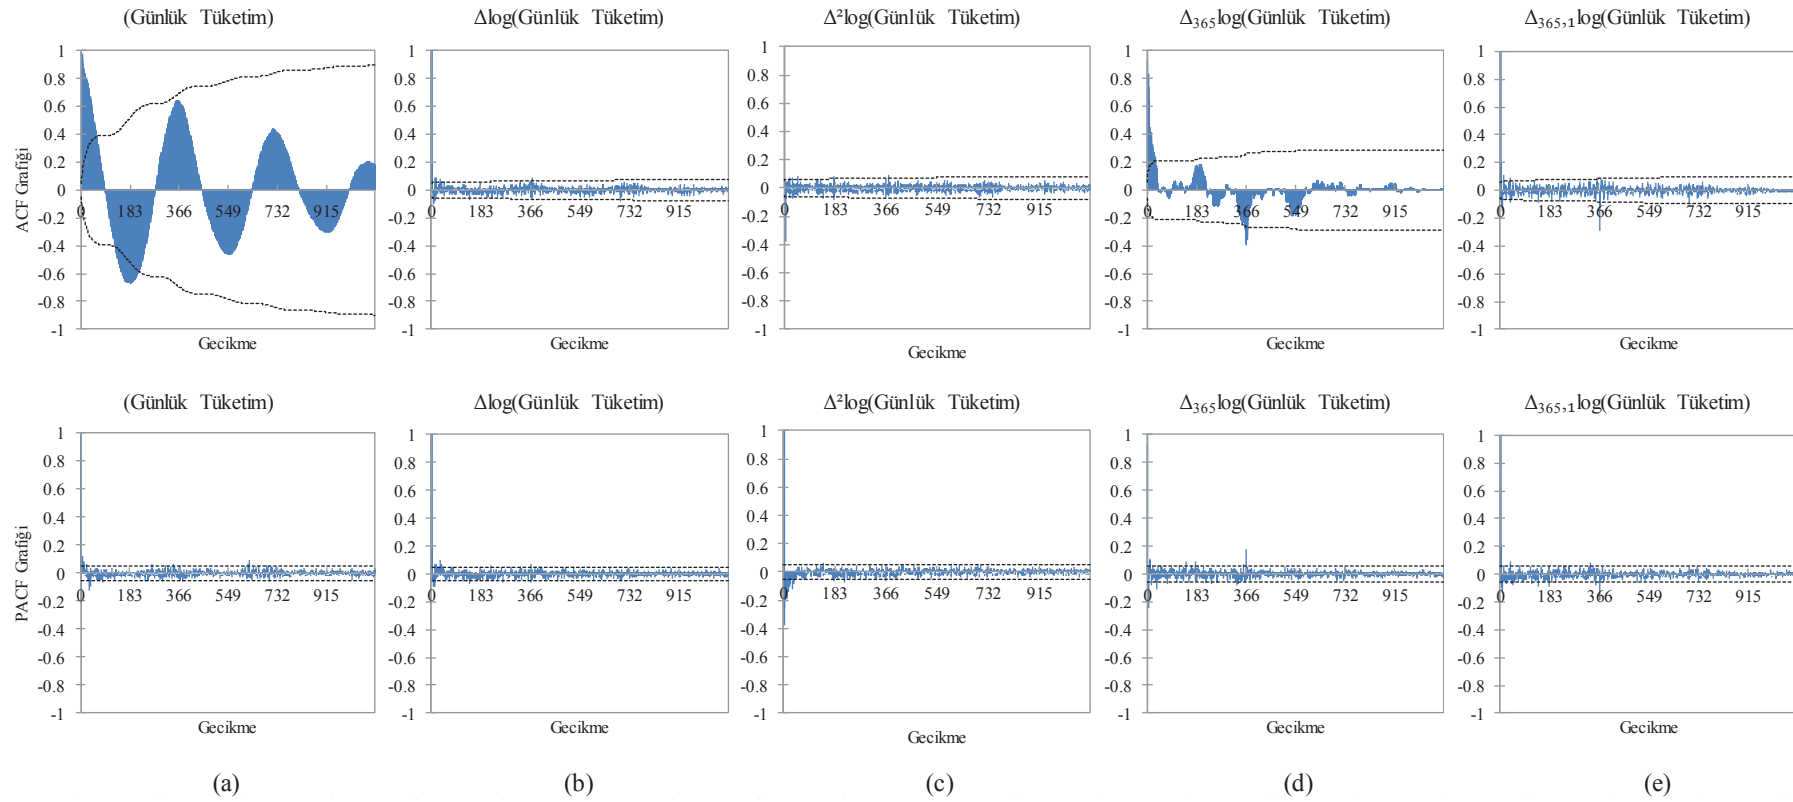
Serilerin durağanlıkları gözle görülmesine rağmen bulunla ilgili ADF ve PP testleri yapılmıştır ve sonuçları Tablo 4.7.'de gösterilmiştir. Anlamlılık düzeyi olan p olasılığı 0,05 olarak alınmıştır ve p değeri bu değer altında ise seri durağandır denir. Birim kök sınaması sabit ve eğilim olmadan (yok durumu), sadece sabit olma durumu (s) ve sabit ile eğilim olma durumu için (S+E) gerçekleştirilmiştir. Test sonuçlarına göre ADF testi üzerinden düşünülürse günlük tüketim serisi ve logaritması alınmış hali de durağan seri olarak tanımlanabilmektedir. Fakat PP testine göre günlük tüketimin düzenlenmemiş ilk hali dışındaki durumlarda serinin durağan olduğu görülmüştür.

Tablo 4.7. Tüketim serilerinin durağanlık test sonuçları

	ADF test			PP test		
	Yok	S	S+E	Yok	S	S+E
Günlük Tüketim	0,0251	0,0045	0,025	0,1403	0,0556	0,2014
I(1)1	0,000	0,000	0,000	0,000	0,000	0,000
I(2)1	0,000	0,000	0,000	0,0001	0,0001	0,0001
I(0)I(1) <sup>365</sup>	0,000	0,000	0,000	0,000	0,000	0,000
I(1)I(1) <sup>365</sup>	0,000	0,000	0,000	0,000	0,000	0,000

Şekil 4.12.'de günlük doğal gaz tüketiminin ACF be PACF grafikleri gösterilmiştir. Burada tüketim serisindeki sezonsal örüntü rahatlıkla görülmektedir. Fakat fark işlemi sonrasında oluşturulmuş serilerde durağanlık görülmektedir. Sezonsal fark alınmış serinin başlangıç, 183. gün, 365. gün ve 549. gün civarında ilişki olduğu görülese bile bunlardan 365. gündeki gecikmenin anlamlı olduğu rahatlıkla görülebilmektedir. Genel olarak durağan serilerde senelik olarak anlamlı ilişki olduğu grafiklerde kendini göstermektedir.

Yapılan bu durağanlaştırma çalışmaları sonucunda I(1)1, I(2)1, I(0)1(1) ve I(1)1(1) serilerinin durağan olduğu görülmüştür. Bu aşamadan sonra durağanlaştırılan seri üzerinde ARIMA/SARIMA yöntemi uygulanmıştır. Yöntemdeki AR, MA kısımlarının sezonsal ve sezonsal olmayan katsayıları, sıfır ile üç arasında farklı değerler için bulunmaya çalışılmıştır. Böylece oluşturulmaya uygun her seri için en fazla 256 farklı tahmin modeli kurulmuştur. Bu modellerden bazılarının fark almadan dolayı katsayıları yetmemiştir. Örneğin çift fark alınmasından dolayı I(1)1(1) serisinde ARIMA(0,1,0)1(1,1,3) modeli kurulamayacaktır. Çünkü kendisinden önce iki sezonsal seri bulunmaktadır. Yani sezonsal fark alınmış modellerde sezonsal parametreler en fazla iki olabilmektedir. ARIMA/SARIMA yönteminde dört farklı ölçüt için en iyi tahmin sonuçları bulunmuştur. 2011-2013 arası MAPE ve  $R^2$ , 2014 yılı MAPE<sub>2014</sub> ve  $R^2_{2014}$  şeklinde gösterilmiştir (Tablo 4.8.). Tablodaki tanımda Günlük veri ile Aylık tahmin için "GA" kullanılmıştır. Sonrasında günlük veri ile en düşük hataya sahip olan günlük tahminler veya günlük tahminlerin aylık veriye dönüştürülerek aylık en düşük tahmini bulunabilmektedir. Her iki yöntem için tahminlerin durumu incelenmiştir. Böylece "GA" ifadesi "GAA" ve "GAG" olabilmektedir. "GAA" günlük veri üzerinden aylık veriye dönüştürülerek bulunan




Şekil 4.12. Logaritmik dönüştürülmüş ve farkları alınmış tüketimlerin ACF ve PACF grafikleri

modelleri, “GAG” ise günlük veri üzerinden bulunan modellerin aylık sonuçlarını göstermektedir. Sonrasında ise GAAx veya GAGx şeklinde ifade edilmiştir. Buradaki x modelin numarasıdır ve detay parametre değerleri tabloda görülmektedir. 2011-2013 arasındaki seride  $R^2$  ve MAPE aynı modelin en iyi tahminde bulunabileceğini öngörürken, 2014 yılında yapılan tahminlere bakıldığında durum değişmektedir. GAA modelleri üzerinden yapılan incelemede 2014 yılı için yapılan tahminlerdeki en iyi durumlarda sadece sezonsal fark bulunmaktadır. Bunun tam tersine GAA modellerinde 2011-2013 yılları arasında en iyi model sadece ilk farklarda oluşmaktadır. Fakat ilk farklarda kurulan modelin sezonsallık içermemesinden dolayı hata oranı yüksek ve belirleme katsayısı düşüktür. Şekil 4.12.’de gösterilen b grafiğinde ilk fark alınmış serinin ACF ve PACF grafikleri görülmektedir. Bu grafikler üzerinde bile sezonsal ilişkinin anlamlı olduğu güvenlik bandını geçen ACF ve PACF değerleri ile görülmektedir. Seri ne kadar durağan olursa olsun sezonsal farkın alınmaması tahmin hatasının yüksek olmasına sebep olacaktır. Diğer taraftan GAA2 ve GAA3 modellerinde sezonsal fark bulunmaktadır. Bunun dışında sezonsal fark alınmış ACF grafiğinde bir sonraki dönemde anlamlı değer olması ARIMA yöntemindeki SMA değerinin sıfırdan farklı, hatta bir olacağını göstermektedir. Sezonsal fark alınmış serinin PACF grafiğinde de bir sonraki döneme ait anlamlı ilişki olduğu görülmektedir. Bu da SAR değerinin sıfırdan farklı, hatta bir olacağını göstermektedir. Tahminde en iyi sonucu veren ARIMA modellerinin de buna uygun olarak en düşük hata ve en yüksek belirleme katsayısına sahip olduğu görülmektedir (ARIMA(1,0,1)1(1,1,1)<sup>365</sup> ve ARIMA(0,0,0)1(0,1,1)<sup>365</sup> modelleri). GAA modelleri için anlatılan durumun benzeri GAG modelleri için de geçerlidir. Her ikisinde de günlük veri üzerinden tahmin yapılması, GAG modellerinde de sezonsal fark alınmış tahminlerin daha doğru sonuç vereceğini göstermektedir. Sezonsal fark alınmış ACF grafiğinde bir sonraki dönemde anlamlı değer olması ARIMA yöntemindeki SMA değerinin sıfırdan farklı, hatta bir olacağını göstermektedir. PACF grafiğinde ise ACF grafiğine göre daha az sayıda anlamlı değer olması SAR kısmının öneminin SMA’ya göre daha düşük olduğunu göstermektedir. GAG modellerinde de bir sezonsal fark alınması ile oluşturulan modellerin sezonsal olmayan ilk farklara göre çok daha iyi sonuç verdiği rahatlıkla gözlenmiştir.

Tablo 4.8. ARIMA/SARIMA yöntemi için en iyi sonuçlar ve tahmin hata durumları

Kriter	Tanım	Parametre değerleri	MAPE (%)	R <sup>2</sup>
MAPE	GAA1	ARIMA(1,1,0)1(0,0,1) <sup>365</sup>	378,48	0,472695
MAPE <sub>2014</sub>	GAA2	ARIMA(1,0,1)1(1,1,1) <sup>365</sup>	11,84	0,981988
R <sup>2</sup>	GAA1	ARIMA(1,1,0)1(0,0,1) <sup>365</sup>	378,48	0,472695
R <sup>2</sup> <sub>2014</sub>	GAA3	ARIMA(0,0,0)1(0,1,1) <sup>365</sup>	12,01	0,991281
MAPE	GAG1	ARIMA(1,1,0)1(2,0,3) <sup>365</sup>	641,57	0,785569
MAPE <sub>2014</sub>	GAG2	ARIMA(0,0,1)1(0,1,1) <sup>365</sup>	11,91	0,991191
R <sup>2</sup>	GAG3	ARIMA(3,1,1)1(0,0,0) <sup>365</sup>	434,14	0,041042
R <sup>2</sup> <sub>2014</sub>	GAG2	ARIMA(0,0,1)1(0,1,1) <sup>365</sup>	11,91	0,991191

Şekil 4.13.'de yıl öncesi aylık talep tahminin günlük veri üzerinden ARIMA/SARIMA sonuçları gösterilmiştir.



Şekil 4.13. Yıl öncesi aylık talep tahmininde günlük veri üzerinden ARIMA/SARIMA sonuçları

GAA1, GAG1 ve GAG3 sonuçları sezonsal tahmin performansı sergileyememiştir. Bunun temel sebebi sezonsal farkın olmayışdır. Hata oranlarının yüksek ve belirleme katsayısının düşük olması grafik ve tablonun örtüşüğünü göstermektedir. GAA2, GAA3 ve GAG2 modellerinde ise her ay için hata oranı %15 güven bandının içinde kalmıştır. Tahminlerin tüm seri için güven bandı sınırları içinde olduğu belirlilik katsayısının 0,99'un üzerinde olmasından görülmektedir. Böylece günlük

veri kullanılarak yapılan tahminlerde önce aylık veriye dönüştürülerek hataların belirlenmesinin, günlük tahminler üzerinden hataların belirlenmesine göre daha uygun kıstas olduğu görülmüştür. Diğer bir ifade ile günlük tahminler üzerinden bir yıllık hata oranının düşük olması, aylık tahminde de düşük olacağını göstermiştir fakat günlük tahminlerin aylık hale getirildikten sonra hatalarının belirlenmesi daha iyi performans sergilemiştir.

#### 4.2.3. Yıl öncesi aylık talep tahmininin genel değerlendirilmesi

Yıl öncesi aylık doğal gaz talep tahmini her yıl yapılan sözleşmelerde aylık olarak belirlenen değerlerdir. Sözleşmeler içinde talep tahminlerinin bulunması, tez çalışmasının bu aşamasının önemini ortaya koymaktadır. Buna göre yıl öncesi aylık talep tahmini için farklı veri frekanslarında yıl öncesi talep tahmini gerçekleştirilmiştir. Aylık veri kullanılarak yapılan çalışmalardan zaman serilerinin ayrıştırmasında TES ve ÇES modellerinin en iyi sonuç verdiği görülmüştür. Bu modeller sırasıyla %15,06, %15,14 MAPE ve 0,9695, 0,9718  $R^2$  değerlerine sahip olmuştur. ÇES modelinin TES modeline göre yaz mevsiminde daha iyi olduğu gözlenmiştir. Winters üstel düzleştirme yönteminde ise TWO modeli %14 MAPE ve 0,9846  $R^2$  ile en iyi sonucu vermiştir. TWO modeli genel olarak %15 bandında kalarak iyi performans sergilemiştir. ARIMA/SARIMA yönteminde ise en iyi sonucu hem sezonsal fark hem de ilk fark alınmış seri üzerinden yapılan tahmin vermiştir (AA2). AA2 modeli  $ARIMA(1,1,1)I(0,1,1)$ 'dir ve %12,89 MAPE, 0,9841  $R^2$  değeri ile ilk iki ay dışında düşük hatalı performans sergilemiştir. Günlük veri kullanılarak yapılan çalışmalarda ise zaman serilerinin ayrıştırması yönteminde ÇES modeli %14 MAPE ve 0,9731  $R^2$  olarak tahminde bulunmuştur ve ilk iki ay kötü performans sergilemiştir. Winters üstel düzleştirme yönteminde ise MAPE ve  $R^2$  değerleri sırasıyla %14,4 ve 0,9905 olmuştur. Ekim ve aralık aylarında kötü performans sergilemiştir. Günlük yapılan ARIMA tahminlerde sonuçların gösterilmesi iki farklı şekilde olabilir. Bunlardan ilki, günlük olarak tahminler gerçekleştirildikten sonra serileri aylık hale getirerek MAPE ve  $R^2$  değerini bulmak; ikincisi ise günlük olarak tahminlerde yine günlük olarak MAPE ve  $R^2$  bulmaktır. İlk durumdaki modeller GAA, ikinci durumundaki modeller GAG ile gösterilmiştir. Burada üç farklı durum



en iyi performansı sergilemiştir. Bunlar sırasıyla GAA2 (ARIMA(1,0,1)1(1,1,1)<sup>365</sup>), GAA3 (ARIMA(0,0,0)1(0,1,1)<sup>365</sup>), GAG2 (ARIMA(0,0,1)1(0,1,1)<sup>365</sup>)'dir. Bu modeller sırasıyla %11,84, %12,01, %11,91 MAPE ve 0,981988, 0,991281, 0,991191 R<sup>2</sup> değerlerine sahiptirler. Burada GAA2 modeli her ne kadar en düşük MAPE'yi verse de R<sup>2</sup> değeri diğer iki modele göre daha düşüktür. Hatta tahmin serisinde Aralık ayı içi sınır dışına çıkmıştır. GAA3 ve GAG2 modelleri ise yazın az miktarda sınırın dışında kalmıştır. Kışın sınır dışına çıkmaktansa yazın sınırın dışında çıkmak daha olumludur. Bunun sebebi kışın doğal gaz talebinin arzına göre daha fazla olmasıdır. Yazın ise arz fazla, talep düşüktür ve eksik gaz talep edildiği anda tedarik edilebilir.

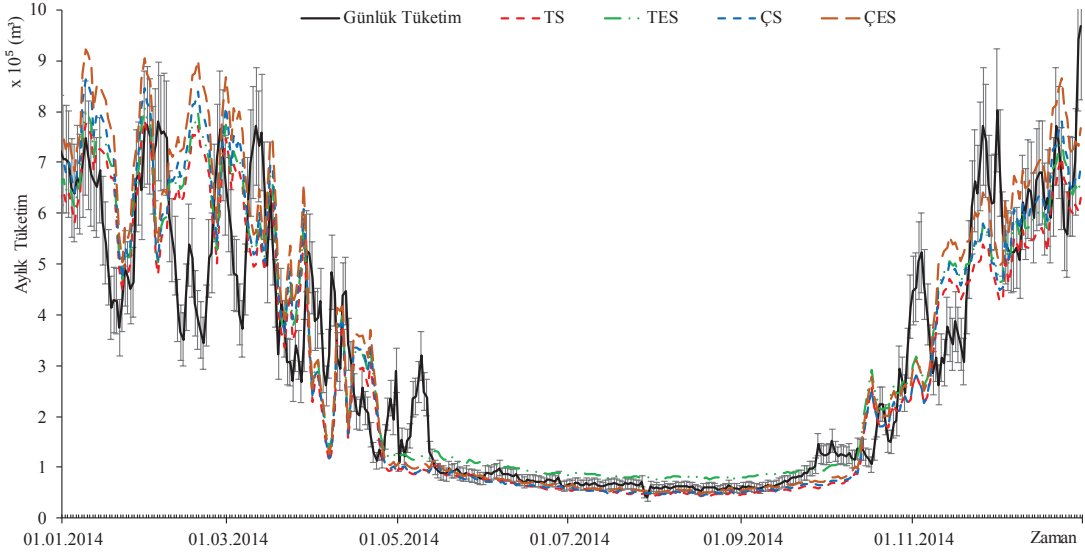
### 4.3. Gün Öncesi Talep Tahmini ve Sonuçları

Çalışmanın bu aşamasında gün öncesi günlük talep tahmini üzerine çalışılmıştır. Günlük tüketim verisi de aylık tüketim gibi mevsimsel değişim göstermektedir. Şekil 4.2.'de günlük tüketimin davranışı gösterilmiştir. Aylık talep tahmininde 36 ay kullanılarak 12 ay tahmin edilmeye çalışılırken gün öncesi talep tahmininde 1096 gün kullanılarak 365 gün tahmin edilmeye çalışılmıştır. Bu kısımda aylık talep tahmininde günlük veri kullanılarak yapılan çalışmadaki günlük talep tahmin sonuçları gösterilmiştir. Buna bağlı olarak zaman serilerinin ayrıştırma, Winters üstel düzleştirme ve ARIMA/SARIMA yöntemlerinin sonuçları günlük olarak gösterilecektir. Bu çalışmaların dışında kayan pencere yöntemi kullanılarak farklı tahmin çalışmaları yapılmıştır. Kayan pencere yöntemini kullanan çalışmalarda yapay sinir ağları üzerine iki farklı eğitim ile gün öncesi talep tahmini ve Winters üstel düzleştirme yöntemi kullanılarak talep tahmini gerçekleştirilmiştir.

#### 4.3.1. Zaman serilerinin ayrıştırma sonuçları

Daha önce günlük veri ile aylık tahminin sonuçları 4.2.2.1. bölümde gösterilmiştir. Bu bölümde aylık hale getirilmeden günlük haldeki tahminler ile 2014 yılı tahmin edilmeye çalışılmıştır. Buna göre zaman serilerinin ayrıştırma sonuçları TS, TES, ÇS ve ÇES için sırasıyla %26,23, %29,47, %26,95, %27 MAPE ve 0,8028, 0,8053,

0,7989, 0,8039  $R^2$  olmuştur. Tahmin grafiği olan Şekil 4.14.'de zaman serilerinin ayrıştırma yöntem sonuçları görülmektedir. Tahmin serisi ve hata durumlarına bakıldığında tüm modellerin eş değer sonuçlar verdiği görülmektedir.



Şekil 4.14. Gün öncesi talep tahmininde zaman serilerinin ayrıştırmasının sonuçları

#### 4.3.2. Holt-Winters üstel düzleştirme sonuçları

Holt üstel düzleştirme yöntemi için  $\alpha$  ve  $\beta$  parametreleri 0,2 olarak ve optimize edilmiş halde sonuçları bulunmuştur. Optimizasyon sonrasında tahmin sonuçlarında iyileşmeler görülmüştür ve  $\alpha=1$ ,  $\beta=0,0057$  bulunmuştur. Yöntem sezonsallığı barındırmaması sebebiyle iki modelde de MAPE'ler çok yüksek ve  $R^2$  değerleri çok düşüktür. 2014 yılı tahmininde  $\alpha$ ,  $\beta=0,2$  ve optimize edilmiş durumdaki MAPE ve  $R^2$  değerleri sırasıyla %3417, %791 ve 0,033, 0,033 olarak bulunmuştur.


Holt-Winters üstel düzleştirme yönteminde eklenen  $\gamma$  parametresi sezonsallığı da içermesini sağlamıştır. Holt-Winters üstel düzleştirme yöntemi için sezonsallığın toplamsal ve çarpımsal modelleri mümkün olabilmektedir. Tablo 4.9.'da Winters üstel düzleştirme yönteminin sonuçları gösterilmiştir. Bu tablodaki parametrelerin değerleri Tablo 4.5.'deki değerler ile aynıdır. Buradaki fark günlük veriler aylık olarak dönüştürülmemiş ve günlük tahminde kullanılmıştır. Sonuçlarda parametrelerin 0,2 olduğu durumda hataların en yüksek olduğu görülmektedir.

Eğilimsiz modellerde ( $\beta=0$ ) hataların eğilimli modellere göre daha düşük olduğu görülmüştür. Bu durum modellerin geçmiş veride çok düşüğe olsa ( $\beta=0,02$ ) artan bir eğilim yakaladığını göstermektedir. Fakat bu eğilimin sonucu talep tahmininde yukarı yönde olmaktadır.

Tablo 4.9. Günlük tüketim ve Winters üstel düzleştirme yöntemi ile günlük tahmin sonuçları

	Yöntem	Kısaltması	Parametre değerleri	MAPE (%)	R <sup>2</sup>
Toplamsal	$\alpha, \beta, \gamma = 0,2$	WT0.2	$\alpha, \beta, \gamma = 0,2$	1962	0,1032
Model	Eğilimsiz	WTE'	$\alpha=0,9797, \gamma=0,0004$	39,5	0,8149
	Optimize edilmiş	WTO	$\alpha=0,9916, \beta=0,02, \gamma=0,062$	197,4	0,7227
Çarpımsal	$\alpha, \beta, \gamma = 0,2$	WÇ0.2	$\alpha, \beta, \gamma = 0,2$	251,7	0,1047
Model	Eğilimsiz	WÇE'	$\alpha=0,9797, \gamma=0,0004$	26,9	0,7782
	Optimize edilmiş	WÇO	$\alpha=0,9916, \beta=0,02, \gamma=0,062$	27,1	0,8280

Şekil 4.15.'de Holt-Winters üstel düzleştirme yönteminin sonuçları gösterilmiştir.



Şekil 4.15. Gün öncesi talep tahmininde Winters üstel düzleştirme yöntemi sonuçları

Tablo 4.9.'da görüldüğü üzere parametrelerin 0,2 olduğu modellerin sonuçları üçüncü ay civarında eksi değerlere gitmektedir. Eğilimli modellerin Optimize edilmemiş parametrelerin ilk 2 aydan sonra sınırların dışına çıktığı görülmektedir. WTO modelinin de çok yüksek sapma ile tahmin ettiği belirlenmiştir. Toplamsal olan bu modelde eğilimin etkisi rahatlıkla görülebilmektedir. Eğilimsiz modellerden toplamsal modelin çarpımsal modele göre daha yüksek tahminler gerçekleştirdiği de

gözle görülebilecek kadar açıktır. WTE', WÇE', WÇO modellerinin tahminde yaklaşık sonuçlar verdiği görülmektedir. Tablo 4.9.'daki diğer modellere göre nispeten yüksek  $R^2$  değerleri şekildeki sonuçları doğrulamaktadır.


### 4.3.3. ARIMA/SARIMA yöntemi sonuçları

ARIMA/SARIMA yöntemi için yapılmış tahmin öncesi çalışmalar 4.2.2.3. ARIMA/SARIMA yöntemi sonuçları bölümünde açıklanmıştır. Bu bölümde aynı değerler kullanılarak gün öncesi tahmindeki performansları gösterilecektir. Burada GAG1 modeli GÖ1, GAG2 modeli GÖ2 ve GAG3 modeli GÖ3 şeklinde ifade edilmiştir. ARIMA/SARIMA yöntemi sonuçlarında en düşük MAPE %23,67 ve buna karşılık  $R^2$  değeri 0,8158 olarak bulunmuştur.

Tablo 4.10. ARIMA/SARIMA yöntemi için en iyi sonuçlar ve tahmin hata durumları

Kriter	Tanım	Parametre değerleri	MAPE (%)	$R^2$
MAPE	GÖ1	ARIMA(1,1,0)1(2,0,3) <sup>365</sup>	688,06	0,720086
MAPE <sub>2014</sub>	GÖ2	ARIMA(0,0,1)1(0,1,1) <sup>365</sup>	23,67	0,815801
$R^2$	GÖ3	ARIMA(3,1,1)1(0,0,0) <sup>365</sup>	467,75	0,028146
$R^2_{2014}$	GÖ2	ARIMA(0,0,1)1(0,1,1) <sup>365</sup>	23,67	0,815801


Şekil 4.16.'da gün öncesi talep tahmininin ARIMA/SARIMA yönteminde en iyi sonuçları gösterilmiştir. Tablo 4.10.'a uyumlu olarak GÖ1 ve GÖ3 modellerinin tahmin sonuçları gerçekleşen tüketimlere göre farklı noktalardadır. GÖ2 modelinin ise gün öncesi tüketim talep tahminine uygun model gerçekleştirebildiği rahatlıkla görülmektedir.



Şekil 4.16. Gün öncesi talep tahmininde günlük veri üzerinden ARIMA/SARIMA sonuçları

#### 4.3.4. Kayan pencere yöntemi sonuçları

Kayan pencere yönteminde tüm veri yerine, bir parçası alınarak sonuçlar bulunmaya çalışılmaktadır. Alınan parça her zaman adımında ilerlemekte fakat boyutu değişmemektedir. Böylece zamana bağlı olarak aynı boyda ama farklı tüketimlere sahip verisetleri oluşturulmuş olacaktır (Şekil 4.17.).



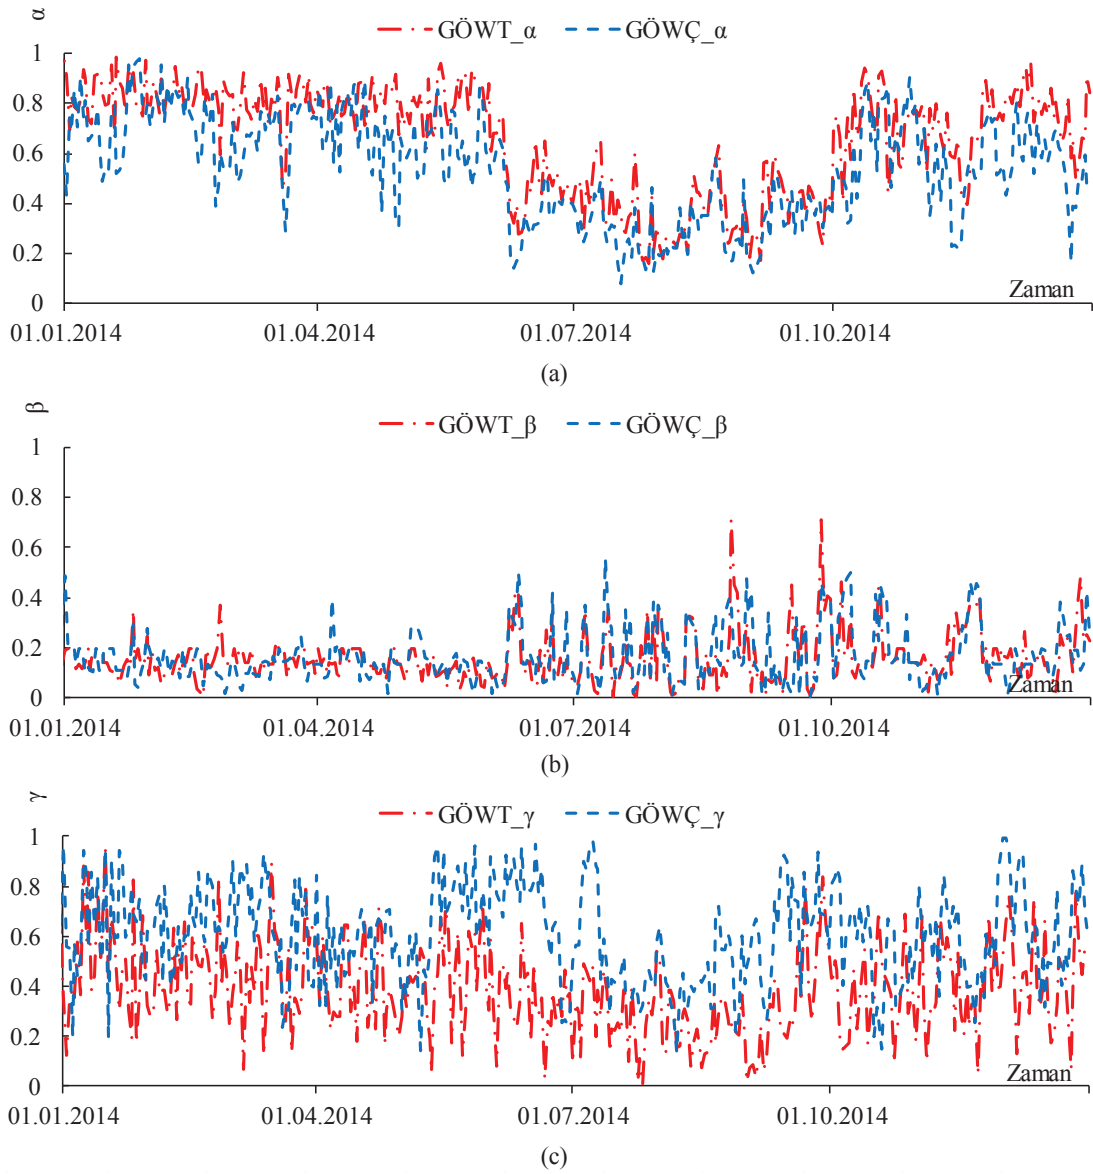
Şekil 4.17. Kayan pencere ve gün öncesi talep tahmini

Bu bölümde üç farklı tahmin metodu kullanılmıştır. Bunlar Winters üstel düzleştirme yöntemi, geri yayımlı yapay sinir ağları ve yapay arı kolonisi ile optimize edilmiş ileri beslemeli yapay sinir ağlarıdır. Bu üç yöntemin kendine has özellikleri bulunmaktadır. Bu bölümde detaylı olarak bahsedilecektir.

#### 4.3.4.1. Holt-Winters üstel düzleştirme yöntemi sonuçları


Gün öncesi talep tahmininde 365 günün bir anda tahmini yerine, tahmin edilecek güne en yakın günler üzerinden modelin kurulması daha uygundur. Bu yüzden 2011-2013 arasındaki tüketimi dörder haftalık tüketimlere ayırıp Winters üstel düzleştirme yönteminin uygulanmıştır. Böylece hatanın düşmesi beklenmektedir. Sezonallık içeren Winters üstel düzleştirme yönteminde en az 3 sezonsal çevrim bulunması gerekmektedir. Bu kısımda ise tahminlerin daha doğru yapılabilmesi için 4 haftalık tüketim, parametrelerin belirlenmesinde kullanılmıştır. 31.12.2013 tarihine kadar bulunan parametrelerin her gün için ortalaması alınarak 2014 yılındaki gün öncesi tahminler bulunmaya çalışılmıştır. Kısa bir örnek ile; 17.06.2011 tüketim tahmini 16.06.2011 tarihinde yapılmaktadır. Bu sebeple 16.06.2011 tarihinden önceki 19.05.2011 – 15.06.2016 tarihleri arasındaki tüketimler parametrelerin belirlenmesi için kullanılmıştır. 2014 tahmininde ise 17.06.2014 tüketim tahmini için 16.06.2011, 16.06.2012 ve 16.06.2013 tarihlerindeki  $\alpha$ ,  $\beta$ ,  $\gamma$  parametrelerinin ortalamaları üzerinden tahminler gerçekleştirilmiştir. Winters üstel düzleştirme yönteminin toplamsal ve çarpımsal biçimi bulunmaktadır. Her ikisi için de sonuçlar üretilmiştir.

Şekil 4.18.'de Winters üstel düzleştirme yönteminin 2014 yılı için parametrelerinin değişimi görülmektedir. Gün öncesi Winters toplamsal ve çarpımsal yöntemleri GÖWT ve GÖWÇ şeklinde kısaltılmıştır.  $\alpha$  parametresi kendisinden önceki değer ile ilişkisini göstermektedir ve bu yüzden ağırlığı seri boyunca yüksek olmuştur (Şekil 4.18.'in a grafiği). Toplamsal modelde 2014 yılı için  $\alpha$  parametresi ortalama 0,65 olurken, çarpımsal modelde ortalama 0,54 olmuştur.  $\beta$  parametresi ise eğilimi göstermektedir ve serideki eğilimin düşük olduğu görülmektedir (Şekil 4.18.'in b grafiği). Toplamsal ve çarpımsal modelde 2014 yılı için  $\beta$  parametresi ortalama 0,16 ve 0,17 olmuştur.  $\gamma$  parametresi ise sezonallığı ifade etmektedir. Dört haftalık geçmiş veri ile tahminin sezonsal yönden ne denli güçlü olduğunu göstermektedir (Şekil 4.18.'in c grafiği). Burada 2014 yılı için toplamsal ve çarpımsal  $\gamma$  parametresinin ortalaması 0,39 ve 0,6 olmuştur.



Şekil 4.18. Gün öncesi kayan pencere yöntemi Winters üstel düzleştirme parametrelerinin değişimi

Şekil 4.19.'da gün öncesi kayan pencere yöntemi Winters üstel düzleştirme sonuçları gösterilmiştir. Grafik üzerinde sarı bantlar %10 güven aralığını göstermektedir.



Şekil 4.19. Gün öncesi kayan pencere yöntemi Winters üstel düzleştirme sonuçları

Yapılan tahmin sonuçlarının önceki bölümlerdeki tahminlere göre çok daha iyi sonuç verdiği görülmektedir. Seri genelinde tahmin ile gerçekleşen tüketim arasındaki uyum çok iyidir. Çarpımsal ve toplamsal modelde her biri için üç farklı tarihli (çarpımsal modelde 15.03, 13.04, 10.05 – 2014, toplamsal modelde 14.02, 27.02, 22.05 – 2014) uç noktası bulunmaktadır. 2014 yılı için, GÖWT modelinde %16,9 MAPE bulunurken, GÖWÇ modelinde %15,02 MAPE bulunmuştur.  $R^2$  değerinde ise tam tersi durum söz konusudur. 2014 yılı için, GÖWT için 0,9377 olurken, GÖWÇ için 0,9066 olmuştur. MAPE'nin düşmesi  $R^2$  değerinin yükseleceği anlamına gelmeyeceği bu çözümde görülmektedir. Her ne kadar MAPE değeri çarpımsal modelde düşük olsa da toplamsal model tüketim tahminini tüm seri üzerine daha doğru yaymıştır.

#### 4.3.4.2. Yapay sinir ağları sonuçları

Tez kapsamında gün öncesi doğal gaz talep tahmini için yapay sinir ağları da kullanılmıştır. Çalışma kapsamında literatürde çok sık kullanılan geri yayılım algoritması içeren yapay sinir ağları (YSA-GY) ve ileri beslemeli yapay arı kolonisi ile optimize edilmiş yapay sinir ağları (YSA-YAK) kullanılmıştır.

İleri hesaplamalı YSA modelinde eğitim MSE hatasına göre bulunmaktadır. MSE değeri her dönemde (epoch) düşmektedir. Fakat geri yayılım algoritması



kullanıldığında fark alma işlemi yapılarak bulunan hata geriye yayılarak ağırlıklar güncellenir. Buradaki MSE değeri bilgi amaçlıdır. Doğal gaz talep tahmininde hata için MAPE kullanılmasından dolayı MSE değeri uygun eğitim için uygun olmamaktadır. MSE’de her hata kendi içinde oranlanmadığından kışın bulunan MSE değeri ile yazın bulunan MSE değerinin etkisi aynı olacaktır. MAPE’de ise her hata oranı ilgili veri için bulunmakta ve bunların ortalaması alınmaktadır. MAPE’nin diğer bir avantajı da mutlak değerinin alınmasıdır. Böylece negatif ve pozitif hatalar birbirini götürmez. Bu çalışma kapsamında evrensel minimum arandığı için eğitimde MAPE kullanıldığında 100 ile çarpmaya gerek yoktur. Eğitimde kullanılan diğer bir katsayı ise  $R^2$  değeridir. Eğitim ile gerçekleşme arasındaki ilişki bu katsayı ile belirlenir ve 0 ile 1 arasında değer alabilir. Değerin bire yaklaşması ilişkinin zayıf olduğunu, sıfıra yakın olması güçlü olduğunu göstermektedir.  $R^2$  değeri sayesinde tüm seri üzerindeki örtüşme görülebilmektedir. YSA-YAK eğitim aşamasında optimize edilmeye çalışılan parametreler MSE, MAPE ve  $R^2$  olmuştur.

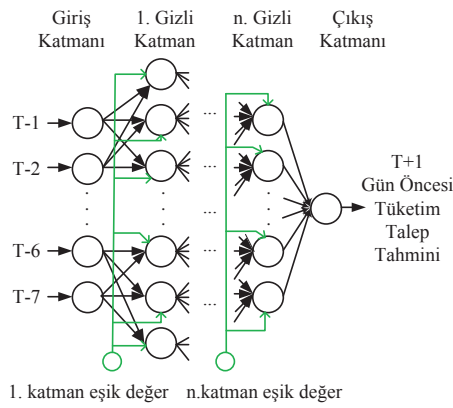
Gün öncesi doğal gaz talep tahmini için çeşitli senaryolar hazırlanmıştır. Bunlar iki farklı eğitim türüne göre ayrılmıştır. İlk grup geri yayılım algoritması ile eğitim olan YSA-GY, ikinci grup yapay arı kolonisi algoritması ile eğitim olan YSA-YAK’dır. Tüm eğitimler aynı sayıda nöron ve gizli katmanda gerçekleştirilmiştir. MSE, MAPE ve  $R^2$  değeri YSA-YAK’da eğitim için kullanılırken, YSA-GY’de yapısı gereği sadece TKH kullanılabilir fakat bilgi olması açısından MSE, MAPE ve  $R^2$  değeri de hesaplanmıştır. 01.01.2014-31.12.2014 tarihleri arasındaki tüketim ise test için kullanılmıştır. Diğer bir ifade ile 01.01.2011-31.12.2013 tarihleri arasında eğitilen ağ yapısı 2014 yılındaki 365 gün için gün öncesi talep tahmininde bulunmuştur. Tablo 4.11.’de YSA-GY ve YSA-YAK eğitiminde kullanılan parametrelerin değerleri gösterilmiştir.

Tablo 4.11. YSA eğitiminde kullanılan GY ve YAK algoritmalarının parametreleri

YAK parametreleri	Değer	GY parametreleri	Değer
Nektar alt sınır değeri	-10	Öğrenme katsayısı	0.2
Nektar üst sınır değeri	10	Momentum	0.8
Koloni boyutu	100	Ağırlık alt sınırı	-1
Yiyecek kaynak sınırı	365	Ağırlık üst sınırı	1

Bu tablodaki yiyecek kaynak sınırı bir yıl için günlük tahmin yapılmasından dolayı 365 olarak belirlenmiştir.

Gün öncesi talep tahmini için 01.01.2011-31.12.2013 tarihleri arasındaki tüketim değerleri eğitim aşamasında kullanılmıştır. Kullanılan YSA modeli Şekil 4.20.'de gösterilmiştir.



Şekil 4.20. Doğal gaz talep tahmini için hazırlanan YSA modeli

T. günde T+1. günün tahmini yapılması için T-7'den T-1'e kadar olan tüketimler YSA'ya giriş olarak verilmektedir. Diğer bir ifade ile tahmin günü, kendisinden önceki bir haftayı giriş olarak alarak kendisinden bir sonraki günü tahmin etmeye çalışmıştır.

Doğal gaz tüketim değerleri yapay sinir ağlarındaki aktivasyon fonksiyonunun alabileceği [0 1] olan değerlere göre çok büyüktür. Bu yüzden normalize edilmesi gerekmektedir. Normalize işlemi için [0,1 0,9] aralığı seçilmiştir. Böylece eğitim esnasında uç değerlerden daha yüksek veya düşük tahmin yapılabilecektir. Normalizasyon için Denklem (4.1) kullanılmıştır.

$$x_{i0.1-0.9} = 0.8x \left[ \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right] + 0.1 \quad (4.1)$$

Tablo 4.12.'de tüketimin kendisinin, [0-1] aralığında normalize edilmiş tüketimin ve [0,1-0,9] aralığında normalize edilmiş tüketimin tanımlayıcı istatistikleri gösterilmiştir.

Tablo 4.12. Günlük doğal gaz tüketimi ve normalize edilmiş doğal gaz tüketiminin tanımlayıcı istatistikleri

<i>Tanımlayıcı İstatistikler</i>	<b>Tüketim</b>	<b>Tüketim<sub>0-1</sub></b>	<b>Tüketim<sub>0,1-0,9</sub></b>
<i>Ortalama</i>	290,914	0.28	0.32
<i>Standart hata</i>	6,604	0.01	0.01
<i>Medyan</i>	202,069	0.18	0.25
<i>Mod</i>	45,254	0.02	0.11
<i>Standart sapma</i>	252,417	0.27	0.21
<i>Örneklem değişirlik</i>	63,714,170,871	0.07	0.05
<i>Basıklık</i>	-0.90	-0.90	-0.90
<i>Çarpıklık</i>	0.65	0.65	0.65
<i>Aralık</i>	947,195	1.00	0.80
<i>En düşük</i>	27,765	0.00	0.10
<i>En yüksek</i>	974,960	1.00	0.90
<i>Toplam</i>	425,025,317	405.89	470.82
<i>Gözlem sayısı</i>	1,461	1,461	1,461

Burada çarpıklık değeri sıfırdan büyüktür ve medyan ortalamadan küçüktür. Bu sağ kuyruklu seri olduğunu göstermektedir. Tüketimin düşük olduğu tarafta verilerin daha yoğun olduğu sonucu çıkartılabilir. Dört yıllık tüketim toplamı 425 milyon m<sup>3</sup> olmuştur ve tüketim aralığı yaklaşık 950.000 m<sup>3</sup>'dür.

Eğitim hatası bulunmadan önce, normalize edilen veriler gerçek tüketim değerlerine dönüştürülmüştür. Böylece eğitim esnasında optimize edilen hata değerleri gerçek tüketim verileri üzerinden hesaplanmıştır. Gerçek tüketim değerleri ile eğitimi yapılan ağlar için farklı yapılar tasarlanmıştır. Tek gizli katmanlı 20; 40; 60; 80 ve 100 nöronlu ağlar 500; 1000; 3000; 5000; 7000 ve 10000 dönemde (epoch) eğitilmiştir. YSA-GY için 30 farklı sonuç bulunurken, YSA-YAK için 90 farklı sonuç bulunmuştur. 2014 yılı gün öncesi doğal gaz talep tahmini için kullanılmıştır ve uygun performansa sahip ağ yapıları seçilmiştir. İlk aşamada uygun performans kriteri 2014 yılı için %20 MAPE ve daha düşük hataya sahip ağ yapılarıdır. MAPE'si %20 ve altında olan ağlar iki gizli katmanlı olarak tekrar tasarlanmıştır. Burada ilk gizli katmandaki nöron sayıları değiştirilmemiştir ve ikinci gizli katmanda 10'dan

60'a kadar onarlı arttırılarak ağ yapıları kurulmuştur. YSA-YAK eğitiminde MSE, MAPE,  $R^2$  ve YSA-GY eğitiminde MSE eğitimi için 120 farklı ağ yapısı oluşturulmuştur. Bu aşamada ise 2014 yılı için gün öncesi talep tahmini uygun performans kriteri %16 ve altında olan ağlar alınmıştır ve üç gizli katmanlı olarak tekrar tasarlanmıştır. Yeni tasarlanan yapıda iki gizli katmana 5, 15 ve 30 nöronlu üçüncü gizli katman eklenmiştir.

Performans kriterine göre farklı ağ yapılarında hazırlanan tasarım sayıları Tablo 4.13.'de gösterilmiştir.

Tablo 4.13. Performans kriterine göre hazırlanan ağ yapısı sayıları

<i>Gizli katman \ Dönem</i>	<i>500</i>	<i>1.000</i>	<i>3.000</i>	<i>5.000</i>	<i>7.000</i>	<i>10.000</i>
<i>Bir gizli katman</i>	5	5	5	5	5	5
<i>İki gizli katman</i>	6	12	6	12	18	6
<i>Üç gizli Katman</i>	-	-	3	3	12	9

Bir gizli katmanlı yapıda 5 farklı ağ yapısı tasarlanmıştır. Bu ağ yapıları 6 farklı dönem sayısına göre eğitilmişlerdir. İlk gizli katmanda %20 ve altında MAPE, MSE eğitiminde sadece 20 nöronlu YSA-YAK ağ yapısında, MAPE eğitiminde 20 ile 60 nöronlu YSA-YAK ağ yapısında,  $R^2$  eğitiminde 20 ile 40 nöronlu YSA-YAK ağ yapısı ile 2014 yılında gün öncesi talep tahminini gerçekleştirmişlerdir. Bir gizli katmanlı yapıda dönem ve nöron sayısı bazında %20 MAPE'nin altında olan ağ modelleri iki gizli katmanlı yapıda tekrar tasarlanmıştır. YSA-YAK için MSE, MAPE,  $R^2$  hatalarının her biri için 60, YSA-GY'de MSE için 60, toplam 240 ağ yapısı tasarlanmıştır. Buna göre 20+10, 20+30, 20+40 ve 20+60 nöronlara sahip ağ yapıları üç gizli katmanlı olarak tekrar tasarlanmıştır. YSA-YAK için her eğitim hatası modeli için 27 ağ yapısı tasarlanırken, YSA-GY için MSE eğitimde 27 ağ yapısı tasarlanmıştır. Tablo 4.13.'de görüleceği gibi en efektif çözüm 7.000 dönemli ağ yapılarında gerçekleşmiştir.

2014 yılı için gün öncesi doğal gaz talep tahmininde her ağ yapısında farklı eğitim hata türlerine göre ve dönem sayılarına göre sonuçlar değişmektedir. 2014 yılı için en düşük MAPE değerine sahip YSA modelleri Tablo 4.14.'de gösterilmiştir.

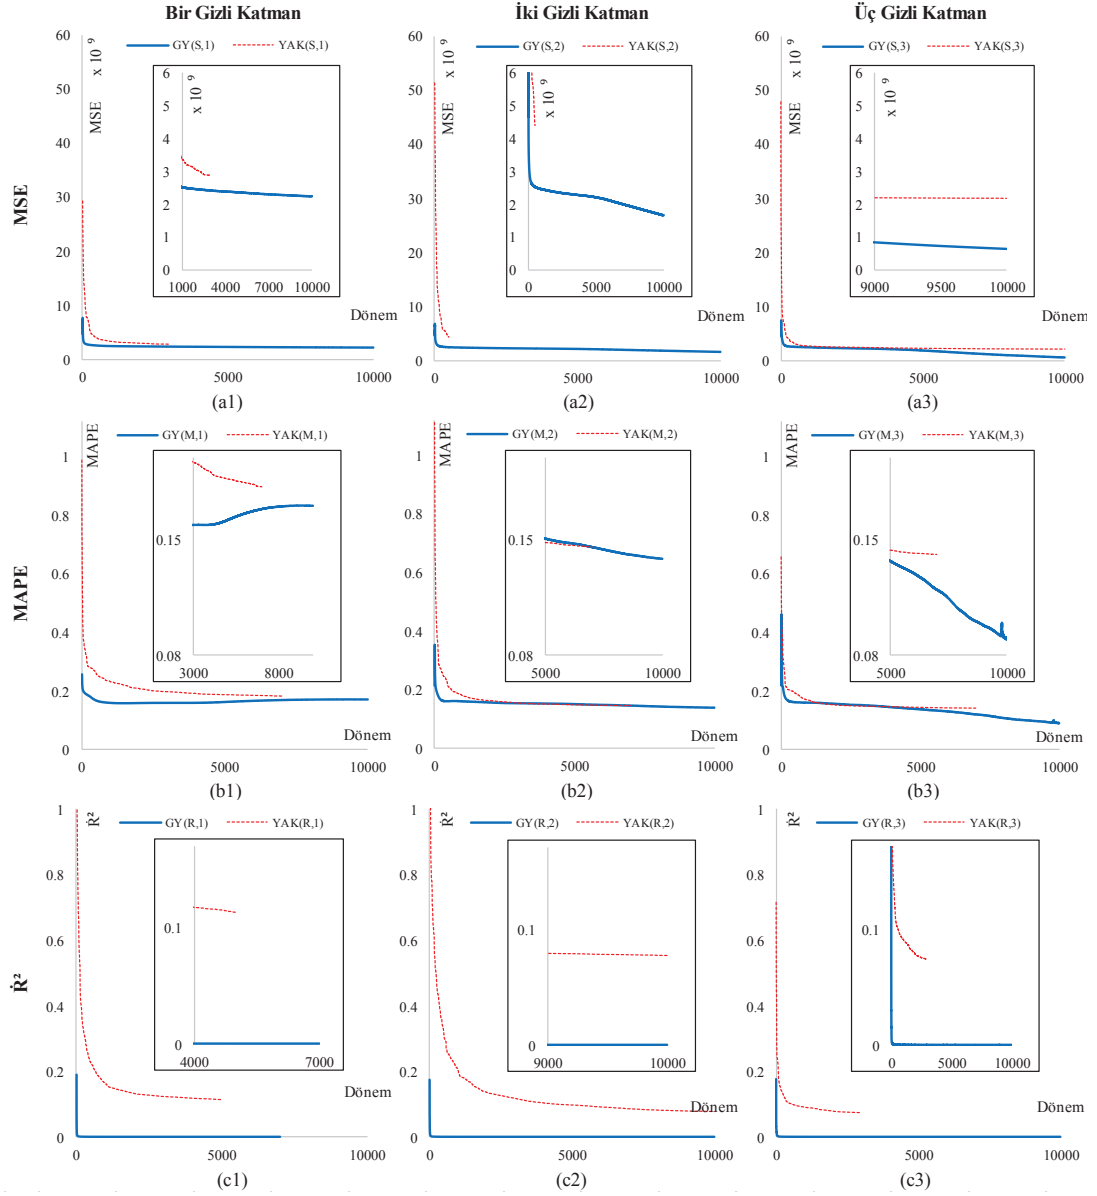
Tablo 4.14. En düşük MAPE'ye sahip ağ modelleri ve kısaltmaları

Ağ Yapısı ve Özellikleri		MSE		MAPE		$\bar{R}^2$	
		GY	YAK	GY	YAK	GY	YAK
Bir gizli katman	Nöron	40	20	20	20	20	40
	Dönem	1.000	3.000	10.000	7.000	7.000	5.000
	Kısaltması	GY(S,1)	YAK(S,1)	GY(M,1)	YAK(M,1)	GY(R,1)	YAK(R,1)
İki gizli katman	Nöron	20+50	20+40	20+30	20+20	20+60	20+60
	Dönem	10.000	500	10.000	7.000	10.000	10.000
	Kısaltması	GY(S,2)	YAK(S,2)	GY(M,2)	YAK(M,2)	GY(R,2)	YAK(R,2)
Üç gizli katman	Nöron	20+60+15	20+10+15	20+60+30	20+10+5	20+60+30	20+10+5
	Dönem	10.000	10.000	10.000	7.000	10.000	3000
	Kısaltması	GY(S,3)	YAK(S,3)	GY(M,3)	YAK(M,3)	GY(R,3)	YAK(R,3)

Kısaltmalarda X(Y,Z) ile ifade edilen terimlerden X; kullanılan eğitim yöntemini, Y; eğitimde kullanılan hata türünü (S: MSE, M: MAPE, R:  $\bar{R}^2$ ), Z ise gizli katman sayısını göstermektedir. En düşük MAPE sonucunu veren ağ yapılarında 500 dönemli 1 model, 1.000 dönemli 1 model, 3.000 dönemli 2 model, 5.000 dönemli 1 model, 7.000 dönemli 4 model ve 10.000 dönemli 9 model bulunmuştur.

En düşük MAPE değerlerine sahip ağ yapılarının 2011-2013 yıllarındaki tüketimi kullanarak gerçekleştirdikleri eğitimin dönemlere (epochlara) göre değişimi Şekil 4.21.'de gösterilmiştir. MSE kullanıldığında YSA-YAK modelindeki en düşük hata 500 dönemde gerçekleşirken YSA-GY modelinde 1.000 dönemde gerçekleşmiştir. Bulunan en düşük MSE değeri GY eğitim modelinde üç gizli katmanda 646.201.826,5 olurken, YAK eğitim modelinde üç gizli katmanda 2.185.385.306 olmuştur. GY algoritmasının eğitimde YAK algoritmasına göre 3,5 kat daha düşük MSE değerine sahip olduğu görülmüştür (Şekil 4.21.'in a3 grafiği). MAPE eğitim hata kriteri olarak kullanıldığında YSA-YAK tüm gizli katman modellerinde 7.000 dönemde, YSA-GY tüm gizli katman modellerinde 10.000 dönemde en düşük değerlere ulaşmıştır (Şekil 4.21.'in b grafikleri). En düşük eğitim MAPE değerleri her iki model yapısında da üç gizli katmanda olmuştur ve bu değerler YSA-GY için %8,94 olurken, YSA-YAK için %14,12 olmuştur (Şekil 4.21.'in b3 grafiği). Eğitim sonunda YSA-GY modelinin MAPE hata değeri YSA-YAK'ın neredeyse yarısı kadardır. En düşük dönem sayısı  $\bar{R}^2$  modelinde GY ve YAK modelleri için sırasıyla 7.000 ve 3.000 olmuştur (Şekil 4.21.'in c grafikleri).  $\bar{R}^2$  değerinin eğitiminde kullanıldığında üç gizli katmanlı yapıda, GY algoritması sıfıra çok yakın olan  $1,78 \times 10^{-6}$  olarak bulunurken, YAK algoritması 0,0734 olarak bulunmuştur. Bu durum aslında  $\bar{R}^2$  değerinin GY algoritmasında 1 değerine çok yakın olduğunu

gösterirken, YAK algoritmasında 0,9266 olduğunu göstermektedir (Şekil 4.21.'in c3 grafiği).

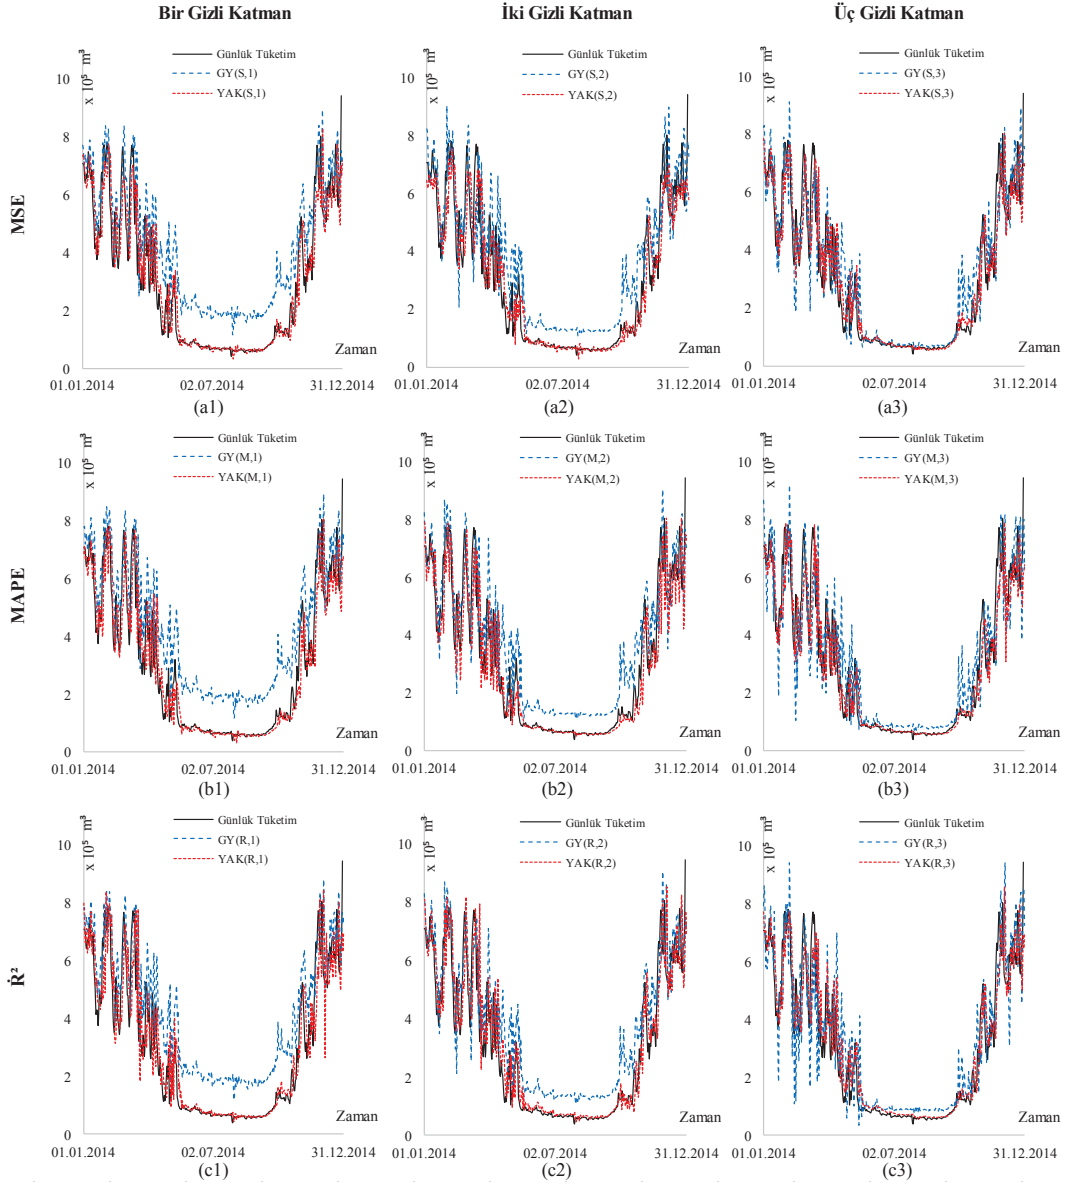


Şekil 4.21. En düşük MAPE değerlerine sahip YSA'nın eğitim durumları

Eğitim aşamasında, GY algoritmasında fark hatası geri yayılım ile ağırlıkların güncellediğinden dolayı YAK algoritmasındaki değerlere göre hem hata kriteri bazında hem de gizli katman yapısı bazında çok daha iyi performans sergilemiştir. Diğer bir ifadeyle YAK eğitim sonuçları GY eğitim sonuçlarına göre daha kötüdür. Bu durumun 2014 yılı için talep tahmininde benzer olması beklenmektedir.

Şekil 4.21. incelendiğinde GY algoritması için gerçekleştirilen eğitimlerde ilk 100 dönemde çoğunun gerçekleştiği belirlenmiştir. İlk 100 dönemden sonra eğitimdeki eğimin düşerek sifira yaklaştığı görülmektedir. Hatta GY algoritması kullanan tek gizli katmanlı yapının MAPE ile eğitim modelinde eğitim hatası artmaktadır (Şekil 4.21.'in b1 grafiği). GY algoritmasının aksine, YAK algoritmasında eğitim her dönemde sürekli düşmektedir. Bu durum, en verimli kaynaktaki nektar seçildikten sonra YAK algoritmasının bu kaynağın civarında daha iyi nektar aramasından kaynaklanmaktadır. Bu durum YAK algoritmasının eğitimde hatasını sürekli iyileştirmesini sağlamaktadır. Fakat GY algoritması eğitim verisinde aşırı uyumlama sergilemiştir.

Eğitim aşamasından sonra 01.01.2014-31.12.2014 tarihleri arasında gün öncesi talep tahmini hazırlanan modeller ile gerçekleştirilmiştir. Düşük hatalı modellerin eğitim sonrasındaki gün öncesi talep tahmin sonuçları Şekil 4.22.'de gösterilmiştir. Tahminlerdeki en farkedilebilir durum hata kriterinden bağımsız olarak (MSE, MAPE ve  $R^2$  hatalarının hepsinde) gizli katman sayısı arttıkça hem GY hemde YAK algoritmalarındaki hataların düşmesidir. GY algoritmasının sonuçları özel olarak incelendiğinde ise tek gizli katman ve iki gizli katmanda hata kriterinden bağımsız olarak tüketim ile tahmin arasındaki çok yüksek farklar rahatlıkla görülebilmektedir. Tek gizli katmanda hata kriterinden bağımsız olarak GY ile eğitim sonucu test edilen ağ yaklaşık 100% MAPE gösterirken, iki gizli katmanlı yapıda %63 MAPE civarına, üç gizli katmanlı yapıda ise %33 MAPE civarına düşmüştür. Her gizli katmanın GY algoritmasında %33 lik MAPE düşürdüğü söylenebilir. YAK ile eğitilen ağ yapısında ise katman sayısının çok da önemli olmadığı görülmektedir. Hata kriterlerinden bağımsız tek gizli katman ve iki gizli katman olduğunda ortalama %16,8 MAPE hata bulunurken, üç gizli katman olduğunda ortalama hata %16,6 MAPE olmuştur. Diğer bir değişle YAK eğitilmiş ağ yapısında gizli katman sayısı hata kriterinden bağımsız olarak farklılık göstermemektedir. Aynı yapıda tasarlanmış olan ağ yapılarının ağırlık ve eşik değerleri değiştirilerek gerçekleşen tüketimlere yakın veya uzak sonuçların bulunması, eğitimin başarısını göstermektedir. YAK ile eğitilen ağın GY ile eğitilen ağa göre daha iyi sonuçlar göstermesi yapılan çalışmadaki yaklaşımın doğruluğunu göstermektedir.



Şekil 4.22. Gün öncesi kayan pencere yöntemi YSA sonuçları

Bütün senaryolardaki testlerde YAK ile eğitilen yapay sinir ağları GY ile eğitilen yapay sinir ağlarından daha düşük hata değerleri üretmiştir. Gün öncesi talep tahmininin 2014 yılı için yapılmasından sonra gizli katmanlara göre MAPE hata değeri Tablo 4.15.'de gösterilmiştir.




Tablo 4.15. Gün öncesi YSA yöntemi için en iyi sonuçlar ve tahmin hata durumları

		<i>Bir gizli katman</i>		<i>İki gizli katman</i>		<i>Üç gizli katman</i>	
		<b>GY</b>	<b>YAK</b>	<b>GY</b>	<b>YAK</b>	<b>GY</b>	<b>YAK</b>
<i>MSE</i>	Model	GY(S,1)	YAK(S,1)	GY(S,2)	YAK(S,2)	GY (S,3)	YAK(S,3)
	MAPE (%)	99,2	16,4	63,8	17,6	30,2	16,9
<i>MAPE</i>	Model	GY(M,1)	YAK(M,1)	GY(M,2)	YAK(M,2)	GY(M,3)	YAK(M,3)
	MAPE (%)	99,9	16,3	61,7	15,4	33,9	14,9
$\bar{R}^2$	Model	GY(R,1)	YAK(R,1)	GY(R,2)	YAK(R,2)	GY(R,3)	YAK(R,3)
	MAPE (%)	97,6	17,8	63,5	17,4	34,3	18,0

Gerçekleştirilen bu senaryolardan tek gizli katmana sahip ağlardan en iyi performansı gösteren %16,29 MAPE değeri ile 7000 dönem çalıştırılan 20 nörona sahip ağ olmuştur. İki gizli katmana sahip ağlardan en iyi performansı gösteren ağ yapısı %15,36 MAPE değeri ile 7000 dönem çalıştırılan 20+20 nörona sahip ağ olmuştur. Üç gizli katmana sahip ağlardan ise en iyi gün öncesi talep tahmini performansını gösteren ağ yapısı %14,94 hata değeri ve 0,894384  $R^2$  ile 7000 dönem çalıştırılan 20+10+5 nörona sahip ağ olmuştur. Tüm bu değerler YSA-YAK'tadır.

YSA-GY modelleri bütün senaryolarda YSA-YAK modellerinin gerisinde kaldığı için farklı bir deneme olarak, veri setinin [0,1] aralığına normalize edilmiş hali ile ve eğitim sırasında gerçek değerlere dönüştürmeden bir, iki ve üç gizli katmana sahip ağlar YSA-GY ile eğitilmiş ve en düşük hata olarak tek gizli katmanda %41,70, iki gizli katmanda %30,21 ve üç gizli katmanda %29,97 MAPE değerine erişilebilmiştir.

Şekil 4.23.'de GY ve YAK eğitimlerinin kayan pencere tekniği ile gün öncesi doğal gaz tüketiminde yaptıkları tahminlere göre en düşük MAPE hatasına sahip YSA sonuçları gösterilmiştir. GY algoritmasının tüm tahmin serisi boyunca hatası YAK algoritmasının üzerinde gerçekleşmiştir. Kış aylarının GY algoritmasında etkisinin daha fazla olmasından dolayı yaz aylarında tahminlerin yüksek olmasını sağlamıştır. Kış aylarının etkisinin fazla olması, bu mevsim ve bahar aylarında geçmiş tüketimin tahminde keskin düşüş ve yükselişler göstermesine sebep olmuştur.



Şekil 4.23. Gün öncesi kayan pencere yöntemi en iyi performans gösteren YSA model sonuçları

GY algoritmasındaki ani düşüş ve yükselişler rahatlıkla görülebilmektedir (Şubat – Mart ve Kasım – Aralık ayları). Ekim ayı özelinde incelenecek olursa GY algoritmasının tahmini gerçek tüketim ile tamamen farklılık göstermektedir. Tüketimin davranışında meydana gelen çok düşük yükselişe, çok yüksek tüketim tepkisi vererek öğrenme değil ezberleme yaptığı rahatlıkla görülmektedir. YAK algoritmasında ise tüm mevsimlerin etkisinin eş değer olduğu söylenebilir. Yaz mevsimi incelendiğinde tahmin ile gerçekleştirmelerin birebir olduğu rahatlıkla görülmektedir. Ekim ayındaki tüketimdeki düşük miktarda artış için aynı seviyede tüketim tahmininde bulunması YAK eğitiminin başarısını göstermektedir. YAK algoritmasında, GY algoritmasından farklı olarak Nisan ayının sonlarına doğru da tahminler tüketimdeki düşüş ile orantılı tepki vermiştir.

#### 4.3.5. Gün öncesi talep tahmininin genel değerlendirmesi

Gün öncesi doğal gaz talep tahmini, ticaret şirketlerinin bir veya birkaç gün sonrası için tüketecekleri doğal gazı, planladıkları ve gerçekleşen tüketimin uzaktan okuma sistemleri ile aktarıldığı Elektronik Bülten Tablosu adı verilen internet sitesi üzerinden gerçekleştirilmektedir. Günlük olarak yapılan talep tahminler, toleransların dışına çıktığında cezai yaptırımları bulunmaktadır. Bu yaptırımlar genellikle para cezası olarak ortaya çıkmaktadır. Tezin bu aşamasında gün öncesi talep tahmini için farklı yöntemler ve teknikler kullanılmıştır. Günlük tüketim verisi kullanarak yapılan

çalıřmalarda YAK(M,3) ve GÖWÇ modellerinin en iyi sonucu verdiđi görölmektedir. Bu modeller sırasıyla %14,9, %15,02 MAPE ve 0,894384, 0,9066 R<sup>2</sup> deđerleri ile tahmini gerçekteřirmişlerdir. Yıl öncesi günlük talep tahmininde ise 365 günlük tahmin bir kerede oluşturulmaktadır. Bu tahminlerde zaman serilerinin ayrıştırma yöntemi, Holt-Winters üstel düzleřtirme yönteminin %17 MAPE ve 0,8 R<sup>2</sup> deđeri civarında tahminler ürettiđi görölmüşür. ARIMA/SARIMA yöntemlerindeki günlük veri ile yıl öncesi tahmindeki en iyi sonucu ARIMA(0,0,1)1(0,1,1)<sup>365</sup> modeli %26,67 MAPE ve 0,82 R<sup>2</sup> deđeri ile elde etmiştir. Gün öncesi talep tahmininde yapılan bir diđer çalıřma kayan pencere yöntemi ile Winters üstel düzleřtirme yönteminin kullanılması ve YSA modellerinin kullanılmasıdır. Dört haftalık tüketimi alarak 2011-2013 yılları arasında gün öncesi talep tahmini Holt-Winters üstel düzleřtirme yöntemi ile yapılmıştır. Her gün öncesi talep tahmin adımıında farklı  $\alpha$ ,  $\beta$  ve  $\gamma$  parametreleri bulunmuştur. Her yılın aynı günündeki parametrelerin ortalamaları alınarak 2014 yılı içindeki ilgili günün talep tahminleri gerçekteřtirilmiştir. Kayan pencere ile Holt-Winters üstel düzleřtirme sonuçları toplamsal ve çarpımsal olarak elde edilmiş ve sırasıyla %16,9, %15,02 MAPE ve 0,9377, 0,9066 R<sup>2</sup> olmuştur. YSA modelleri iki farklı yöntem ile eğitilmiştir. Bunlardan birincisi GY algoritması, ikincisi YAK algoritmasıdır. Burada üç gizli katmanlı tahminlerin en düşük hataya sahip oldukları görölmektedir. YSA'da GY(S,3) ve YAK(M,3) modeli en düşük hataya sahiptir ve sırasıyla %30,2 ile %14,9 MAPE ve 0,83 ile 0,89 R<sup>2</sup> deđerinde olmuşlardır.

Yapılan tahmin hataları, řirketler için cezai yaptırımları beraberinde getirmektedir. Kullanılan farklı yöntemler ve bunların MAPE ile R<sup>2</sup> deđerleri Tablo 4.16.'da gösterilmiştir. Bu tabloda ilgili günlerde yapılan tahminlerin cezaları toplanarak bir sene içinde ödenmesi gereken bedeller de tabloda gösterilmiştir.

Tablo 4.16. Gün öncesi modellerin tahminleri için ceza bedelleri

<i>Model Kısaltması</i>	<i>MAPE (%)</i>	<i>R<sup>2</sup></i>	<i>Ceza (TL)</i>
<i>TS</i>	26,23	0,8028	781.631,15
<i>TES</i>	29,47	0,8053	789.769,74
<i>ÇŞ</i>	26,95	0,7989	949.090,00
<i>ÇES</i>	27	0,8039	976.158,75
<i>WT0.2</i>	1962	0,1032	61.106.200,17
<i>WTO</i>	197,4	0,7227	4.854.209,08
<i>WÇ0.2</i>	251,7	0,1047	18.112.984,56
<i>WÇE'</i>	26,9	0,7782	1.007.307,72
<i>WÇO</i>	27,1	0,8280	866.694,73
<i>GÖ1</i>	688,06	0,7201	23.117.248,56
<i>GÖ2</i>	27,67	0,8158	840.284,97
<i>GÖ3</i>	467,75	0,0281	13.690.236,86
<i>GÖWT</i>	16,9	0,9377	278.044,34
<i>GÖWÇ</i>	15,02	0,9066	385.302,74
<i>GY(S,3)</i>	30,2	0,8295	748.054,4
<i>YAK(M,3)</i>	14,9	0,8944	524.945,91

Buradaki modellerin yarısında, ceza miktarlarının önemli ölçüde düşük olduğu görülmektedir. Tabloda önemli olan başka bir nokta düşük MAPE oranlarında ceza miktarlarının düşmesidir. Tablodaki bu haliyle MAPE ile ceza arasındaki ilişkinin, MAPE ile  $R^2$  arasındaki ilişkinin ve  $R^2$  ile ceza arasındaki ilişkinin korelasyon katsayıları sırası ile 0,9861, -0,6654 ve -0,7261 olarak bulunmuştur. Fakat burada MAPE'den ziyade  $R^2$  değerinin cezaları düşürmede daha etkili olduğu görülebilmekle birlikte MAPE ve ceza ile ters orantılı olduğu belirlenmiştir. 1.000.000 ve üzeri cezaların tahmin modelleri listeden çıkartıldığında ise MAPE ile ceza arasındaki ilişkinin, MAPE ile  $R^2$  arasındaki ilişkinin ve  $R^2$  ile ceza arasındaki ilişkinin korelasyon katsayıları sırası ile 0,7091, -0,7614, -0,9634 olarak değişmektedir. Bu durum gün öncesi düşük %50 MAPE değeri altındaki modellerde  $R^2$  değerinin ödenecek ceza bedelinde daha etkili olduğunu göstermektedir.

## BÖLÜM 5. TARTIŞMA VE ÖNERİLER

Yapılan tez çalışmasının temel amacı, enerji talep tahminini tek değişkenli yöntemler kullanarak en düşük hata ile gerçekleştirmektir. Tez çalışmasında iki farklı tahmin aralığı incelenmiştir. Bunlardan birincisi yıl öncesi aylık tahmin, ikincisi ise gün öncesi talep tahmindir. Uygulama olarak doğal gaz sektörü ele alınmış, uygulanan yöntemlerin sonuçları değerlendirilmiştir.

Yıl öncesi talep tahmini her sene yenilenen sözleşmelerin üzerindeki tüketim bedellerini temsil ettiği için önemlidir. Sözleşmeler “al ya da öde” anlaşmaları olduğundan, fazla tüketim durumunda doğal gaz için birim ücret daha yüksek olabilmekte veya gaz arzında sıkıntı yaşanmakta olup düşük olduğunda ise sözleşmede belirtilen miktar fazlası kadar ödemenin yapılması gerekmektedir. Yıl öncesi aylık tüketim tahmininde iki farklı davranış söz konusudur. Burada yıl öncesi aylık veri kullanımı ve günlük veri kullanımı ile aylık tahminler yapılabilmektedir. Zaman serilerinin ayrıştırması, Winters üstel düzeltirme yöntemi, ARIMA/SARIMA yöntemi yıl öncesi aylık talep tahmininde kullanılan yöntemlerdir. Yıl öncesi aylık talep tahmin sonuçları Tablo 5.1.’de gösterilmiştir. ARIMA/SARIMA yöntemi Box-Jenkins yaklaşımı gereği durağan seriler üzerinden tahmin yapabilmektedir. Doğal gaz tüketim serisinin öncelikle fark alma işlemi yapılarak durağanlaştırılması gerçekleştirilmiş ve seri durağanlık testleri olan ADF ve PP ile test edilmiştir. Daha sonra serilerin üzerinden ACF ve PACF grafikleri incelenerek ilişkinin olduğu AR ve MA parametreleri belirlenmeye çalışılmıştır. Yapılan tahminler sonucunda ARIMA/SARIMA yönteminin 2014 yılı için yaptıkları tahminler 2011-2013 arasındaki en düşük MAPE, 2014 için en düşük MAPE ( $MAPE_{2014}$ ), 2011-2013 arasında en yüksek  $R^2$  ve 2014 için en yüksek  $R^2$  ( $R^2_{2014}$ ) olarak dört farklı kritere göre belirlenmiştir. Buna göre 2011-2013 arasındaki en düşük MAPE ve en yüksek  $R^2$  modeli aynı olmuştur (ARIMA(3,0,3)1(1,1,1)<sup>12</sup> – AA1).  $MAPE_{2014}$  ve  $R^2_{2014}$

modelleri ise  $ARIMA(1,1,1)1(0,1,1)^{12} - AA2$  ve  $ARIMA(0,1,1)1(0,1,1)^{12} - AA3$  sonuçları aylık veri ile en iyi tahmin performansı göstermişlerdir.

Tablo 5.1. Yıl öncesi aylık doğal gaz talep tahmin sonuçları

<i>Aylık Veri İle Tahmin</i>			<i>Günlük Veri İle Tahmin</i>		
Model Adı	MAPE (%)	R <sup>2</sup>	Model Adı	MAPE (%)	R <sup>2</sup>
TS	17,21	0,9650	TS	16,8	0,9636
TES	15,07	0,9695	TES	14,8	0,9688
ÇŞ	17,51	0,9665	ÇŞ	16,2	0,9653
ÇES	15,15	0,9718	ÇES	14,0	0,9731
WT0.2	74,6	0,9510	WT0.2	1858	0,1113
.	.	.	WTE'	25,7	0,9721
WTO	14	0,9846	WTO	179,8	0,8562
WÇ0.2	26,7	0,9584	WÇ0.2	243,1	0,1314
WÇE'	93,5	0,9888	WÇE'	18,3	0,9265
WÇO	15,05	0,9640	WÇO	14,4	0,9905
AA1 (MAPE - R <sup>2</sup> )	27,44	0,8706	GAA1 (MAPE - R <sup>2</sup> )	378,48	0,4727
AA2 (MAPE <sub>2014</sub> )	12,89	0,9841	GAA2 (MAPE <sub>2014</sub> )	11,84	0,9820
AA3 (R <sup>2</sup> <sub>2014</sub> )	14,99	0,9863	GAA3(R <sup>2</sup> <sub>2014</sub> )	12,01	0,9913
			GAG1 (MAPE)	641,57	0,7856
			GAG2 (MAPE <sub>2014</sub> - R <sup>2</sup> <sub>2014</sub> )	11,91	0,9912
			GAG3 (R <sup>2</sup> )	434,14	0,0410

Günlük doğal gaz verisi kullanılarak da aylık talep tahmini yapılabilmektedir. Böylece veri yoğunluğunun talep tahmini üzerindeki etkisi de görülmüştür. Bu bölümde de zaman serilerinin ayrıştırması, Winters üstel düzleştirme yöntemi, ARIMA/SARIMA yöntemi kullanılmıştır ve sonuçlar Tablo 5.1.'de gösterilmiştir. Günlük veri ile yapılan tahmin zaman serileri ayrıştırma yöntemi sonuçlarının aylık veri ile yapılan tahminlere göre daha iyi sonuç verdiği görülmüştür. Yıl öncesi tahminde aylık veri kullanıldığında en iyi MAPE %14 ve R<sup>2</sup> 0,9888 iken günlük veri kullanılarak yapılan tahminde en iyi MAPE %14,4 ve R<sup>2</sup> 0,9905 olmuştur. Holt-Winters üstel düzleştirme yönteminde günlük veri ile yapılan tahmindeki en düşük MAPE aylık veri ile yapılan tahmindeki MAPE'den daha yüksek belirlenmiştir. Fakat R<sup>2</sup> değerinde tam tersi, günlük veri ile yapılan tahmin sonucu daha iyi sonuç göstermiştir. ARIMA/SARIMA yönteminin 2014 yılı için yaptıkları tahminlerin, serilerin günlük veri üzerinden en düşük hataların bulunması (GAG modelleri) ve günlük verilerin aylık veriye dönüştürüldükten sonra en düşük hataların bulunması

(GAA modelleri) olarak iki bölümü bulunmaktadır. 2011-2013 arasındaki en düşük MAPE, MAPE<sub>2014</sub>, 2011-2013 arasında en yüksek R<sup>2</sup> ve R<sup>2</sup><sub>2014</sub> olarak dört farklı ölçüte göre belirlenmiştir. Buna göre GAA modellerinde 2011-2013 arasındaki en düşük MAPE ile en yüksek R<sup>2</sup> modeli aynı olmuştur ve ARIMA(1,1,0)1(0,0,1)<sup>365</sup> – GAA1 modeli bulunmuştur. MAPE<sub>2014</sub> ve R<sup>2</sup><sub>2014</sub> modellerinde ise en düşük modeller sırasıyla ARIMA(1,0,1)1(1,1,1)<sup>365</sup> – GAA2 ve ARIMA(0,0,0)1(0,1,1)<sup>365</sup> – GAA3 olmuştur. Aynı dört ölçüt GAG modelleri ile tahminde 2011-2013 arasında en düşük MAPE ve R<sup>2</sup> için sırasıyla ARIMA(1,1,0)1(2,0,3)<sup>365</sup> – GAG1 ve ARIMA(3,1,1)1(0,0,0)<sup>365</sup> – GAG3 olmuştur. MAPE<sub>2014</sub> ve R<sup>2</sup><sub>2014</sub> modellerinde ise ARIMA(0,0,1)1(0,1,1)<sup>365</sup> – GAG2 en düşük MAPE ve en yüksek R<sup>2</sup> değerini elde etmiştir. Bu sonuçlara göre ARIMA/SARIMA yöntemlerinde günlük veri kullanılarak yapılan yıl öncesi aylık doğal gaz tahmininin aylık veri kullanılarak yapılan tahmine göre daha iyi sonuç verdiği bulunmuştur.

Tez çalışması kapsamında yapılan diğer bir çalışma da gün öncesi doğal gaz talep tahminidir. Gün öncesi talep tahmin sonuçları Tablo 5.2.'de gösterilmiştir.

Tablo 5.2. Gün öncesi doğal gaz talep tahmin sonuçları

<i>Yıl Öncesi Günlük Talep Tahmini</i>			<i>Gün Öncesi Talep Tahmini</i>		
Model Adı	MAPE (%)	R <sup>2</sup>	Model Adı	MAPE (%)	R <sup>2</sup>
TS	26,23	0,8028	GY(S,3)	30,2	0,8295
TES	29,47	0,8053	YAK(M,3)	14,9	0,8944
ÇŞ	26,95	0,7989	GÖWT	16,9	0,9377
ÇES	27	0,8039	GÖWÇ	15,02	0,9066
WT0.2	1962	0,1032			
WTE'	39,5	0,8149			
WTO	197,4	0,7227			
WÇ0.2	251,7	0,1047			
WÇE'	26,9	0,7782			
WÇO	27,1	0,8280			
GÖ1 (MAPE)	688,06	0,7200			
GÖ2 (MAPE <sub>2014</sub> - R <sup>2</sup> <sub>2014</sub> )	23,67	0,8158			
GÖ3 (R <sup>2</sup> )	467,75	0,0282			

Gün öncesi doğal gaz talep tahmini, günlük olarak gerçekleştirilmekte ve tüketim durumuna göre bazı toleranslar oluşturmaktadır. Bu toleranslar dışında tahminler

gerçekleştiğinde, tolerans miktarına bağlı olarak sistemi dengesizliğe uğratmaktan dolayı cezalar kesilmektedir. Gün öncesi talep tahmininde iki farklı açıdan yaklaşılarak hataların ve cezaların en düşük düzeyde olması sağlanmaya çalışılmıştır. İlk yaklaşım günlük veri kullanılarak tüm senenin bir kerede tahmin edilmesidir. İkinci yaklaşımda ise gün öncesi seriye kendiden önceki belli zaman çerçevesinde tüketim verisi verilerek bir gün sonrası tahmin edilmeye çalışılmıştır. İkinci yöntem kayan pencere yöntemi olarak gösterilmiştir. İlk yaklaşıma göre 2014 yılı için MAPE ve  $R^2$  değerleri en düşük %26.23 ve 0,828 olarak bulunmuştur. İkinci yaklaşıma göre iki farklı algoritma kullanılmıştır. Bunlardan ilk Holt-Winters üstel düzleştirme yöntemidir ve 4 haftalık tüketim verisi verilen kayan pencere yöntemi ile 2011-2013 arasında her gün için  $\alpha$ ,  $\beta$ ,  $\gamma$  parametreleri belirlenip 2014 yılındaki tahminlerde bu parametrelerin ortalamaları alınarak tahmin gerçekleştirilmiştir. Buna göre toplamsal ve çarpımsal olarak modeller oluşturulmuştur. Kullanılan farklı algoritmalarından ikincisi YSA'dır. YSA modellerinde ise GY ve YAK ile eğitim modelleri oluşturulmuştur. Farklı gizli katman ve ağ yapılarında hazırlanan modeller kayan pencere yöntemine göre hazırlanmış 2011-2013 tüketim verileri ile eğitilmişlerdir. Daha sonra eğitilmiş ağ yapısına en yakın 7 günlük tüketim verisi verilerek bir gün sonrası tahmin edilmiştir. GÖWT, GÖWÇ ve YSA-YAK modelleri ürettikleri tahminler ile daha düşük hata ve daha yüksek  $R^2$  elde etmiştir. Literatürde Prema ve Rao rüzgar hızının tahmininde Holt-Winters üstel düzleştirme, ARIMA yöntemleri ile zaman serilerinin ayrıştırmasını kullanmışlardır ve sırasıyla %25,61, %23,26, %18,24 MAPE değerlerini bulmuşlardır [46]. Gelažanskas ve Gamage sıcak su talep tahmininde  $R^2$  değerini zaman serilerinin ayrıştırması, Holt-Winters üstel düzleştirme yöntemi ve ARIMA için 0,863, 0,811, 0,872 bulmuşlardır [45]. Wu ve Peng rüzgâr gücü üretimini tahmin eden model geliştirmiştir ve ARIMA ile karşılaştırmıştır. ARIMA yöntemindeki tahminde hata %38,57 MAPE değerinde gerçekleşmiştir [108]. Sonuçlar literatür ile de karşılaştırıldığında hata oranlarının ve  $R^2$  değerlerinin hem yıl öncesi aylık tahminde hem de gün öncesi talep tahmininde daha düşük bulunduğu belirlenmiştir.

Tablo 4.16'da gün öncesi talep tahmin modellerine göre 2014 yılı için ödenecek ceza miktarı görülmektedir. MAPE değerinin %50'nin altına düşmesi halinde,  $R^2$



değerinin ödenecek ceza miktarında daha etkili olduğu ortaya çıkmıştır. Gün öncesi talep tahmininde ise GÖWT, GÖWÇ ve YAK(M,3) modellerinin gün öncesi talep tahmininde diğer modellere göre çok daha uygun olduğu belirlenmiştir.

Yıl öncesi talep tahmininde istatistiksel yöntemlerin güçlü oldukları görülmüştür. Burada günlük veri ile de sonuçların iyileştirilebileceği görülmüştür. Yöntem olarak birbiri ile eşleşen tüketim aralıklarının (Aralık-Ocak-Şubat ayları için model, Mart-Nisan-Ekim-Kasım ayları için model, Mayıs-Haziran-Temmuz-Ağustos-Eylül ayları için model gibi) kendine has modelleri oluşturularak yıl öncesi aylık tahmin yapılmasının sonuçları geliştireceği düşünülmektedir.

Gün öncesi talep tahmininde ise kayan pencere tekniğinin etkili olduğu görülmüştür. Kayan pencere tekniği kullanılarak gerçek zamanlı YSA modelleri ile daha doğru tahmin yapılabileceği öngörülmektedir. Ayrıca Winters üstel düzleştirme yönteminde de gerçek zamanlı modellerin her gün oluşturularak daha doğru sonuç bulanabileceği düşünülmektedir. Bununla beraber parametrelerin belirlenmesinde geçmiş veri olarak dört haftalık veri dışında farklı boyutlarda da çerçeveler kullanılarak daha iyi sonuçlar alınması sağlanabilir. Aynı şekilde parametrelerin optimizasyonunda YAK algoritmasının kullanılması da daha hızlı sonuçların üretilmesini sağlayabilir. Tek değişkenli yaklaşım dışında, doğal gaz talep tahmininde bağımsız değişkenlerin kullanılmasının hataları düşüreceği düşünülmektedir ve gün öncesi tahminde önerilmektedir. Önerilen bir diğer çalışma ise tek değişkenli yöntemler sonucunda tahmin edilemeyen hataların bağımsız değişkenler ile aralarındaki ilişkiyi inceleyerek modele eklenmesidir.

## KAYNAKLAR

- [1] Gürpınar, F., Akpınar, M., Yumuşak, N., Toptan Satış Şirketi Odaklı Kısa Dönem Doğal Gaz Tüketim Talep Tahmini. Uluslararası İstanbul Akıllı Şebekeler ve Şehirler Kongre ve Fuarı, , 2015.
- [2] T.C. Enerji Piyasası Düzenleme Kurumu, Turkish Natural Gas Market Report 2014. Ankara, 2015.
- [3] T.C. Enerji Piyasası Düzenleme Kurumu, Doğal Gaz Piyasası Sektör Raporu 2015. Ankara, 2016.
- [4] T.C. Enerji Piyasası Düzenleme Kurumu, Elektrik Piyasası 2015 Yılı Piyasa Gelişim Raporu. Ankara, 2016.
- [5] 6446 sayılı Elektrik Piyasası Kanunu, T.C. Resmi Gazete, 2013.
- [6] Rekabet Kurumu, Doğal Gaz Sektör Araştırması. Ankara, 2012.
- [7] Shaikh, F., Ji, Q., Forecasting natural gas demand in China: Logistic modelling analysis. *International Journal of Electrical Power and Energy Systems*, 77, 25–32, 2016.
- [8] Siemek, J., Nagy, S., Rychlicki, S., Estimation of natural-gas consumption in Poland based on the logistic-curve interpretation. *Applied Energy*, 75(1–2), 1–7, 2003.
- [9] Gutiérrez, R., Nafidi, A., Gutiérrez Sánchez, R., Forecasting total natural-gas consumption in Spain by using the stochastic Gompertz innovation diffusion model. *Applied Energy*, 80(2), 115–124, 2005.
- [10] Ma, H., Wu, Y., Grey predictive on natural gas consumption and production in China. *Proceedings of the 2009 2nd Pacific-Asia Conference on Web Mining and Web-Based Application, WMWA 2009, Wuhan*, 91–94, 2009.
- [11] Ünal, H. K., Türkiye Doğal Gaz İletim Sistemine Üçüncü Taraf Erişimi 2007-2013. Ankara, 2014.

- [12] BOTAŞ İletim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar 22.11.2007 tarih 1384 sayılı Kurul Kararı, T.C. Resmi Gazete, 2007.
- [13] BOTAŞ İletim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar 17.10.2008 tarih 1809 sayılı Kurul Kararı, T.C. Resmi Gazete, 2007.
- [14] İletişim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar, Boru Hatları ile Taşıma A.Ş., 2013.
- [15] Akpınar, M., Yumuşak, N., Forecasting household natural gas consumption with ARIMA model : A case study of removing cycle. 2013 7th IEEE International Conference on Application of Information and Communication Technologies (AICT), Bakü, 1-6, 2013.
- [16] Akpınar, M., Yumuşak, N., Estimating household natural gas consumption with multiple regression: Effect of cycle. 2013 International Conference on Electronics, Computer and Computation (ICECCO), Ankara, 188–191, 2013.
- [17] Akpınar, M., Yumuşak, N., Year Ahead Demand Forecast of City Natural Gas Using Seasonal Time Series Methods. *Energies*, 9(9), 727, 2016.
- [18] Potočnik, P., Soldo, B., Šimunović, G., Šarić, T., Jeromen, A., Govekar, E., Comparison of static and adaptive models for short-term residential natural gas forecasting in Croatia. *Applied Energy*, 129, 94–103, 2014.
- [19] Soldo, B., Potočnik, P., Šimunović, G., Šarić, T., Govekar, E., Improving the residential natural gas consumption forecasting models by using solar radiation. *Energy and Buildings*, 69, 498–506, 2014.
- [20] Zhu, L., Li, M. S., Wu, Q. H., Jiang, L., Short-term natural gas demand prediction based on support vector regression with false neighbours filtered. *Energy*, 80, 428–436, 2015.
- [21] Aramesh, A., Montazerin, N., Ahmadi, A., A general neural and fuzzy-neural algorithm for natural gas flow prediction in city gate stations. *Energy and Buildings*, 72, 73–79, 2014.
- [22] Iranmanesh, H., Abdollahzade, M., Miranian, A., Mid-term energy demand forecasting by hybrid neuro-fuzzy models. *Energies*, 5(1), 1–21, 2012.
- [23] Aras, N., Forecasting Residential Consumption of Natural Gas Using Genetic Algorithms. *Energy Exploration & Exploitation*, 26(4), 241–266, 2008.

- [24] Izadyar, N., Ong, H. C., Shamshirband, S., Ghadamian, H., Tong, C. W., Intelligent forecasting of residential heating demand for the District Heating System based on the monthly overall natural gas consumption. *Energy and Buildings*, 104, 208–214, 2015.
- [25] Izadyar, N., Ghadamian, H., Ong, H. C., Moghadam, Z., Tong, C. W., Shamshirband, S., Appraisal of the support vector machine to forecast residential heating demand for the District Heating System based on the monthly overall natural gas consumption. *Energy*, 93, 1558–1567, 2015.
- [26] Timmer, R. P., Lamb, P. J., Relations between temperature and residential natural gas consumption in the Central and Eastern United States. *Journal of Applied Meteorology and Climatology*, 46(11), 1993–2013, 2007.
- [27] Harold, J., Lyons, S., Cullinan, J., The determinants of residential gas demand in Ireland. *Energy Economics*, 51, 475–483, 2015.
- [28] Soldo, B., Forecasting natural gas consumption. *Applied Energy*, 92(5), 26–37, 2012.
- [29] Taşpınar, F., Çelebi, N., Tutkun, N., Forecasting of daily natural gas consumption on regional basis in Turkey using various computational methods. *Energy and Buildings*, 56, 23–31, 2013.
- [30] Dagher, L., Natural gas demand at the utility level: An application of dynamic elasticities. *Energy Economics*, 34(4), 961–969, 2012.
- [31] Tavakoli, E., Montazerin, N., Stochastic analysis of natural gas consumption in residential and commercial buildings. *Energy and Buildings*, 43(9), 2289–2297, 2011.
- [32] Akpınar, M., Yumuşak, N., Naïve forecasting household natural gas consumption with sliding window approach. *Turk J Elec Eng & Comp Sci*, 25(1), 2017.
- [33] Sánchez-Úbeda, E. F., Berzosa, A., Modeling and forecasting industrial end-use natural gas consumption. *Energy Economics*, 29(4), 710–742, 2007.
- [34] Szoplik, J., Forecasting of natural gas consumption with artificial neural networks. *Energy*, 85, 208–220, 2015.
- [35] Yu, F., Xu, X., A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network. *Applied Energy*, 134, 102–113, 2014.

- [36] Demirel, Ö. F., Zaim, S., Çalışkan, A., Özuyar, P., Forecasting natural gas consumption in Istanbul using neural networks and multivariate time series methods. *Turk J Elec Eng & Comp Sci*, 20(5), 695–711, 2012.
- [37] Akpınar, M., Adak, M. F., Yumusak, N., Forecasting Natural Gas Consumption with Hybrid Neural Networks – Artificial Bee Colony. *IEEE 2016 2nd International Conference on Intelligent Energy and Power Systems*, Kiev, 101–106, 2016.
- [38] Huntington, H. G., Industrial natural gas consumption in the United States: An empirical model for evaluating future trends. *Energy Economics*, 29(4), 743–759, 2007.
- [39] Melikoğlu, M., Vision 2023: Feasibility analysis of Turkey’s renewable energy projection. *Renewable Energy*, 50, 570–575, 2013.
- [40] Xie, Y., Li, M., Research on Prediction Model of Natural Gas Consumption Based on Grey Modeling Optimized by Genetic Algorithm. *2009 IITA International Conference on Control, Automation and Systems Engineering (case 2009)*, , 335–337, 2009.
- [41] Soldo, B., Forecasting natural gas consumption. *Applied Energy*, 92, 26–37, 2012.
- [42] Ediger, V. S., Akar, S., Uğurlu, B., Forecasting production of fossil fuel sources in Turkey using a comparative regression and ARIMA model. *Energy Policy*, 34, 3836–3846, 2006.
- [43] Liu, L.-M., Lin, M.-W., Forecasting residential consumption of natural gas using monthly and quarterly time series. *International Journal of Forecasting*, 7(1), 3–16, 1991.
- [44] Yalçıntaş, M., Bulu, M., Küçükvar, M., Samadi, H., A Framework for Sustainable Urban Water Management through Demand and Supply Forecasting: The Case of Istanbul. *Sustainability*, 7(8), 11050–11067, 2015.
- [45] Gelažanskas, L., Gamage, K., Forecasting Hot Water Consumption in Residential Houses. *Energies*, 8(11), 12702–12717, 2015.
- [46] Prema, V., Rao, K. U., Time series decomposition model for accurate wind speed forecast. *Renewables: Wind, Water, and Solar*, 2(1), 18, 2015.
- [47] Martínez-Álvarez, F., Troncoso, A., Asencio-Cortés, G., Riquelme, J., A Survey on Data Mining Techniques Applied to Electricity-Related Time Series Forecasting. *Energies*, 8(12), 13162–13193, 2015.

- [48] Wang, J., Zhu, S., Zhang, W., Lu, H., Combined modeling for electric load forecasting with adaptive particle swarm optimization. *Energy*, 35(4), 1671–1678, 2010.
- [49] Khotanzad, A., Elragal, H., Lu, T. L., Combination of artificial neural-network forecasters for prediction of natural gas consumption. *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, 11(2), 464–73, 2000.
- [50] Gorucu, F. B., Artificial Neural Network Modeling for Forecasting Gas Consumption. *Energy Sources*, 26(3), 299–307, 2004.
- [51] Potočnik, P., Thaler, M., Govekar, E., Grabec, I., Poredoš, A., Forecasting risks of natural gas consumption in Slovenia. *Energy Policy*, 35(8), 4271–4282, 2007.
- [52] Yokoyama, R., Wakui, T., Satake, R., Prediction of energy demands using neural network with model identification by global optimization. *Energy Conversion and Management*, 50(2), 319–327, 2009.
- [53] Azadeh, A., Asadzadeh, S. M., Ghanbari, A., An adaptive network-based fuzzy inference system for short-term natural gas demand estimation: Uncertain and complex environments. *Energy Policy*, 38(3), 1529–1536, 2010.
- [54] Karimi, H., Dastranj, J., Artificial neural network-based genetic algorithm to predict natural gas consumption. *Energy Systems*, 5(3), 571–581, 2014.
- [55] Yao, S. ., Song, Y. ., Zhang, L. ., Cheng, X. ., Wavelet transform and neural networks for short-term electrical load forecasting. *Energy Conversion and Management*, 41(18), 1975–1988, 2000.
- [56] Sözen, A., Arcaklioğlu, E., Özkaymak, M., Turkey's net energy consumption. *Applied Energy*, 81(2), 209–221, 2005.
- [57] Yalcinoz, T., Eminoglu, U., Short term and medium term power distribution load forecasting by neural networks. *Energy Conversion and Management*, 46(9–10), 1393–1405, 2005.
- [58] Murat, Y. S., Ceylan, H., Use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34(17), 3165–3172, 2006.
- [59] Gareta, R., Romeo, L. M., Gil, A., Forecasting of electricity prices with neural networks. *Energy Conversion and Management*, 47(13–14), 1770–1778, 2006.

- [60] Amjady, N., Day-Ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network. *IEEE Transactions on Power Systems*, 21(2), 887–896, 2006.
- [61] Pao, H., Comparing linear and nonlinear forecasts for Taiwan's electricity consumption. *Energy*, 31(12), 2129–2141, 2006.
- [62] Ermis, K., Midilli, A., Dincer, I., Rosen, M. A., Artificial neural network analysis of world green energy use. *Energy Policy*, 35(3), 1731–1743, 2007.
- [63] Sözen, A., Gülseven, Z., Arcaklıoğlu, E., Forecasting based on sectoral energy consumption of GHGs in Turkey and mitigation policies. *Energy Policy*, 35(12), 6491–6505, 2007.
- [64] Sözen, A., Arcaklıoğlu, E., Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey. *Energy Policy*, 35(10), 4981–4992, 2007.
- [65] Hamzaçebi, C., Forecasting of Turkey's net electricity energy consumption on sectoral bases. *Energy Policy*, 35(3), 2009–2016, 2007.
- [66] Tso, G. K. F., Yau, K. K. W., Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks. *Energy*, 32(9), 1761–1768, 2007.
- [67] González-Romera, E., Jaramillo-Morán, M. A., Carmona-Fernández, D., Monthly electric energy demand forecasting with neural networks and Fourier series. *Energy Conversion and Management*, 49(11), 3135–3142, 2008.
- [68] Azadeh, A., Ghaderi, S. F., Sohrabkhani, S., Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors. *Energy Conversion and Management*, 49(8), 2272–2278, 2008.
- [69] Ying, L.-C., Pan, M.-C., Using adaptive network based fuzzy inference system to forecast regional electricity loads. *Energy Conversion and Management*, 49(2), 205–211, 2008.
- [70] Saini, L. M., Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks. *Electric Power Systems Research*, 78(7), 1302–1310, 2008.
- [71] Lauret, P., Fock, E., Randrianarivony, R. N., Manicom-Ramsamy, J.-F., Bayesian neural network approach to short time load forecasting. *Energy Conversion and Management*, 49(5), 1156–1166, 2008.

- [72] Pao, H. T., Forecasting energy consumption in Taiwan using hybrid nonlinear models. *Energy*, 34(10), 1438–1446, 2009.
- [73] Geem, Z. W., Roper, W. E., Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, 37(10), 4049–4054, 2009.
- [74] Sözen, A., Future projection of the energy dependency of Turkey using artificial neural network. *Energy Policy*, 37(11), 4827–4833, 2009.
- [75] Ekonomou, L., Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35(2), 512–517, 2010.
- [76] Cinar, D., Kayakutlu, G., Daim, T., Development of future energy scenarios with intelligent algorithms: Case of hydro in Turkey. *Energy*, 35(4), 1724–1729, 2010.
- [77] Kankal, M., Akpınar, A., Kömürcü, M. İ., Özşahin, T. Ş., Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*, 88(5), 1927–1939, 2011.
- [78] Azadeh, A., Saberi, M., Asadzadeh, S. M., Hussain, O. K., Saberi, Z., A neuro-fuzzy-multivariate algorithm for accurate gas consumption estimation in South America with noisy inputs. *International Journal of Electrical Power and Energy Systems*, 46(1), 315–325, 2013.
- [79] Wu, B., Qian, C., Ni, W., Fan, S., Hybrid harmony search and artificial bee colony algorithm for global optimization problems. *Computers & Mathematics with Applications*, 64(8), 2621–2634, 2012.
- [80] Azadeh, A., Asadzadeh, S. M., Mirseraji, G. H., Saberi, M., An emotional learning-neuro-fuzzy inference approach for optimum training and forecasting of gas consumption estimation models with cognitive data. *Technological Forecasting and Social Change*, 91, 47–63, 2015.
- [81] Uzlu, E., Akpınar, A., Öztürk, H. T., Nacar, S., Kankal, M., Estimates of hydroelectric generation using neural networks with the artificial bee colony algorithm for Turkey. *Energy*, 69, 638–647, 2014.
- [82] Karaboga, D., Gorkemli, B., Ozturk, C., Karaboga, N., A comprehensive survey: artificial bee colony (ABC) algorithm and applications. *Artificial Intelligence Review*, 42(1), 21–57, 2014.
- [83] Li, Y., Wang, Y., Li, B., A hybrid artificial bee colony assisted differential evolution algorithm for optimal reactive power flow. *International Journal of Electrical Power & Energy Systems*, 52, 25–33, 2013.



- [84] Kaur, S., Gangwar, R. C., Hybrid GSTEB routing protocol using clustering and artificial bee colony optimization. 2015 International Conference on Green Computing and Internet of Things (ICGCIoT), Delhi, 661–666, 2015.
- [85] Gao, K. Z., Suganthan, P. N., Pan, Q. K., Tasgetiren, M. F., Sadollah, A., Artificial bee colony algorithm for scheduling and rescheduling fuzzy flexible job shop problem with new job insertion. Knowledge-Based Systems, 1-16, 2016.
- [86] Hashim, H. A., Ayinde, B. O., Abido, M. A., Optimal placement of relay nodes in wireless sensor network using artificial bee colony algorithm. Journal of Network and Computer Applications, 64, 239–248, 2016.
- [87] Adak, M.F., Yumuşak, N., Classification of E-Nose Aroma Data of Four Fruit Types by ABC-Based Neural Network. Sensors, 16(3), 304, 2016.
- [88] Suganthi, L., Samuel, A. A., Energy models for demand forecasting—A review. Renewable and Sustainable Energy Reviews, 16(2), 1223–1240, 2012.
- [89] Ahmad, A. S., Hassan, M. Y., Abdullah, M. P., Rahman, H. A., Hussin, F., Abdullah, H., Saidur, R., A review on applications of ANN and SVM for building electrical energy consumption forecasting. Renewable and Sustainable Energy Reviews, 33, 102–109, 2014.
- [90] Makridakis, S., Wheelwright, S. C., J., H. R., Forecasting: Methods and Applications. John Wiley, New York, 642, 2008.
- [91] Özmucur, S., Geleceği Tahmin Yöntemleri. İstanbul Sanayi Odası, İstanbul, 393, 1990.
- [92] Orhunbilge, N., Zaman Serileri Analizi Tahmin ve Fiyat İndeksleri. İstanbul Üniversitesi İşletme Fakültesi Yayınları, İstanbul, 1999.
- [93] Yaffee, R. A., McGee, M., Introduction to Time Series Analysis and Forecasting: With Applications of SAS and SPSS. 1st. Ed., Academic Press, Orlando, FL, 528, 2000.
- [94] Stephen A. DeLurgio, Forecasting Principles and Applications. Irwin McGraw-Hill, Boston, 802, 1998.
- [95] Delurgio, S., Bhamu, C., Forecasting Systems for Operations Management. Irwin Professional Pub, New York, 648, 1991.

- [96] O'Rourke, N., Hatcher, L., Stepanski, E. J., A Step-by-Step Approach to Using SAS for Univariate & Multivariate Statistics. SAS Institute Inc., North Carolina, 514, 2005.
- [97] Box, G. E. P., Jenkins, G. M., Reinsel, G. C., Time Series Analysis. 5th. Ed., John Wiley & Sons, Inc., Hoboken, NJ, 712, 2008.
- [98] Dickey, D. A., Fuller, W. A., Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, 74 (366), 427, 1979.
- [99] Cavaliere, G., Harvey, D. I., Leybourne, S. J., Robert Taylor, A. M., Testing for Unit Roots Under Multiple Possible Trend Breaks and Non-Stationary Volatility Using Bootstrap Minimum Dickey-Fuller Statistics. *Journal of Time Series Analysis*, 36 (5), 603–629, 2015.
- [100] Phillips, P. C. B., Perron, P., Testing for a unit root in time series regression. *Biometrika*, 75 (2), 335–346, 1988.
- [101] Schalkoff, R. J., Artificial Neural Networks. 1st. Ed., McGraw Hill, New York, New York, United States, 1997.
- [102] Haykin, S., Neural Networks: A Comprehensive Foundation. Second Edi. Ed., Prentice Hall, New Jersey, 1998.
- [103] Swingler, K., Applying Neural Networks: A Practical Guide. First Edit. Ed., Academic Press, New York, 317, 1996.
- [104] Karaboga, D., An idea based on Honey Bee Swarm for Numerical Optimization. Technical Report TR06, Erciyes University, 10, 2005.
- [105] Karaboga, D., Basturk, B., A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of Global Optimization*, 39(3), 459–471, 2007.
- [106] Akay, B., Karaboga, D., Solving Integer Programming Problems by Using Artificial Bee Colony Algorithm. *AI\*IA 2009: AI\*IA 2009: Emergent Perspectives in Artificial Intelligence*, Berlin, 355–364, 2009.
- [107] Karaboğa, D., Yapay Zeka Optimizasyon Algoritmaları. Üçüncü Bas. Ed., Nobel Yayıncılık, Ankara, 231, 2014.

- [108] Wu, Q., Peng, C., Wind Power Generation Forecasting Using Least Squares Support Vector Machine Combined with Ensemble Empirical Mode Decomposition, Principal Component Analysis and a Bat Algorithm. *Energies*, 9(4), 261, 2016.

## ÖZGEÇMİŞ

Mustafa Akpınar, 1983 yılında Adapazarı'nda doğdu. 1994 yılında Ahmet Akkoç İlkokulu'ndan mezun oldu. Orta öğretim ve lise öğrenimini Figen Sakallıođlu Anadolu Lisesi'nde 1998 ve 2001 yıllarında tamamladı. 2001 yılında Sakarya Üniversitesi, Makina Mühendisliđi Bölümü'ne başladı ve 2006 yılında bitirdi. 2007 yılında Sakarya Üniversitesi, Makina Mühendisliđi Bölümünde yüksek lisans eğitime başladı ve 2010 yılında tamamladı. 2004 yılında başladığı Anadolu Üniversitesi, İktisat Bölümünü 2010 yılında bitirdi. Bu süre içinde 2009 yılında Sakarya Üniversitesi, Bilgisayar Mühendisliđi Bölümü'nde eğitimine başladı. 2012 Ocak'da Bilgisayar Mühendisliđi Bölümünden mezun oldu ve aynı dönem Sakarya Üniversitesi Bilgisayar Mühendisliđi Bölümü'nde yüksek lisansa başladı. 2014 Ocak'da yüksek lisanstan mezun oldu ve Sakarya Üniversi, Bilgisayar Mühendisliđi Bölümü'nde doktora öğrenimine başladı. 2012 Ekim'de Araştırma Görevlisi olmadan önce Divan Mobilya, Kromel Makina ve AGDAŞ gibi özel sektörden çeşitli şirketlerde de çalışmıştır.