

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TALEP TAHMİNİ İÇİN GRİ TEMELLİ BİR YAKLAŞIM



DOKTORA TEZİ

Ceyda TANYOLAÇ BİLGİÇ

İşletme Mühendisliği Anabilim Dalı

İşletme Mühendisliği Programı

OCAK 2022

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TALEP TAHMİNİ İÇİN GRİ TEMELLİ BİR YAKLAŞIM

DOKTORA TEZİ

**Ceyda TANYOLAÇ BİLGİÇ
(507122001)**

İşletme Mühendisliği Anabilim Dalı

İşletme Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Ferhan ÇEBİ

OCAK 2022

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 507122001 numaralı Doktora Öğrencisi Ceyda TANYOLAÇ BİLGİÇ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “TALEP TAHMİNİ İÇİN GRİ TEMELLİ BİR YAKLAŞIM” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Ferhan ÇEBİ**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Cengiz KAHRAMAN**
İstanbul Teknik Üniversitesi

Prof. Dr. Şakir ESNAF
İstanbul Üniversitesi- Cerrahpaşa

Prof. Dr. Mehmet Mutlu YENİSEY
İstanbul Üniversitesi- Cerrahpaşa

Doç. Dr. Tuncay ÖZCAN
İstanbul Teknik Üniversitesi

Teslim Tarihi : 1 Aralık 2021
Savunma Tarihi : 11 Ocak 2022





Aileme,



ÖNSÖZ

Bu tez çalışmamı sunarken; doktora öğrenimim ve tez çalışmam boyunca desteğini hiçbir zaman esirgemeyen danışmanım Prof. Dr. Ferhan ÇEBİ'ye,

Tez çalışmalarım sırasında ve akademik hayatım boyunca beni hep destekleyen, çalışmam boyunca bana yol gösteren ve moral veren hocam Prof. Dr. Şakir ESNAF'a,

Tez çalışmalarım süresince bana zaman ayıran ve yapıcı eleştirileriyle yol gösteren hocam Prof. Dr. Cengiz KAHRAMAN'a,

Akademisyenliğe adım attığım günden bu yana manevi desteğini hep üzerimde hissettiğim hocam Prof. Dr. Alp BARAY'a,

Uzun ve zorlu bir süreç olan tez çalışmalarım boyunca bana destek olan Prof. Dr. Mehmet Mutlu YENİSEY hocam başta olmak üzere tüm hocalarıma ve çalışma arkadaşlarıma,

Tez çalışmamda bana yardımcı olan ve zaman ayıran hocam Doç. Dr. Tuncay ÖZCAN'a,

Benimle birlikte sevinip, birlikte üzülen ve her daim maddi ve manevi desteklerini esirgemeyen aileme, bu süreçte tıkanıp her noktada yardımcı olan, fikir veren sevgili eşim Boğaç BİLGİÇ'e, ve doktora sürecimin sonunda daha dünyaya gelmeden varlığının hissi ile beni motive eden, manevi destekçim, oğlum Barlas'a sonsuz teşekkürlerimi sunarım.

Kasım 2021

Ceyda TANYOLAÇ BİLGİÇ



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ	xv
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1 Tezin Amacı	1
1.2 Tezin Literatüre Katkısı	2
1.3 Tezin Organizasyonu	2
2. LİTERATÜR TARAMASI	5
3. TALEP TAHMİNİ	13
3.1 Talep Tahmini İlkeleri	13
3.2 Talep Tahmin Yöntemleri	14
3.2.1 Kalitatif yöntemler	14
3.2.2 Kantitatif (İstatistiksel) yöntemler	15
3.2.3 Yapay zeka ve sezgisel algoritmalar	16
4. GRİ SİSTEM TEORİSİ VE GRİ MODELLEME	17
4.1 Gri Sistem Teorisi	17
4.2 Gri Tahmin Modelleri	21
4.2.1 GM (1,1)	21
4.2.2 Yuvarlanma mekanizmalı GM(1,1)	22
4.2.3 Hata analizi	23
5. BULANIK GRİ MODEL	25
6. METASEZGİSELLER	29
6.1 Metasezgisellerin Sınıflandırılması	30
6.2 Genetik Algoritma	32
6.3 Parçacık Sürü Optimizasyonu	36
6.4 Güve-Işık Optimizasyonu	39
7. ÖNERİLEN MODELLER	47
7.1 ÜBGM(1,1) Parametre Optimizasyonu Modeli	47
7.1.1 GA ile ÜBGM(1,1) parametre optimizasyonu	49
7.1.2 PSO algoritması ile ÜBGM(1,1) parametre optimizasyonu	50
7.1.3 GIO algoritması ile ÜBGM(1,1) parametre optimizasyonu	51
7.2 Yuvarlanma Mekanizmalı ÜBGM(1,1)	53
7.3 Yuvarlanma Mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu	54
7.3.1 Genetik algoritma ile yuvarlanma mekanizmalı ÜBGM(1,1) parametre optimizasyonu	54

7.3.2 PSO algoritması ile yuvarlanma mekanizmalı ÜBGM(1,1) parametre optimizasyonu	55
7.3.3 GIO algoritması ile yuvarlanma mekanizmalı ÜBGM(1,1) parametre optimizasyonu	56
8. ÜBGM(1,1) MODELLERİ VE GERÇEK HAYAT UYGULAMASI.....	59
8.1 ÜBGM(1,1) ile Elektrik Yüğü Tahmini	63
8.2 GA-ÜBGM(1,1) Parametre Optimizasyonu ile Elektrik Yüğü Tahmini	67
8.3 PSO-ÜBGM(1,1) Parametre Optimizasyonu ile Elektrik Yüğü Tahmini.....	71
8.4 GIOA-ÜBGM(1,1) Parametre Optimizasyonu ile Elektrik Yüğü Tahmini	75
8.5 Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yüğü Tahmini	79
8.6 GA-Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yüğü Tahmini	86
8.7 PSO-Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yüğü Tahmini.....	93
8.8 GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yüğü Tahmini..	101
8.9 Sonuçların Değerlendirilmesi.....	108
9. SONUÇLAR	131
KAYNAKLAR.....	133
EKLER	143
ÖZGEÇMİŞ.....	171

KISALTMALAR

AA	: Armonik Arama
ARMA	: Otoregresif Hareketli Ortalamalar
ARIMA	: Birleştirilmiş Otoregresif Hareketli Ortalamalar
ASA	: Altın Sinüs Algoritması
AT	: Altın Top
BFO	: Beyin Fırtınası Optimizasyonu
BÜİ	: Birinci Dereceden birikimli üretim işlemi
COVID 19	: Yeni Koronavirüs Hastalığı
ÇEY	: Çapraz Entropi Yöntemi
EPDK	: Enerji Piyasası Düzenleme Kurumu
FOA	: Futbol Oyunu Algoritması
GA	: Genetik Algoritma
GBHO	: Gazların Brown Hareketi Optimizasyonu
GİO	: Güve-Işık Optimizasyonu
GİOA	: Güve-Işık Optimizasyonu Algoritması
GİG	: Genel İndirgenmiş Gradyan Algoritması
GM (1,1)	: Tek değişkenli Gri Model (1,1)
GM (1,N)	: Çok değişkenli Gri Model (1,N)
GSYİH	: Gayri Safi Yurtiçi Hasıla
KA	: Kültürel Algoritma
KDA	: Kara Delik Algoritması
KKO	: Karınca Kolonisi Optimizasyonu
KOKH	: Kök Ortalama Kare Hata
KRO	: Kimyasal Reaksiyon Optimizasyonu
MARS	: Çok Değişkenli Adaptif Regresyon Eğrileri
MKY	: Müzik Kompozisyonu Yöntemi
NGBM (1,1)	: Tek değişkenli Doğrusal Olmayan Gri Bernoulli Model
NGBM (1,N)	: Çok değişkenli Doğrusal Olmayan Gri Bernoulli Model
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hatası
PSO	: Parçacık Sürü Optimizasyonu
SKA	: Sinüs Kosinüs Algoritması
SO	: Spiral Optimizasyonu
TA	: Tabu Arama
TB	: Tavlama Benzetimi
ÜBGM(1,1)	: Tek değişkenli Üçgen Bulanık Gri Model
YA	: Yarasa Algoritması
YAK	: Yapay Arı Kolonisi
YAKA-MGM(1,1)	:Yapay Arı Kolonisi Algoritması tabanlı Metabolik Gri Model
YKA	: Yapay Kabile Algoritması
YSA	: Yapay Sinir Ağları



SEMBOLLER

a	: Gelişme katsayısı
b	: Gri kontrol değişkeni
c₁ , c₂	: Öğrenme parametreleri
F	: Işık Matrisi
g*	: Global en iyi
I	: Güvelerin ilk rassal konumu
i	: Zaman
k	: Bağımsız değişken
lb	: Alt sınır
M	: Güve Matrisi
MFO	: Global optimal fonksiyonu
OF	: Işık Uygunluk Fonksiyonu
OM	: Güve Uygunluk Fonksiyonu
P	: Güvelerin hareketi
p_c	: Çaprazlama Oranı
p_m	: Mutasyon oranı
T	: Arama sürecinin bitimi
ub	: Üst sınır
v_i	: i. parçacığın hız vektörü
x_i	: i. parçacığın konum vektörü
x_i*	: Yerel en iyi
x⁽⁰⁾	: Orijinal zaman serisi
$\hat{x}^{(0)}$	: Tahmin değeri
x⁽¹⁾	: Monoton artan seri
$\tilde{x}^{(0)}$	: Üçgen bulanık zaman serisi
x_L⁽⁰⁾	: Olası en küçük değer
x_M⁽⁰⁾	: Olası değer
x_R⁽⁰⁾	: Olası en büyük değer
$\tilde{x}^{(1)}$	: Üçgen bulanık monoton artan seri
$\hat{\tilde{x}}^{(0)}$	: Üçgen bulanık tahmin değeri
α, β, γ	: Geliştirme parametresi ağırlıkları
Δt	: Zaman değişimi
λ	: Yatay düzeltme katsayısı
$\tilde{\lambda}$	: Bulanık yatay düzeltme katsayısı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1: Belirsizlik modellerinin farkları	19
Çizelge 4.2: Gri kavramının özellikleri	20
Çizelge 6.1: GIOA'nın özellikleri	41
Çizelge 8.1: Ara yük bloğuna ait 30 günlük elektrik yükü	60
Çizelge 8.2: Temel yük bloğuna ait 30 günlük elektrik yükü	61
Çizelge 8.3: Zirve yük bloğuna ait 30 günlük elektrik yükü	62
Çizelge 8.4: Algoritmaların parametre değerleri	63
Çizelge 8.5: Ara yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.	64
Çizelge 8.6: Temel yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.	64
Çizelge 8.7: Zirve yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.	65
Çizelge 8.8: Ara yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.	66
Çizelge 8.9: Temel yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.	66
Çizelge 8.10: Zirve yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.	67
Çizelge 8.11: Ara yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.	68
Çizelge 8.12: Temel yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.	68
Çizelge 8.13: Zirve yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.	69
Çizelge 8.14: Ara yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.	70
Çizelge 8.15: Temel yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.	71
Çizelge 8.16: Zirve yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.	71
Çizelge 8.17: Ara yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.	72
Çizelge 8.18: Temel yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.	72
Çizelge 8.19: Zirve yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.	73
Çizelge 8.20: Ara yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.	74
Çizelge 8.21: Temel yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.	74
Çizelge 8.22: Zirve yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.	75
Çizelge 8.23: Ara yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.	75
Çizelge 8.24: Temel yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.	76
Çizelge 8.25: Zirve yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.	76
Çizelge 8.26: Ara yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.	77
Çizelge 8.27: Temel yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.	78
Çizelge 8.28: Zirve yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.	78
Çizelge 8.29: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).	79
Çizelge 8.30: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).	80
Çizelge 8.31: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).	80

Çizelge 8.32: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=7$).....	81
Çizelge 8.33: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	82
Çizelge 8.34: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=7$).	82
Çizelge 8.35: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).....	83
Çizelge 8.36: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	84
Çizelge 8.37: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	84
Çizelge 8.38: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).....	85
Çizelge 8.39: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=14$).	85
Çizelge 8.40: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=4$).	86
Çizelge 8.41: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	86
Çizelge 8.42: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	87
Çizelge 8.43: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	88
Çizelge 8.44: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	88
Çizelge 8.45: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=10$).	89
Çizelge 8.46: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).	90
Çizelge 8.47: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	90
Çizelge 8.48: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	91
Çizelge 8.49: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	91
Çizelge 8.50: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).	92
Çizelge 8.51: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=4$).	93
Çizelge 8.52: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	93
Çizelge 8.53: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	94
Çizelge 8.54: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	95
Çizelge 8.55: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	95
Çizelge 8.56: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	96

Çizelge 8.57: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini($k^*=10$)	96
Çizelge 8.58: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).	97
Çizelge 8.59: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	98
Çizelge 8.60: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	98
Çizelge 8.61: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	99
Çizelge 8.62: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).	99
Çizelge 8.63: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini($k^*=4$)	100
Çizelge 8.64: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	100
Çizelge 8.65: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	101
Çizelge 8.66: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	102
Çizelge 8.67: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	102
Çizelge 8.68: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	103
Çizelge 8.69: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=10$).	104
Çizelge 8.70: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	104
Çizelge 8.71: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	105
Çizelge 8.72: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	106
Çizelge 8.73: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).	106
Çizelge 8.74: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).	107
Çizelge 8.75: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=4$).	107
Çizelge 8.76: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).	108
Çizelge 8.77: Dokuz adet test verisi için OMYH değerleri	109
Çizelge 8.78: Altı adet test verisi için OMYH değerleri.	110
Çizelge 8.79: Ara yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (%30) test verisi).	111
Çizelge 8.80: Ara yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 20 test verisi).	112
Çizelge 8.81: Temel yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 30 test verisi).	113
Çizelge 8.82: Temel yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 20 test verisi).	114

Çizelge 8.83: Zirve yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (%30 test verisi).	115
Çizelge 8.84: Zirve yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 20 test verisi).	116
Çizelge A.1 : 4-10 Ocak Türkiye'nin elektrik tüketimi	145
Çizelge A.2 : 11-17 Ocak Türkiye'nin elektrik tüketimi.....	145
Çizelge A.3 : 18-24 Ocak Türkiye'nin elektrik tüketimi.....	146
Çizelge A.4 : 25- 31 Ocak Türkiye'nin elektrik tüketimi.....	147
Çizelge A.5 : 1-7 Şubat Türkiye'nin elektrik tüketimi	147
Çizelge A.6 : 8-13 Şubat Türkiye'nin elektrik tüketimi	148



ŞEKİL LİSTESİ

Sayfa

Şekil 5.1: Üçgen bulanık sayı	25
Şekil 6.1: Metasezgisellerin sınıflandırması	33
Şekil 6.2: Genetik algoritmada bir çaprazlama örneği	34
Şekil 6.3: Genetik algoritmada bir mutasyon örneği	34
Şekil 6.4: Genetik algoritma akış şeması	35
Şekil 6.5: Genetik algoritma sözde kodu	36
Şekil 6.6: PSO'da bir parçacığın yerel en iyiye ve global en iyiye hareketi	37
Şekil 6.7: PSO sözde kodu	38
Şekil 6.8: PSO akış şeması	39
Şekil 6.9: Enine yönlendirme	40
Şekil 6.10: Yakın ışık kaynakları etrafında spiral uçuş yolu	40
Şekil 6.11: Güve-ışık eşleşmesi	43
Şekil 6.12: Logaritmik spiral, ışığın etrafındaki alan ve t'ye göre konum	44
Şekil 6.13: Güve-ışık optimizasyonu algoritması akış şeması	45
Şekil 6.14: Güve - ışık algoritması sözde kodu	46
Şekil 7.1: GA-ÜBGM(1,1) modeline ait akış şeması	50
Şekil 7.2: PSO-ÜBGM(1,1) modeline ait akış şeması	51
Şekil 7.3: GIO-ÜBGM(1,1) modeline ait akış şeması	52
Şekil 7.4: Yuvarlanma mekanizmalı ÜBGM(1,1) modeli	53
Şekil 7.5: GA-yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması	54
Şekil 7.6: PSO-yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması	56
Şekil 7.7: GIOA-yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması	57
Şekil 8.1: Ara yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA- ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi	117
Şekil 8.2: Temel yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA- ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi	118
Şekil 8.3: Zirve yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA- ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi	118
Şekil 8.4: Ara yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi	119
Şekil 8.5: Temel yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi	120
Şekil 8.6: Zirve yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi	121
Şekil 8.7: Ara yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi	121

Şekil 8.8: Temel yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi.	122
Şekil 8.9: Zirve yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi.	123
Şekil 8.10: Ara yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	124
Şekil 8.11: Temel yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	124
Şekil 8.12: Zirve yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	125
Şekil 8.13: Ara yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	126
Şekil 8.14: Temel yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	127
Şekil 8.15: Zirve yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	128
Şekil 8.16: Ara yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	128
Şekil 8.17: Temel yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	129
Şekil 8.18: Zirve yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).	130

TALEP TAHMİNİ İÇİN GRİ TEMELLİ BİR YAKLAŞIM

ÖZET

Gri sistem teorisi ilk olarak 1989 yılında literatüre kazandırılmış bir çalışma alanıdır. Gri sistem teorisinin alt konularından biri olan gri tahmin ise, bu tez çalışmasının da temelini oluşturmaktadır.

Talep tahmini çalışmaları literatürde sıklıkla karşılaşılan alanlardan olup, bu çalışmada talep tahmini için gri tahmin modellerinden yararlanılmıştır. Talep tahmininde ise enerji ve dolayısıyla elektrik talebi (tüketimi) tahmini çalışmaları günümüzde önem arz etmektedir. Kapasitenin doğru planlanması ve doğru fiyatlandırılma politikası, doğru tüketim tahminleriyle başarılı olacaktır.

Tüm bu durumlardan yola çıkarak; bu tez çalışmasının temel amacı, talep tahmini için yeni bir model sunmaktır. Bu çalışmada gri modelin küçük boyutlu verilerle yapılan tahminlerde başarılı olmasının avantajına odaklanarak hata oranını daha da küçükleyecek melez modeller sunmak amaçlanmıştır.

Tezde elektrik tüketimi tahmini üzerine yapılan uygulamada kullanılan ve önerilen modeller, literatürde ilk kez kullanılan hibrit modellerdir. Bu yönüyle çalışma literatüre önemli katkı sağlamaktadır.

Literatür taraması ile gri tahmin modeller kullanılarak yapılan tahmin çalışmaları ve alanları, elektrik tüketim tahmininde kullanılan gri modeller ve Türkiye’de yapılan elektrik tüketimi tahmin çalışmalarında kullanılan modeller genel olarak incelenmiş ve bu bilgiler ışığında hibrit bir model olan bulanık GM (1,1) parametre optimizasyonu Güve- Işık Optimizasyonu Algoritması modeli önerilmiştir. Önerilen bu modele yuvarlanma mekanizması da eklenerek bir model önerisinde daha bulunulmuştur. Yapılan literatür taramasında gri modellerde parametre optimizasyonu çalışmaları da incelenmiş ve sıklıkla kullanılan metasezgisellerin olduğu çalışmalara yer verilmiştir.

Çalışmada literatür taraması ve talep tahmini konusundan sonra literatürde en çok kullanılan Gri modellere ve bu tezin temel modeli olan Üçgen Bulanık GM(1,1) modeline detaylı biçimde yer verilmiştir. Sonrasında ise; metasezgisel algoritmalar konusu incelenmiş ve parametre optimizasyonunda kullanılan metasezgiseller detaylıca anlatılmıştır.

Önerilen modellerin denklemleri ayrıntılı bir şekilde ifade edilmiş ve Türkiye’nin kısa dönem elektrik tüketimi tahmini konusunda bir çalışma yapılarak sonuçlar yorumlanmıştır. Uygulama, MATLAB 2018b programından yararlanılarak yapılmıştır. Önerilen modeller literatürde var olan gri model ile kıyaslanarak tahmin performansı başarımları ölçülmüştür. Kullanılan hata ölçütü literatürde sıklıkla kullanılan Ortalama Mutlak Yüzde Hatası (OMYH)’dır. Modellerde kullanılan ve literatürde yeni olan Güve- Işık Optimizasyonu Algoritması’nın performansı ise literatürde parametre optimizasyonu için sıklıkla kullanılan algoritmalarla kıyaslanarak ölçülmüştür. Söz konusu algoritma ile önerilen modeller Genetik Algoritma ile

kıyaslandığında daha iyi bir tahmin performansı sergilemekte olup; PSO ile kıyaslandığında en az onun kadar güçlü olduğu sonucuna varılmıştır. Kıyaslama yapılırken programın çalışma süresi ve metasezgisellerin optimum noktayı yakaladıkları iterasyon sayıları dikkate alınmıştır. Uygulama sonuçlarına bakıldığında önerilen modellerin tahmin performansının geliştiği gözlemlenmiştir. GIOA, Genetik Algoritmaya göre süreler ve iterasyon sayıları açısından çok daha iyi sonuç verirken; PSO ile kıyaslandığında ise yakın süreler ve iterasyon sayıları vermekte olduğu gözlemlenmiştir.

Son olarak, yapılan araştırma ve edinilen bilgiler ışığında tez çalışmasının sonuçları yorumlanmış ve gelecek çalışmalarla ilgili önerilerde bulunulmuştur.



A GREY BASED APPROACH TO DEMAND FORECASTING

SUMMARY

Grey system theory is a field of study that was first introduced in 1989. Grey forecasting, which is one of the subtopics of grey system theory, forms the basis of this thesis.

Grey system theory is a new method that focuses on problems with small samples and lack of information. Obtains useful information by using partial information available in uncertain systems. In this way, grey system theory analyzes indeterminate systems. Thus, the operational behaviors of the system and the evolution principles of these behaviors can be accurately defined and followed effectively.

Demand forecasting studies are frequently encountered in the literature, and in this study, grey forecasting models are used for demand forecasting. In demand forecasting, energy and therefore electricity demand (consumption) forecasting studies are really important today. Correct planning of capacity and correct pricing policy will be successful with forecasting the consumption correctly.

The models used and suggested in the application on electricity consumption estimation in the thesis are the hybrid models used for the first time in the literature. In this respect, the study makes an important contribution to the literature.

With the literature review, forecasting studies and fields using grey forecasting models, grey models used in electricity consumption estimation and models used in electricity consumption forecasting studies conducted in Turkey were examined in general, and in the light of this information, a Triangular Fuzzy GM (1,1) parameter optimization model based on Moth- Flame Optimization Algorithm, which is a hybrid model, is proposed. By adding the rolling mechanism to this proposed model, another model has been proposed. In the literature review, parameter optimization studies in grey models were also examined and studies with frequently used metaheuristics were included.

In the study, after the literature review and demand forecasting are explained, the most used Grey models in the literature (GM (1,1) and rolling mechanism GM (1,1)) and the Triangular Fuzzy GM (1,1) model, which is the basic model of this thesis, are given in detail. In the traditional GM (1,1) model, the entire data set is used for forecasting. Sometimes, however, data may exhibit different trends and characteristics. It is recommended to use the GM (1,1) model with a rolling mechanism instead of the traditional GM (1,1) model in such chaotic and different data.

Afterwards; the subject of metaheuristic algorithms is examined and metaheuristics used in parameter optimization are explained in detail.

Metaheuristics are algorithmic constructs that are applied to various optimization problems, usually with only a few modifications to fit the given problem. Metaheuristics have been classified in various ways in the literature. In this study, the

most frequently used classifications are included. GA and PSO algorithm are the most widely used metaheuristics in the literature.

GA is one of the most popular evolutionary algorithms. GA is also a population-based algorithm. PSO is the most widely used algorithm among swarm intelligence based algorithms with its flexibility and simplicity. While imitating herd behaviors, it also has ties to evolutionary programming and genetic algorithms.

In the study, both algorithms are explained in detail. The working principles of the algorithms are explained step by step and pseudo-codes are written. Finally, the working principles are visualized with flow charts.

The Moth-Flame Optimization Algorithm used in the thesis is given in more detail. Algorithm principles are explained and the working mechanism is explained step by step. As in PSO and GA, pseudo -codes are explained in this algorithm and a flowchart is given.

Moths fly by taking advantage of the moonlight. Moths, which are insects similar to the butterfly family, have a special way of finding their way at night called “transverse orientation.” The Moth-Flame Optimization (MFO) Algorithm was inspired by these special flight methods of moths.

The equations of the proposed models have been expressed in detail. Three basic models are explained in detail and PSO, GA and MFO based parameter optimized models are also explained separately. Each algorithm is integrated into the proposed models.

The decision variables in the proposed models are the horizontal correction parameter λ , which is a triangular fuzzy number, and α , β and γ which constitutes the improvement parameter a .

After the detailed explanation of the proposed models, an application has been made on Turkey's short-term electricity consumption forecasting, and the results have been interpreted.

Turkey's electricity demand has been estimated using hourly electricity consumption data. The models presented in the study were used in demand forecasting. The forecasting power of the proposed models was measured using the mean absolute percent error (MAPE), which is an error measure. The TFGM (1,1) model, which exists in the literature and is explained in detail in this study, and the proposed models were compared using the MAPE error criterion.

In this study, since Turkey's hourly electricity consumption is considered, it is taken into account that EMRA divides one-day electricity demand into three periods. The hours between 22:00 and 06:00 are called night hours, between 06:00 and 17:00 are called daytime hours, and between 17:00 and 22:00 are called peak hours. Night hours are considered as intermediate load, peak hours as peak load, and daytime hours as base load.

The application was made by considering the data size in two different dimensions as 80 % education-20 % test and 70 % education-30 % test.

The application has made using the MATLAB 2018b program. The error criterion used is the Mean Absolute Percent Error (MAPE), which is frequently used in the literature. The performance of the Moth-Flame Optimization Algorithm, which is used in the models and is new in the literature, has been measured by comparing it with the

algorithms frequently used for parameter optimization in the literature. The models proposed with the said algorithm show better prediction performance when compared to the Genetic Algorithm; It has been concluded that it is at least as strong as PSO when compared to it. While comparing, the running time of the program and the number of iterations in which the metaheuristics reached the optimum point were taken into account. When the application results are examined, it has been observed that the prediction performance of the proposed models has improved.

When the results of the application are examined, it has been determined that the estimation error obtained with the MFOA-Rolling mechanism TFGM (1,1) among the proposed models has the lowest estimation error in both data sizes and in all three load blocks. When the run times were examined, it was concluded that MFOA had shorter times than the times obtained with GA and obtained close times with the PSO Algorithm. Based on all these analyzes, it is concluded that the performance of the MFOA used in the proposed and newly introduced models is as successful as the algorithms frequently used in the literature. While MFOA gives much better results in terms of durations and iteration numbers compared to the Genetic Algorithm; when compared to PSO, it has been observed that it gives close times and iteration numbers.

Finally, the study was interpreted in the light of the results obtained and suggestions were made for future studies.



1. GİRİŞ

Bu tez çalışmasında literatürde yeni olan Güve-Işık Optimizasyonu Algoritması ile Üçgen Bulanık GM(1,1) modeli parametre optimizasyonu modelleri geliştirilmiş ve bu melez modeller ile elektrik tüketimi tahmini üzerine bir uygulama çalışması yapılmıştır.

Gri modeller Gri Sistem Teorisinin alt konularından Gri tahmin konusu modelleridir. Gri sistem teorisi 1989'da ortaya atılan bir konudur ve günümüze kadar çeşitli alanlarda yapılan çalışmalar bulunmaktadır. Gri modellerin en başarılı olduğu nokta veri boyutlarının küçük olduğu durumlardır. Gri tahmin modelleri ile yapılan çalışmalara oldukça rastlanmasına karşın; modeller, tahmin doğruluğunu artırma yönünde gün geçtikçe geliştirilmektedirler. Bu çalışmada tek değişkenli bir zaman serisi konusu olan GM(1,1), bulanık sayılarla entegre edilerek, diğer çalışmalardan farklı olarak hem parametreleri hata oranını en küçükleyecek şekilde optimize edilmiş hem de optimizasyon için kullanılan metasezgisel Güve- Işık Optimizasyonu algoritması söz konusu model ile ilk kez kullanılarak yeni bir çalışma sunulmuştur. Sunulan melez tahmin modelleriyle elde edilen tahmin sonuçlarının düşük hata oranı vermesi amaçlanmış ve başarılı olunmuştur.

1.1 Tezin Amacı

Üretim ve hizmet sektöründe planlama yaparken öngörülerin gerçek değerleri yansıtması oldukça önem arz etmektedir. Talep tahmininin doğruluğu, gerçeğe en yakın değerleri vermesi planlamanın doğru ve etkin bir şekilde gerçekleştirilebilmesi için oldukça önemlidir. Bu önemden yola çıkarak; bu tez çalışmasının temel amacı, talep tahmini için yeni bir model sunmaktır.

Bu çalışmada gri modelin küçük boyutlu verilerle yapılan tahminlerde başarılı olmasının avantajına odaklanarak hata oranını daha da küçükleyecek melez modeller sunmak amaçlanmıştır.

Önerilen modellerle daha önce literatürde yapılan bir çalışmaya rastlanılmamış olan Güve- Işık Optimizasyonu Algoritması ile Üçgen Bulanık GM(1,1) parametre optimizasyonu modeli geliştirmek ve melez bir model sunmak bir diğer amaçtır.

Gri tahmin modellerinin parametre optimizasyonunda genellikle kullanılan, literatürde çeşitli alanlarda var olan algoritmalar ile önerilen modellerin karşılaştırılması ve böylece modellerin tahmin performans başarımını ölçmek de bu tezin amaçlarından biridir.

Bir diğer amaç ise; önerilen modeller ile Türkiye'nin elektrik tüketimi tahminini yapmak ve tezin çıkış noktası olan literatürdeki benzer model ile karşılaştırarak modellerin tahmin performansını ölçmektir.

1.2 Tezin Literatüre Katkısı

Bu tez çalışması önerilen modellerle, literatürde var olan üçgen bulanık gri modellerden farklı olarak parametre optimizasyonunda daha önce kullanılmayan Güve-Işık Optimizasyonu algoritması kullanılan ilk çalışma olarak literatüre katkıda bulunmaktadır.

Yine literatürde karşılaşılan gri model parametre optimizasyonlarında en iyilenen parametre olan λ (yatay düzeltme katsayısı) bu tez çalışmasında net sayı olarak değil; üçgen bulanık sayı olarak ele alınmıştır. Ayrıca gelişme parametresi "a"yı oluşturan ağırlıklar (α, β, γ) da en iyilenen parametrelerdir. Literatürde bu açıdan da ilk çalışma olması önem arz etmektedir. Önerilen modellerin tahmin performansları varolan model ve algoritmalar ile kıyaslanarak da test edilmiş ve başarılı sonuçlar elde edilmiştir. Modellerle elektrik tüketimi alanında uygulama yapılmış olup; bu alanda önerilen modellerle yapılan ilk çalışma olarak literatüre katkı sağlamıştır.

1.3 Tezin Organizasyonu

Tez çalışması dokuz temel bölümden oluşmaktadır. Birinci bölümü oluşturan tezin amacı ve katkısının açıklandığı giriş bölümünden sonra ikinci bölümde literatür taraması yer almaktadır. Bu bölümde gri model ile yapılan çalışmalar açıklanmış, hangi alanlarda çalışmalar yapıldığı anlatılmıştır. Tezin uygulama alanı olan elektrik tüketimi alanında yapılan çalışmalara yer verilmiştir. Ayrıca bulanık gri model çalışmalarına da değinilmiştir. Tezde kullanılan Güve-Işık Optimizasyonu

Algoritmasının kullanıldığı alanlara ve algoritma kullanılarak yapılan gri model tahmin çalışmalarına yer verilmiştir.

Tezin üçüncü bölümünde talep tahmini üzerinde kısaca durulmuştur. Genel tahmin yöntemleri açıklanmıştır. Dördüncü bölümde bu tezin ana konusu gri sistem teorisi ve gri modelleme konusu detaylıca anlatılmıştır. Gri tahmin modellerinin denklemleri açıklanmıştır. Tahmin performansını ölçmek için kullanılan hata ölçütlerine kısaca değinilmiştir.

Beşinci bölümde önerilen modellerin temelini oluşturan bulanık gri modele yer verilmiştir.

Altıncı bölümde metasezgisel konusu üzerinde durulmuş, genel sınıflandırma açıklanmıştır. Tez çalışmasında kullanılan Genetik Algoritma, Parçacık Sürü Optimizasyonu ve Güve Işık Optimizasyonu algoritmaları detaylıca anlatılmıştır.

Yedinci bölümde önerilen modellere yer verilmiştir. Modellerin denklemleri detaylıca açıklanmıştır.

Sekinci bölümde önerilen modeller ve karşılaştırılacak modeller ile elektrik tüketimi uygulaması yapılmış ve sonuçlar yorumlanmıştır.

Son olarak dokuzuncu bölümde, uygulama sonuçları ışığında değerlendirme yapılmış ve gelecek çalışmalarla ilgili önerilerde bulunulmuştur.



2. LİTERATÜR TARAMASI

Gri sistem teorisi ilk olarak 1982 yılında Julong Deng tarafından ortaya atılmıştır. 1989'da J. Deng, gri sistem teorisi ve gri ilişkisel analiz, gri tahmin, gri karar verme vb. onun temel içerik ve konuları hakkında bir çalışma yapmıştır (Deng, 1989).

Gri teori, daha sonraki yıllarda optimizasyon problemlerinde kullanılmak üzere de formüle edilmiş ve detaylı bir formülasyon çalışması yapılmıştır (Zheng ve Lewis, 1993). Bu çalışma, açıklanan formülasyonlar ile daha çok alanda çalışılabileceği önerisinde bulunmaktadır. Daha ileriki yıllarda GM(1,1) modelinde parametre optimizasyonu yapılarak; sabit 0,5 değeri alan λ parametresinin "0" ile "1" değerleri arasında bir değer almasının hata oranını düşürdüğünü öne sürmüşlerdir (Wen ve diğ., 2000). Model denklemlerle açıklanarak, Penghu bölgesindeki yıllık balık sayısı tahmini çalışmasına uygulanarak parametrenin 0,5 değerinden farklı bir değer kullanılmasıyla daha küçük bir hata oranına (OMYH) sahip olduğu gösterilmiştir.

Gri teoriye dayalı yaklaşımlar deprem, tarım, kaya mekaniği birçok alanda da uygulanmıştır (An ve diğerleri, 2012), (Xiuwen, 1994). Sıcaklık tahmini için, bulanık modellerle yapılan tahminlerin, gri model ile yapılan tahminlerle kıyaslandığı bir çalışmaya rastlanmıştır (Huang ve Huang, 1997). Sıklıkla kullanılan opto-elektronik endüstrisi verileri ile de GM(1,1) modeli kullanılarak tahmin çalışması yapılmıştır (Lin ve Yang, 2003).

İktisat alanında, Çin'in 1990- 2007 yılları arasındaki GSYİH değerleri GM(1,1)'in parametre optimizasyon modeli ile tahmin edilmiştir (Shang ve Pei, 2009). Parametre optimizasyonunda Parçacık Sürü Optimizasyonu Algoritması kullanılmış olup; model, geleneksel Gri model ile kıyaslandığında daha düşük bir hata oranı ile daha güçlü bir tahmin performansı ortaya koymuştur.

Tayvan entegre devre endüstrisinin çıktı tahmininde genetik algoritma tabanlı çok değişkenli gri model optimizasyon modeli kullanılmıştır (Hsu, 2009). Model geleneksel GM(1,1) ve geleneksel GM(1,N) modelleri ile kıyaslanmıştır. Hata ölçütü olarak OMYH kullanılmış olup, önerilen modelin daha kabul edilebilir bir hata oranına

sahip olduđu sonucuna varılmıştır. Finansal alanda dolar kuru tahmininde Gri model (1,1) ve Gri Verhulst modeli ve Fourier Serileri ile geliştirilmiş gri model kullanılmıştır. Geliştirilmiş Gri Modelin tahmin performansının diğeri modellerden daha iyi olduđu sonucuna varılmıştır (Kayacan ve diğ., 2010). Aynı şekilde finansal alanda NGBM(1,1) modeli kullanılarak yapılan bir çalışmada, hisse senedi endeksi tahmini yapılmıştır (Chen ve diğ., 2010).

Tayvan opto- elektronik endüstrisi verilerine uygulanan parametre optimizasyonlu NGBM(1,1) modeli yine aynı çalışmada Çin'in seçilen 30 farklı bölgesinde atık suların tahliye edilme oranının tahminine de uygulanmıştır (Wang ve diğ., 2011). Çalışma sonucunda elde edilen oranlara göre bölgelere önerilerde bulunulmuştur. Finansal alanda yapılan bir tahmin çalışmasında gri model parametre optimizasyonu modelinde kaotik PSO algoritması kullanılarak hibrit model ile tahmin yapılmıştır (Wang ve diğ., 2011). Çin'de kırsal kesimin net kişi başına gelirini Diferansiyel Evrim Algoritması tabanlı GM(1,1) modeli ile tahmin edilen bir çalışmaya rastlanmıştır (Zhao ve diğ., 2012). Çalışma söz konusu algoritma kullanılarak yapılan ilk hibrit model olma özelliğini taşımaktadır.

Eğitim harcamaları ve okul kayıt sayısı tahmini alanında da gri model ve yuvarlanma mekanizmalı GM(1,1) modeli kullanılmıştır (Tang ve Yin, 2012). Başka bir çalışmada havayolu endüstrisi ele alınmış ve gri model kullanılarak rotalardaki yolcuların sayısı tahmini yapılmıştır (Benítez ve diğ., 2013).

Çin'de demir ithalatı ve tüketimi tahmini için yuvarlanma mekanizmalı GM(1,1) modeli parametre optimizasyonu için PSO algoritması ile entegre edilerek bir hibrit model oluşturulmuştur (Ma ve diğ., 2013). Yine aynı model ile 2014 yılında bir çalışma yapılmıştır (Liu ve diğ., 2014). Modelin tahmin doğruluğunu göstermek için model üç farklı gerçek ekonomik veriye uygulanmıştır. Sonuçlar GM(1,1) ve Yuvarlanma mekanizmalı GM(1,1) ile kıyaslanmış ve önerilen model ile tahmin doğruluğunun arttığı sonucuna varılmıştır.

Döviz kuru tahmini çalışmasında NGBM (1,1) modeli optimizasyonu ile yüksek tahmin doğruluğu elde edilmiştir (Lu ve diğ., 2016). Elde edilen sonuçların olumlu olması üzerine önerilen model trafik akışı tahmini için kullanılmış ve başarılı bir çalışma ortaya konmuştur.

Motorlu taşıtların tahmini için bir çalışmada $GM(1,N)$ modelinde düzeltmeler yapılarak yeni bir model adı altında ($NGM(1,N)$) bir model önerisinde bulunulmuştur (Zeng ve diğ., 2016). Yapılan uygulama sonuçlarına göre önerilen modelin tahmin performansı başarılıdır. Hurda araç sayısı tahmini ile ilgili bir çalışmada tahmin modeli olarak parametre optimizasyonlu ve Fourier serisi modifikasyonlu gri tahmin modeli oluşturulmuştur (Ene ve Öztürk, 2017). Bu model Markov Zinciri teorisi ile geliştirilmiştir. Uygulamada Türkiye’den 12 bölge seçilmiş ve bu bölgelerde bulunan on yaşından büyük araba sayıları yıl bazında veri olarak kullanılmıştır. Geliştirilen modelin OMYH hata ölçütü bazında en iyi tahmin performansı değerine sahip olduğu ortaya konmuştur.

Pekin’de üçüncül endüstri (nakliye, depolama ve posta (NDP), toptan ve perakende, ticaret ve otel ve yemek hizmetleri (TPT&OYH), finansal aracılık (FA), gayrimenkul (G) ve diğer hizmetler (DH)) tahmini çalışmasında geliştirilmiş bir $GM(1,1)$ modeli kullanılmıştır (Wang ve diğ., 2017). Modelde veri temizleme için üstel ön işleme yöntemi uygulanarak, PSO tabanlı $GM(1,1)$ ile parametre optimizasyonu yapılmıştır.

Bir tahmin çalışmasında ise Gri modele Yapay Arı Kolonisi Algoritması entegre edilerek YAKA-MGM(1,1) modeli geliştirilmiştir. Model kömür ısı kaybı kapasitesi tahmininde kullanılarak tahmin performansı PSO ve GA tabanlı $GM(1,1)$ ile kıyaslanmıştır (Li ve diğ., 2018). Sonuçlar önerilen modelin tahmin doğruluğunun diğer modellere göre daha iyi olduğu göstermektedir.

Sağlık sektöründe yapılan bir tahmin çalışmasında Genetik Algoritma tabanlı $GM(1,1)$ modeli ve yuvarlanma mekanizmalı $GM(1,1)$ modeli parametre optimizasyonu modelleri önerilmiş ve yıllık bazda sağlık harcamaları tahmini yapılmıştır (Özcan ve Tüysüz, 2018). Çalışmanın sonucu adım adım ileriye götürülmüş ve en iyi modelin yuvarlanma mekanizmalı $GM(1,1)$ modeli parametre ve veri boyutu optimizasyonu olduğu uygulama ile gösterilmiştir.

Şahin, Metabolik NBGM(1,1) modeli ile parametre optimizasyonu çalışması yapmış ve Türkiye’nin sera gazı emisyon tahmininde kullanmıştır (Şahin, 2019). Parametre optimizasyonunda Genel İndirgenmiş Gradyan (GİG) algoritmasını modele entegre etmiştir.

Stok yönetimi ve sipariş miktarlarının planlanması konusunda bir karar verme yöntemi geliştirilen bir çalışmada gri tahminleme yönteminin de içinde bulunduğu karma bir tahmin yöntemi ile ileriye yönelik veriler tahmin edilmiştir (Yiğit, 2019).

Doğalgaz tüketimi tahminine yeni bir tahmin modeli öne süren bir çalışmada gri model geliştirilmiş ve homojen olmayan gri model adı altında yeni bir model sunulmuştur (Zheng ve diğ., 2020). Modelin tahmin performansı klasik gri model ile kıyaslanmıştır.

Ayrıca elektrik tüketimi tahmini çalışmaları incelenmiş ve literatürde karşılaşılan bazı çalışmalar kısaca açıklanmıştır.

Trigonometrik gri model ile elektrik tüketimi tahmin çalışmasına rastlanmıştır (Zhou ve diğ., 2006). Önerilen model ile GM(1,1)'in tahmin doğruluğunun daha da artırıldığı öne sürülmüştür.

Gri Markov tahmin modeli ile elektrik üretim ve tüketim tahmini yapılan bir çalışmada, Tahmin modelinin performansını ölçmek için sonuçlar GM(1,1) ile karşılaştırılmıştır (Huang ve diğ., 2007).

İncelenen başka bir çalışmada, PSO ile parametre optimizasyonlu doğrusal olmayan gri bernoulli modeli (NGBM(1,1)) kullanılarak uzun dönem elektrik tüketimi tahmini yapılmıştır (Zhou ve diğ., 2009). Çalışmada öncelikle model detaylıca anlatılmıştır. Hata ölçütü olan OMYH amaç fonksiyonu, λ ve λ üs değerleri ise karar değişkenleridir. PSO algoritması kullanılarak uygulanan modelde hata oranını minimize eden karar değişkenleri optimum değişkenler olarak belirlenmiştir.

GM(1,1) modeli yapılan bir çalışmada elektrik tüketimini tahmini yanında; karbon emisyonu ve ekonomik büyüme tahmini olmak üzere iki ayrı alanda kullanılmıştır (Pao ve Tsai, 2011). Model ARIMA model sonuçlarıyla karşılaştırılarak tahmin performansının daha başarılı olduğu ortaya konmuştur.

Genetik programlama algoritmasının entegre edilmesiyle önerilen hibrit gri tahmin modeli ile de elektrik tüketimi çalışması yapılmıştır (Lee ve Tong, 2011). 2012 yılında yapılan bir elektrik tüketimi çalışmasında veri kısa dönemli olarak ele alınmış ve adaptif GM (1,1) isimli bir model önerilmiştir (Li ve diğ., 2012). Model detaylı olarak açıklanarak uygulama ile tahmin performansı ortaya konmuştur. Tahmin performansının ölçülebilmesi için model geri yayılım yağay sinir ağları ve destek vektör regresyon modeli ile karşılaştırılmıştır.

Dalgacık dönüşümü ve gri model birleştirilerek sunulan bir model PSO ile geliştirilerek bir çalışmada detaylıca anlatılmıştır (Bahrami ve diğ., 2014). Modelin tahmin doğruluğunu ölçmek için New York ve İran'ın bir güne ait saatlik elektrik yükü tahmin edilmiş ve sonuçlar daha önce çalışılan modellerle karşılaştırılarak tahmin doğruluğunun daha yakın olduğu sonucu ortaya konmuştur.

Kısa dönem elektrik yükü tahmini çalışmasının ele alındığı bir makalede dalgacık dönüşümü ile Holt Winters yöntemi ve ağırlıklandırılmış en yakın komşu modelleri kullanılmıştır (Sudheer ve Suseelatha, 2015). Önerilen modellerin tahmin performansı başarımları yüksektir. Yıllık elektrik tüketimi tahminini ele alan aynı yıla ait bir çalışmada ise gri model ve Markov modeli tüketim verisine uygulanarak tahmin yapılmıştır (Nai-ming ve diğ., 2015). Makalede, modelin regresyon modeli ile karşılaştırması sonucu daha iyi bir tahmin performansı sergilediği sonucuna varılmıştır.

Bir elektrik tüketimi tahmini çalışmasında konvolüsyon integrali GM(1,N) modeli ile entegre edilmiş ve hibrit bir model sunulmuştur (Wang ve Hao, 2016). Modelin tahmin doğruluğu düşük çıkmış ve modelde parametre optimizasyonuna başvurularak sonuçlar iyileştirilmiştir. Modelin tahmin performansı ARMA ve GM(1,1) modellerinin tahmin performansı ile kıyaslanarak daha doğru bir tahmin değeri ortaya konulduğu gösterilmiştir.

Bir çalışmada, Güney Afrika için yoğun talep saatleri olan 18:00-20:00 arasındaki kısa dönem elektrik tüketimi tahmini için kısmi doğrusal regresyon yöntemi kullanılmıştır (Lebotsa ve diğ., 2018). Gri modele yuvarlanma mekanizması ve yeni bilgi önceliği koşulu eklenerek, bir çalışmada yeni bir model önerilmiştir (Ding ve diğ., 2018). Modelde parametre optimizasyonu yine PSO ile yapılmıştır. Modelin geçerliliğini ölçmek için Çin'in toplam ve endüstriyel elektrik tüketimi tahmini çalışması yapılmış ve önerilen model başarılı bulunmuştur. Yine aynı yılda yapılan bir çalışmada uzun dönem elektrik tüketimi tahmini için ARIMA ve üstel düzgünleştirme yöntemi kullanılmıştır (de Oliveira ve Cyrino Oliveira, 2018).

Yıllık elektrik tüketimi tahmini çalışmasında gri model kullanılarak geliştirilen bir modelde parametre optimizasyonu için Karınca Aslan Algoritması kullanılmıştır (Wang ve diğ., 2018).

Kısa dönem elektrik tüketimi tahmininde MARS, Destek Vektör Makineleri ve ARIMA modelleri kullanılmıştır (Al-Musaylh, 2018). Kullanılan veri seti Avusturalya'nın yarım saat ve bir saatlik elektrik tüketimi bilgilerinden oluşmaktadır.

Üniversite kampüsünün mevsimsel saatlik elektrik tüketimi hakkında yapılan çalışmada tahmin modeli olarak Yapay Sinir Ağı kullanmışlardır (Yuan, 2018).

Bir uzun dönem elektrik tüketimi tahmini çalışmasında Bulanık Bayezyen teori kullanılmıştır (Tang ve diğ., 2019). Model oluşturulurken bulanık koşul grafiği oluşturulmuş ve uzman deneyimlerinden yararlanarak bir matris meydana getirilmiştir. Tahmin sonucunun karşılaştırmalarında lojistik regresyonu ARMA ve YSA(Yapay Sinir Ağları) gibi modeller kullanılmıştır. Kıyaslamada kullanılan hata ölçütü ise OMYH 'tır. Önerilen model daha iyi tahmin performansı sergilemiştir.

Bir çalışmada doğrusal olmayan GBM(1,1) modeli Fourier Dönüşümü kullanılarak geliştirilmiştir (Nguyen ve diğ., 2019). Elektrik tüketimi tahmini konusunda ele alınan bir diğer çalışmada ise kesikli gri polinom modeli geliştirilmiştir (Luo ve diğ., 2020). Parametre optimizasyonlu modelde PSO algoritması kullanılmıştır.

Pakistan'ın uzun dönem hidroelektrik tüketimi tahmini çalışmasında ARIMA modeli kullanılmıştır (Jamil, 2020). 2030 yılına kadar tüketim tahmini raporlanmıştır. Hidroelektrik tüketimi konusunda yapılan başka bir çalışmada ise NGBM(1,1) modeli geliştirilmiştir (Zheng, 2021). 2021 yılında yapılan bir elektrik tüketimi çalışmasında COVID 19'un etkileriyle oluşan elektrik tüketimi ve kullanım etkinliği için mevsimsel Gri model ile tahmin modeli önerilmiştir (Chen ve diğ., 2021). Çalışmada üç aylık tüketim verileri kullanılmıştır.

Hamzaçebi, Türkiye'nin net elektrik tüketimi tahmininde Yapay Sinir Ağları yöntemini kullanarak bir çalışma yapmıştır (Hamzaçebi, 2007). Aynı yılda Türkiye'nin yıllık toplam ve endüstriyel Elektrik tüketimi yuvarlanma mekanizmalı gri tahmin yöntemiyle tahmin edilmiştir (Akay ve Atak, 2007). Enerji Talep Analizi Modeli'ne göre önerilen model ile daha geçerli tahmin sonucuna ulaşılmıştır. Tahmin performansının ölçümünde kullanılan hata ölçütü OMYH (ortalama mutlak yüzde hatası)'tır. 2012 yılında yine Yapay Sinir Ağları ve Destek Vektör Makinaları yöntemleri ile Türkiye'nin aylık elektrik tüketimi tahmini çalışması yapılmıştır (Oğcu ve diğ., 2012).

2014 yılında Türkiye'nin yıllık enerji tüketimi tahmini GM(1,1) optimizasyon modeli ile yapılmıştır (Hamzaçebi ve Es, 2014). Çalışmada direkt optimizasyon ve yinelemeli gri optimizasyon modelleri kullanılmıştır. Hata ölçütü olarak OMYH kullanılmış olup; sırasıyla, % 3,28 ve % 5,36 hata oranı elde edilmiştir. Sonuçlar yine aynı verileri kullanan Akay ve Atak'ın çalışma sonucuyla kıyaslanmış (OMYH= %3,43) ve önerilen modellerden, direkt gri optimizasyon modelinin daha iyi tahmin performansına sahip olduğu sonucuna varılmıştır.

Türkiye'nin yıllık elektrik tüketimi tahmininde regresyon analizi, yapay sinir ağları ve en küçük kareler destek vektör makineleri modelleri kullanılmış ve karşılaştırmalar yapılarak yorumlanmıştır (Kaytez ve diğ., 2015).

Türkiye'nin yıllık elektrik tüketimi tahmini konusunda yapılan başka bir çalışmada parametre optimizasyonlu GM(1,1) PSO ve GA ile entegre edilmiş; iki ayrı model önerisinde bulunmuşlardır (Ervural ve Ervural, 2018). Başka bir çalışmada Kesirli doğrusal olmayan gri Bernoulli modeli (FNGBM(1,1)) geliştirilmiş ve Türkiye'nin toplam yenilenebilir ve hidro enerjiden elektrik üretimi ve kurulum gücü tahmininde uygulanmıştır (Şahin, 2020). Önerilen modeller GM(1,1) ve NGBM(1,1) modelleri ile karşılaştırılmış ve önerilen modellerin tahmin performansları klasik modellere göre daha iyi olduğu sonucuna varılmıştır. Sonuçlar hata ölçütü OMYH kullanılarak kıyaslanmıştır.

Bir sonraki yıl sunulan çalışmada yenilenebilir enerji tüketimi için aynı modeller kullanılarak Türkiye dışındaki (Fransa, Almanya, İtalya, İspanya ve Birleşik Krallık) başka ülkelerin verileri kullanılarak da uygulama yapılmıştır (Şahin, 2021). Çalışma sonuçları yine başarılıdır.

Literatürde varolan bulanık gri model ile ilgili çalışmalar incelenmiştir. 2006 yılında bulanık gri modelin detaylıca açıklandığı bir çalışmaya rastlanmıştır (Tsaur, 2006). Önerilen modelde bulanık sayı GM(1,1) ile entegre edilmiş ancak parametreler sabit alınmış, optimizasyon yapılmamıştır. Başka bir çalışmada ise üçgen bulanık sayılar ile GM(1,1) modeli entegre edilerek Üçgen bulanık gri model (ÜBGM(1,1)) isimli bir tahmin modeli sunmuşlardır (Zeng ve diğ., 2016). Çalışmada belirli saat dilimlerini içeren bloklar halinde elektrik tüketimi verilerini ve sıcaklık verilerini kullanarak iki ayrı uygulama yapmışlardır. Literatürde tez çalışmasında ele alınan GIOA-ÜBGM(1,1) modeli ile yapılan bir tahmin çalışmasına rastlanmamıştır.

Bu tez çalışmasında kullanılan Güve-Işık Optimizasyonu (GIO) Algoritması Mirjalili tarafından ortaya atılmıştır (Mirjalili, 2015). Söz konusu algoritma kullanılarak çeşitli konularda çalışmalar yapılmıştır. Bilimsel çalışma yapılan alanlardan bazılarına bu literatür çalışmasında yer verilmiştir.

Bir çalışmada baskın olmayan sıralamalı güve ışık optimizasyonu geliştirilmiş ve çok amaçlı problem çözümünde kullanılmıştır (Savsani ve Tawhid, 2017). Benzetim Tavlaması algoritması ile birleştirilerek hibrit bir algoritma oluşturulan bir çalışmada GIO algoritması ile fonksiyon optimizasyonu yapılmış ve mühendislik tasarım problemleri çözülmüştür (Sayed ve Hassanien, 2018).

Benzetim Tavlaması algoritması dışında PSO (Bhesdadiya ve diğ., 2017; Jangir, 2017), Ateş Böceği (Sarma, 2017) ve Yerçekimi Arama Algoritması (Zhang, 2016) ile oluşturulmuş hibrit algoritmalara literatürde rastlanmıştır.

GIOA'nın kullanıldığı diğer çalışma alanları; sağlık alanında; göğüs kanseri tespiti (Sayed ve diğ., 2016; Sayed ve Hassanien, 2017), Alzheimer teşhisi (Sayed ve diğ., 2016), PID kontrolcü tasarımı (Sahu, 2017), Su kaynaklarının optimizasyonu (Li ve diğ., 2018), terör tahmini (Soliman, 2016), görüntü segmentasyonu (El Aziz, 2017), radyal dağıtım sistemlerinde kapasitörlerin optimum boyutlandırılması ve yerleştirilmesi (Upper ve diğ., 2017), rüzgar çiftliği entegrasyonu ile kar maksimizasyonu (Gope ve diğ., 2016), petrokimya endüstrilerinde üretim planlaması (Chauhan ve Kotecha, 2016) gibi çeşitli alanlardır.

Bu çalışma alanlarının dışında rastlanan gri tahmin modeli ile entegre edilen GIO Algoritması modelleriyle yapılan tahmin çalışmaları incelenmiş ve yalnızca aşağıda açıklanan çalışmalara rastlanmıştır.

Yuvarlanma mekanizmalı GM(1,1) modeli parametre optimizasyonu için GIO algoritması ile entegre edilmiştir (Zhao ve diğ., 2016). Bu çalışmada, GIO-yuvarlanma mekanizmalı GM(1,1) modeli elektrik tüketimi tahmini için önerilmiştir.

Doğalgaz üretimi ve tüketimi tahmininde kullanılan algoritma uygun kesikli homojen olmayan gri Bernoulli modeli ile entegre edilerek yeni bir model sunulmuştur (Zheng ve diğ., 2021).

3. TALEP TAHMİNİ

Tahmin, geçmiş veriler kullanılarak bazı tahmin teknikleriyle geleceğin hesaplanmasıdır. Talep tahmini ise geçmiş yılların talep miktarından ya da talebi etkileyen faktörlerden yola çıkılarak geleceğe yönelik talebin öngörülmesidir (Olgun, 2009). Geleceğe yönelik beklentileri yansıtmak için geçmiş deneyimleri kullanma tekniğidir (Chapman,2006).

Bu tez çalışmasında uygulama konusu olan enerji tüketimi, ülkenin ekonomik büyümesini, sosyal istihdamını, karbon emisyonlarını vb. derinden etkiler (Yongwei ve diğ., 2020). Enerji talebinin tahmin edilmesi, iklim değişikliğiyle mücadele edilecek ve istikrarlı ekonomik kalkınmayı sürdürecektir bölgelerde önemli bir role sahiptir. Elektrik, yüksek kaliteli bir ikincil enerjidir ve elektrik tüketimi, enerji tüketiminin çoğunu oluşturur. Sanayi şirketleri elektrik tüketiminde başı çekmektedir. Sanayi şirketlerinin elektrik tüketimleri ile ekonomik büyümeleri doğru orantılıdır. Ayrıca, finansal planlamada farklı türdeki faktörlerin sınırlamalarını incelemek için ülkelerin elektrik tüketimini tahmin etmesi de yararlı bir gerekliliktir (Chen ve diğ., 2021).

3.1 Talep Tahmini İlkeleri

Tahmin doğruluğunun artması için aşağıdaki adımlar izlenmelidir (Kobu, 2008).

- Amacın saptanması
- Tahmin yapılacak zaman aralığının saptanması,
- Gerekli verilerin biraraya getirilmesi, değerlendirilmesi ve analiz yapılması
- Yöntemin kararlaştırılması ve değerlendirilmesi
- Tahminin gerçekleştirilmesi
- Sonuçların analiz edilerek, yöntemin performansının değerlendirilmesi

3.2 Talep Tahmin Yöntemleri

Talep tahmin yöntemleri iki sınıfta incelenebilir. (Chapman, 2006; Kobu, 2008; Krajewsky ve diğ, 2010).

- Kantitatif Yöntemler
- Kalitatif (Nitel) Yöntemler

3.2.1 Kalitatif yöntemler

Kalitatif yöntemler, iyi tanımlanmış bir analitik yapıya sahip olmayan bilgilerden üretilen tahminlerdir. Bir ürünün yeni olması ve satış geçmişi olmaması gibi geçmiş veriler mevcut olmadığında özellikle yararlı olabilirler (Chapman, 2006). Bunlar; pazar anketi, delphi tekniği, kolektif düşünce yöntemi, yaşam döngüsü analoji tahmini yöntemidir. (Kobu, 2008; Krajewsky ve diğ, 2010).

Delphi veya kolektif düşünce tekniği, pazarda veya anketin geliştirilmekte olduğu alanda tanımlanmış uzmanların panellerini kullanır. Uzmanlar, söz konusu ürünler veya ürün aileleri için talep tahmini konusunda bir fikir birliği geliştirmeye çalışmak için birbirleriyle etkileşime girerek, talebi etkileyen faktörlere ilişkin bireysel bilgilerini analize dahil etmeye çalışırlar. İki yöntem arasındaki en büyük fark, süreçteki farktır. Panel tahmini, uzmanları tartışma için bir toplantı formatında bir araya getirme eğilimindeyken, Delphi yöntemi her uzman tarafından bir dizi bireysel tahminin yapılmasına izin verir. Her uzman, kendi tanımladığı nedenlerle kendi tahminini geliştirir. Bu toplu küme daha sonra tüm uzmanlarla paylaşılır ve her birinin diğer uzmanlardan gelen bilgilere dayanarak tahminlerini değiştirmesine izin verilir. Bahsedilen adımlar aracılığıyla; ana fikir, tahmin konusunda bir fikir birliği elde etmektir (Chapman, 2006). Politik ve duygusal şartlarda karar vermekte zorluk yaşanıldığında veya üst gruplardan etkilenme durumlarında delphi yöntemine başvurulabilir (Şahin, 2001).

Pazar anketleri genellikle pazardaki potansiyel müşterilere sunulan yapılandırılmış anketlerdir. Ürünler veya potansiyel ürünler hakkında fikir isterler ve ayrıca genellikle ürün veya hizmetler için müşteri talebi olasılığını anlamaya çalışırlar. İyi yapılandırılırlarsa, tanımlanan popülasyonun iyi bir temsili örneğine uygulanırlar ve

doğru analiz edilirlerse, özellikle kısa vadede oldukça etkili olabilirler. Önemli bir dezavantajı, doğru yapıldığında oldukça pahalı ve zaman alıcı olmalarıdır.

Yaşam döngüsü analoji tahmini, ürün veya hizmet yeni olduğunda kullanılan oldukça özel bir uygulamadır. Konsept oldukça basit. Çoğu ürün ve hizmetin oldukça iyi tanımlanmış bir yaşam döngüsüne sahip olduğu gerçeğine dayanmaktadır. Pazara girişten sonraki erken aşamada genellikle büyüme vardır. Bir noktada, ürün veya hizmet olgunlaşır, çok az veya hiç ek büyüme göstermez, sonunda talep artık sunulmadığı noktaya kadar düşer

3.2.2 Kantitatif (İstatistiksel) yöntemler

Tahmin konusunda objektif öngörülerde bulunmak doğru karar vermek açısından oldukça önemlidir. Niteliksel (kalitatif) yöntemlere başvurulurken bağımlı değişkeni (talebi) etkileyen faktörler arttıkça bu yöntemlerin etkisi azalmaktadır. Böyle durumlarda istatistiksel yöntemleri kullanmak daha doğru olacaktır. (Kobu, 2008; Tengilimoğlu ve Yiğit, 2013).

Bu çalışmanın konusu olan geleneksel gri modeller de istatistiksel modeller altında sınıflandırılmıştır (Hammad ve diğ, 2020). Gri modeller bir sonraki bölümde detaylı olarak anlatılmaktadır.

3.2.2.1 Zaman serileri analizi

Zaman serisi, olayların sürekli değerli değişkenlerle karakterize edildiği zamansal bir dizidir. Etkili ve doğru zaman serisi tahmini, gerçek dünya uygulamaları için zorunludur. Bu nedenle, doğru modelleme, optimal tahminin temeli haline gelir (Kuranga ve Pillay, 2022). Geçmişe bakılarak değişim gözlemlenir ve bu değişime göre gelecekteki talep tahmin edilir. Zaman serileri dört bileşenden oluşmaktadır: trend, mevsimsellik, periyotlar, rassal varyasyonlar (Heizer ve Render, 2011).

Naive Yöntemi: Tahmin edilecek dönemin değerinin bir önceki dönemde gerçekleşen değer olduğu kabul edilir. Tahminde maliyet azaltmak için kullanılan bir yöntemdir. Hareketli Ortalama Yöntemi : Bu yöntem bir tahmin oluşturmak için bir dizi geçmiş gerçek veri değerini kullanır. Geçmiş değerlerin ortalamasını alarak bu tahmini yapar. Piyasa taleplerinin zaman içinde oldukça stabil kalacağı durumlarda hareketli ortalamalardan yararlanır. Tespit edilebilir bir eğilim veya model mevcut olduğunda,

son deęerlere daha fazla vurgu yapmak için aęırlıklar kullanılabilir (aęırlıklı hareketli ortalama). Bu uygulama, tahmin tekniklerini deęiřikliklere daha duyarlı hale getirir, çünkü daha yakın dönemler daha aęırlıklı olabilir.

Üstel Düzgünleřtirme Yöntemi: Bu yöntemde başka bir aęırlıklı hareketli ortalama tahmin yöntemidir. Geçmiş verilerin çok az kaydını içerir ve kullanımı oldukça kolaydır. Bu yöntemde kullanılan düzeltme katsayısı verinin özellięi ve eğilimine göre saptanarak, gerekirse deęiřtirilerek, kullanılır.

Trend Analizi: Bu teknik, bir dizi geçmiş veri noktasına bir eğilim(trend) çizgisi uydurur ve ardından orta ve uzun vadeli tahminler için çizginin eğimini ileriki dönemlere yansıtır. Bu yöntemde geçmiş veri serisine bir trend oturtulur ve bu trend gelecek veriye uyarlanır.

3.2.2.2 Nedensel modeller

Nedensel modellerde geçmiş dönem verilerinin etkiledięi deęiřkenlere ait veriler kullanılır. Zaman serileri analizinden farklı olarak, tahmin edilen deęerle ilgili birkaç deęiřkeni de modelde dikkate alır. Bu ilgili deęiřkenler bulunduğundan sonra, istatistiksel bir model oluşturulur ve ilgili öęeyi tahmin etmek için kullanılır.

Regresyon Analizi : Bu yöntem bir deęiřkenin zaman ve başka deęerlere göre alacağı deęerlerin artma ya da azalma eğilimlerinin saptanması ile ilgilidir.

3.2.3 Yapay zeka ve sezgisel algoritmalar

Geleneksel istatistiksel modeller sınırlıdır ve bazen tatmin edici olmayan çözümlere yol açabilir. Bunun nedeni, büyük çözüm sürelerine ve belirli doğrusal olmayan veri modellerinin karmaşıklığına yol açan çok yüksek sayıda hesaplama olmasıdır. Bu nedenle, makine öğrenimi ve yapay zeka tabanlı teknikler, umut verici ve çekici bir alternatif sunar (Hammad ve dię., 2020). Yapay zeka teknikleri en çok optimizasyon amaçlı olarak kullanılmaktadır. Geleneksel yöntemlerle çözülmesi zor olan problemleri çözmede ve kararsız ortamlarda tahmin yapmada kullanılmaktadır. Bu tahmin yöntemleri bulanık mantık, yapay sinir aęları, sinirsel-bulanık sistem, genetik algoritmalar dır.

4. GRİ SİSTEM TEORİSİ VE GRİ MODELLEME

4.1 Gri Sistem Teorisi

Gri sistem teorisi ilk olarak Julong Deng (1982) tarafından ortaya atılmıştır. Gri sistem teorisi küçük örneklem ve bilgi eksikliği içeren problemlere odaklanan yeni bir yöntemdir. Belirsiz sistemlerde mevcut olan kısmi bilgileri kullanarak yararlı bilgiler elde eder. Bu şekilde gri sistem teorisi belirsiz sistemleri çözümler. Böylece sistemin operasyonel davranışları ve bu davranışların evrim ilkeleri doğru bir şekilde tanımlanıp, etkin bir şekilde takip edilebilir. Gerçek hayatta da küçük örneklem ve bilgi eksikliği içeren alanlar oldukça fazla olduğundan gri teorisinin uygulanabileceği alanlar da oldukça fazladır (Sifeng ve diğ, 2011).

Belirsiz sistemlerin temel özellikleri bilgi eksikliği ve bilgideki hatadır. Bilgi eksikliğini içeren sistemler aşağıdaki dört durumla açıklanabilir:

- Faktörlerle (parametreler) ilgili bilgi eksikliği
- Sistem yapısı bilgilerindeki eksiklik
- Sistem sınırları hakkında bilgi eksikliği
- Sistem davranışındaki bilgi eksikliği

Verideki doğal hata belirsiz sistemlerin bir diğer özelliğidir. Belirsizliğin nasıl oluştuğuna bağlı olarak üç tiptir:

- Kavramsal Tip
- Seviye Tipi
- Tahmin Tipi

Kavramsal tip, belirli bir olay, nesne, kavram veya dilek hakkındaki ifadeden ötürü oluşan hata tipidir. İyi, kötü, Güzel, yüksek gibi oldukça sık kullanılan kavramlar tanımlamadaki eksikliklerden ötürü hatalıdır. Bu kavramları sayısal olarak ifade etmek oldukça zordur.

Seviye tipi hata, araştırmaların veya gözlemlerin seviyesindeki değişimden ötürü ortaya çıkar. Mevcut veriler, belirlenmiş bir sistem düzeyinde görüldüğünde doğru

iken, daha ayrıntılı bir seviyede incelendiğinde hatalı olabilir. Örneğin, santimetre veya milimetre birimiyle bir kişinin boyu ölçüldüğünde bu ölçü doğrudur ancak ölçümün on binde bir mikron seviyesinde doğru olması gerekiyorsa aynı ölçüm hatalı olarak değerlendirilir.

Evrin yasalarını tamamen anlamamanın zorluğundan ötürü geleceği tahmin etmek hatalı olma eğilimindedir. Bir şehrin gelecek ay sıcaklığının 30°C 'nin üstüne çıkmayacağı örneği belirsiz sayılar içermektedir. Bu da hatanın tahmin tipini göstermektedir. Ne olursa olsun tamamen hatasız bir değer tahmin etmek oldukça zordur.

Olasılık ve istatistik, gri sistem teorisi, kaba küme teorisi (rough set theory) ve bulanık matematik, belirsiz sistemlerde araştırma yapmak için en çok kullanılan yöntemlerdir.

Olasılık ve istatistik, istatistik kuralları ile stokastik belirsizlikleri inceler. Stokastik belirsizliklerin oluşmasındaki her bir olasılığı hesaplamaktadır. Belirli bir dağılım yöntemini karşılayacak büyüklükte bir örnekleme sahip olup olmadığını araştırır.

Bulanık matematik kavramsal belirsizliklerin araştırılması üzerinde durur. İfadenin (intension) açık olduğu ancak bu ifadenin kapsamının (extension) net olmadığı durumları araştırır. Bu tür problemleri deneyim ve üyelik fonksiyonu kullanarak çözümler.

Kaba küme teorisi, nesneler arasındaki ayırt edilemezliği ifade eden, örtüşmeyen kaba sınıf ve kaba kavramı ile ilgilenmektedir. Kavram hem alt hem üst yakınsama ile yakınsamaktadır. Fazlalık, fazla ayrıntıyla bulanıklaştırılabilen verilerden örüntü keşfini mümkün kılan öznitelik indirgeme algoritması ile azaltılabilir.

Gri sistem teorisinin odak noktası ise olasılık açısından ele alınması zor olan küçük örneklemelerin ve eksik bilgi içeren verilerin belirsizlik problemleridir. Gri sistem teorisi, malzeme ve olayların hareketlerini ve evrimin gerçekçi yasalarını, bilgi kapsamı ve dizi operatörlerinin çalışmaları aracılığıyla araştırır ve ortaya çıkarır. En önemli özelliklerinden birisi küçük veri ile modeller oluşturmaktır. Genellikle bulanık mantık ile karıştırılan gri teori; bulanıklıktan ayrılan temel bir yönü vardır. Gri sistem objelerin dışsal uzantılarının kesinliğini vurgularken, bulanık matematik iç anlamın kesinliğini vurgulamaktadır. Diğer bir deyişle; gri sistem dışsal uzantısı kesinlik oluşturan ancak içsel anlamı belirsizlik içeren objelerle çalışır. Bulanık matematik ise içsel anlamı kesinlik içeren objelerle çalışmaktadır. Net bir kapsam, belirsiz bir ifadeye

sahip nesnelerin araştırılmasına odaklanmasıyla bulanık matematikten ayrılmaktadır (Lin ve diğ, 2003).

Çizelge 4.1’de yukarıda belirtilen dört yöntemin farkları özetlenmektedir.

Çizelge 4.1: Belirsizlik modellerinin farkları (Lin ve diğ., 2003).

Başlık	Olasılık İstatistik	Bulanık Matematik	Kaba Küme	Gri Sistem
Araştırma Konusu	Stokastik	Kavramsal belirsizlik	Ayırt edilmezlik	Bilgi eksikliği
Temel Kümeler	Cantor kümeler	Bulanık kümeler	Küme yakınsaması	Gri kümeler
Yöntemler	Haritalama	Haritalama	Ayırma	Bilgi kapsamı
İşlemler	Sıklık dağılımı	Kesim setleri	Alt ve üst yakınsama	Dizi işlemleri
Veri Gereksinimi	Tipik Dağılım	Bilinen üyelik fonksiyonu	Eşdeğer ilişkiler	Herhangi bir dağılım
Vurgu	Kavram	Kapsam	Kavram	Kavram
Amaç	Kanunlar	Kavramsal ifade	Kavram yakınsaması	Gerçeklik yasaları
Özellikler	Büyük örneklem	Deneyim	Bilgi sistemleri	Küçük örneklem

Bir çok sistem sınıflandırıldığı özelliklere göre isimlendirilirken gri sistemler sistemin rengine göre isimlendirilmektedir. Kontrol teorisinde, mevcut bilginin netlik derecesini tanımlamak için renkler kullanılır. Hiçbir bilgiye ulaşamayan nesnelere kara kutu adı verilmektedir. Hiçbir bilgiye ulaşamayan sistemlere siyah, tüm bilgiye ulaşılabilir ise beyaz, bazı bilgiye ulaşılır bazısına ulaşılmazsa gri sistem adı verilmektedir. Bu kapsamda Çizelge 4.2 gri kavramının özelliklerini özetlemektedir (Lin ve diğ, 2003).

Gri sistem teorisinin altı temel ilkesi aşağıdaki gibidir:

1. Bilgideki değişiklikler ilkesi: Her bir bilgi farklılık içermelidir. Bu farklılık bir yandan da bilginin varlığını ifade etmektedir.
2. Eşsiz olmama ilkesi: Çözümler eksik bilgiden ötürü eşsiz değildir.

3. Asgari bilgi ilkesi: Gri teori, en az bilgi ile en yüksek faydayı sağlar.
4. Doğrulama temeli ilkesi: Bilgi insanların anlama ve doğrulamalarının temelini oluşturmaktadır.
5. Yeni bilgi önceliklidir ilkesi: Yeni bir bilginin yararı eski bilgiye göre daha fazladır.
6. Mutlak Grilik ilkesi: Bilginin eksikliği kesindir.

Çizelge 4.2: Gri kavramının özellikleri (Lin ve diğ., 2003).

Durum Kavram	Siyah	Gri	Beyaz
Bilgi	bilinmiyor	eksik	biliniyor
Görüntü	karanlık	bulanık	net
Süreç	yeni	değişken	eski
Özellikler	kaotik	çok değişkenli	sıralı
Yöntemler	eksik, olumsuz	daha iyisi için değişim	doğrulama
Davranış	gevşek	toleranslı	sıkı
Çıktı	çözüm yok	birden fazla çözümlü	tek çözüm

Gri sistemin ilk ortaya atılışından bu yana sistem analizi, değerlendirme, modelleme, tahmin, karar verme, kontrol ve optimizasyon tekniklerinden oluşan kendi teorik yapısıyla yeni ortaya çıkan bir bilimsel disiplindir. Ana başlıkları aşağıdaki gibi özetlenebilir (Sifeng ve diğ., 2011).

- Gri sayılar, gri matrisler, gri denklemler
- Sıralı işlemler, ortalama üretim işlemleri, birikimli işlemler, ters birikimli işlemler
- Gri ilişkisel analiz
- Gri karar verme teknikleri
- Gri tahmin modelleri

Gri tahmin modelleri bu tez çalışmasının da konusu olup temel modeller bir sonraki başlıkta detaylı olarak açıklanmaktadır.

4.2 Gri Tahmin Modelleri

Gri sistem teorisi tahmin tekniği olarak da birçok alanda kullanılmaktadır. En sık kullanılan tahmin modeli ise Gri Model (GM(1,1))'dir (Liu ve Lin, 2006).

Bu bölümde Gri modeller ayrıntılı olarak anlatılmaktadır.

4.2.1 GM (1,1)

GM(1,1)'deki ilk "1" tek değişkeni; ikinci "1" ise gri modeli oluşturulan birinci dereceden diferansiyel denklemi ifade etmektedir (Chen ve diğ., 2021) . GM(1,1) aşağıdaki adımlardan oluşmaktadır (Lee ve Tong, 2011).

k: bağımsız değişken

a: katsayı

b: gri kontrol değişkeni

$x^{(0)}$ denklem (4.1)'deki gibi orijinal sıralı veriyi ifade etmektedir.

$$x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)) \quad n \geq 3 \quad (4.1)$$

1. Birinci dereceden birikimli üretim işlemi (accumulated generating operation- AGO) (BÜİ), orijinal zaman serisi olan, $x^{(0)}$ 'a uygulanmıştır ve $x^{(0)}$ denklem (4.2) ve (4.3)'teki monoton artan seriye dönüştürülmüştür.

$$x^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)) \quad (4.2)$$

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i) \quad (4.3)$$

2. Bu seri lineer diferansiyel denklemlerin çözüm eğrisine benzerdir. Bu yüzden GM(1,1)'in gri diferansiyel denklemi denklem (4.4)'teki gibi elde edilir.

$$x^{(0)}(k) + az^{(1)}(k) = b, \quad k=2, 3 \dots n. \quad (4.4)$$

3. En küçük kareler yöntemi uygulanarak denklem (4.5) elde edilir.

$$\hat{a} = \begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_N \quad (4.5)$$

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}, \quad Y_N = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad (4.5a)$$

Denklem (4.5)' teki a parametresi gelişme katsayısını, b parametresi ise gri kontrol değişkenini ifade etmektedir. Denklem (4.6) 'daki yatay düzeltme katsayısı (λ) 0 ile 1 arasında bir değer almaktadır. Geleneksel GM(1,1) modelinde ise λ her zaman 0,5 kabul edilmektedir (Ma ve diğ., 2013).

$$z^{(1)}(k) = 0.5 x^{(1)}(k-1) + (1-0.5)x^{(1)}(k), k=2, 3, \dots, n \quad (4.6)$$

4. Terse birikimli üretim işlemi uygulanır. Tahmin değerleri denklem (4.7) ve (4.8) yardımıyla elde edilir.

$$\hat{x}^{(1)}(k) = \left(x^{(1)}(1) - \frac{b}{a} \right) e^{-a(k-1)} + \frac{b}{a}, \quad k = 2, 3, \dots, n \quad (4.7)$$

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 2, 3, \dots, n \quad (4.8)$$

4.2.2 Yuvarlanma mekanizmalı GM(1,1)

Geleneksel GM(1,1) modelinde tahmin için tüm veri seti kullanılmaktadır. Ancak bazen, veri farklı eğilim ve özellikler sergileyebilmektedir. Bu tip kaotik ve farklılık içeren verilerde geleneksel GM(1,1) modeli yerine yuvarlanma mekanizmalı GM(1,1) modeli kullanılması önerilmektedir (Ma ve diğ., 2013).

Üstel veya kaotik verilerde tahmin doğruluğunu artırmada yuvarlanma mekanizmalı GM(1,1) modeli daha etkili bir modeldir.

Yuvarlanma mekanizmalı GM (1,1) modelinde, k değerinde bir veri boyutu belirlenir. $x^{(0)} = (x^{(0)}(1), x^{(0)}(2), x^{(0)}(3) \dots, x^{(0)}(k))$ kullanılarak $x^{(0)}(k+1)$ tahmin edilirken GM(1,1) modeli uygulanır ($k < n$). İlk veri olan $x^{(0)}(1)$ değeri veriden çıkarılır, orijinal veri olan $x^{(0)}(k+1)$ veri sonuna eklenir ve bir sonraki değer hesaplanır. Diğer bir değişle, $x^{(0)}(k+2)$ değerini tahmin etmek için $x^{(0)} = (x^{(0)}(2), x^{(0)}(3) \dots, x^{(0)}(k), x^{(0)}(k+1))$ kullanılır. İşlemler bu şekilde tekrarlanarak tahmin değerleri elde edilir. $k=4,5,6, \dots, n-1$ olmalıdır.

4.2.3 Hata analizi

Bir tahmin modelinin tahmin doğruluğunun performansı gerçek değerlerle tahmin değerleri arasındaki sapmaların analizi sonucu ortaya çıkar. Eğer tespit edilen sapmalar hata ölçütlerine göre kabul edilebilir düzeyde değil ise hata sebepleri incelenir ve hataları azaltacak bir takım önlemler alınır. Tahmin yapılırken bir faktörün model dışı tutulması, ani değişimler, yanlış yöntemlerin kullanılması ve yorumlanması gibi nedenler hatanın yüksek olmasına sebep olabilirler. (Kobu, 2008).

Tahmin yapılırken yanlış yöntem seçiminden dolayı oluşan hata düzeltilebilir. Birkaç yöntem tahmin verisine uygulanarak hatası en düşük olan yöntem uygun tahmin yöntemi olarak seçilebilir. (Kobu, 2008).

Tahminde sıklıkla kullanılan hata analizi ölçütleri; Kök Ortalama Kare Hata (KOKH) (Root square mean error- RMSE), Ortalama Mutlak Hata (OMH) (Mean Absolute Error-MAE), Ortalama Mutlak Yüzde Hatası (OMYH) (Mean Absolute Percentage Error-MAPE)'dir (Wang ve diğ., 2018; Zhao ve diğ., 2016). Gri tahmin modellerinin uygulandığı çalışmalar incelendiğinde en çok kullanılan hata ölçütünün OMYH olduğu gözlenmiştir (Lee ve Tong, 2011; Ene ve Öztürk, 2017; Şahin,2021). OMYH hesabı denklem (4.9)'daki gibidir.

$$OMYH = \frac{100}{n-1} \sum_{k=2}^n \left| \frac{\hat{x}^{(0)}(k) - x^{(0)}(k)}{x^{(0)}(k)} \right| \quad (4.9)$$




5. BULANIK GRİ MODEL

Bulanık sayı ilk olarak Zadeh tarafından literatüre kazandırılmıştır (Zadeh, 1965). Bulanık mantık, sürecin kesin olmadığı durumlar için değişen üyelik fonksiyonu ile özellikle kullanılan bulanık küme teorisinin konusudur. Bulanık sayılar, normalize edilmiş ve dışbükey olan bulanık kümelerdir (Tüysüz ve Kahraman, 2010).

Bulanık kümelerin üyelik fonksiyonunun şekli, incelenen sistemin doğasına bağlı olarak doğrusal (yamuk veya üçgen) veya doğrusal olmayan çeşitli formlar olabilir (Acaroğlu ve diğ., 2008).

Bu çalışmada da kullanılan üçgen bulanık sayı Şekil 5.1’de gösterildiği gibi; üçgenin tabanının $[a, c]$ aralığı ve tepe noktasının b olduğu üç sayı ile tanımlanır (Tüysüz ve Kahraman, 2010).



Şekil 5.1: Üçgen bulanık sayı (Tüysüz ve Kahraman, 2010).

Aşağıda detaylı şekilde denklemleri verilen model ise üçgen bulanık sayı ile GM(1,1) entegre edilmesiyle sunulan bir çalışmadaki modele aittir (Zeng ve diğ., 2016).

$\tilde{x}^{(0)}$, üçgen bulanık sayı zaman serisi verilerini ifade etmektedir.

$$\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}, \quad (5.1)$$

Denklem (5.1) açık olarak $\tilde{x}^{(0)}(k) = [x_L^{(0)}(k), x_M^{(0)}(k), x_R^{(0)}(k)]$ şeklinde ifade edilir.

k verinin sırasını, “0” ise orijinal veri olduğunu ifade etmektedir. $x_L^{(0)}(k)$ olası en

küçük değeri, $x_M^{(0)}(k)$ ortalama değeri ve $x_R^{(0)}(k)$ ise en büyük değeri ifade etmektedir. ÜBGM(1,1) modelinin adımları aşağıdaki gibidir (Zeng ve diğ., 2016).

Adım 1. Geleneksel GM(1,1)'de olduğu gibi Birinci dereceden birikimli üretim işlemi orjinal üçgen bulanık sıralı seri, $\tilde{x}^{(0)}$ 'a uygulanır. Böylece, $\tilde{x}^{(0)}$ monoton artan seriye dönüştürülür ve denklem (5.2)'deki gibi ifade edilir.

$$\tilde{x}^{(1)} = \{\tilde{x}^{(1)}(1), \tilde{x}^{(1)}(2), \dots, \tilde{x}^{(1)}(n)\}, \quad (5.2)$$

$\tilde{x}^{(1)}(k)$ açık olarak denklem (5.3)'te görüldüğü üzere, bir önceki orijinal sayı ile toplanarak elde edilir.

$$\begin{aligned} \tilde{x}^{(1)}(k) &= \sum_{i=1}^k \tilde{x}^{(0)}(i) = \left[\sum_{i=1}^k x_L^{(0)}(i), \sum_{i=1}^k x_M^{(0)}(i), \sum_{i=1}^k x_R^{(0)}(i) \right] \\ &= [x_L^{(1)}(k), x_M^{(1)}(k), x_R^{(1)}(k)] \end{aligned} \quad (5.3)$$

Adım 2. ÜBGM(1,1) modelinin gri diferansiyel denklemi (5.4)'teki gibi elde edilmektedir.

$$\tilde{x}^{(0)}(k) + a \times \tilde{z}^{(1)}(k) = \tilde{b}, k = 2, 3, \dots, n., \quad (5.4)$$

Adım 3. En küçük kareler yöntemiyle denklem (5.5) elde edilmektedir.

$$\begin{pmatrix} a_L \\ b_L \end{pmatrix} = (A^T A)^{-1} A^T Y_L, \quad \begin{pmatrix} a_M \\ b_M \end{pmatrix} = (B^T B)^{-1} B^T Y_M, \quad \begin{pmatrix} a_R \\ b_R \end{pmatrix} = (C^T C)^{-1} C^T Y_R \quad (5.5)$$

Denklem (5.5)'teki her bir ifade denklem (5.6) –(5.8)'de açıkça verilmiştir.

$$A = \begin{bmatrix} -z_L^{(1)}(2) & -1 \\ -z_L^{(1)}(3) & -1 \\ \dots & \dots \\ -z_L^{(1)}(n) & -1 \end{bmatrix}, \quad Y_L = \begin{bmatrix} -x_L(2) \\ -x_L(3) \\ \dots \\ -x_L(n) \end{bmatrix} \quad (5.6)$$

$$B = \begin{bmatrix} -z_M^{(1)}(2) & -1 \\ -z_M^{(1)}(3) & -1 \\ \dots & \dots \\ -z_M^{(1)}(n) & -1 \end{bmatrix}, \quad Y_M = \begin{bmatrix} -x_M(2) \\ -x_M(3) \\ \dots \\ -x_M(n) \end{bmatrix} \quad (5.7)$$

$$C = \begin{bmatrix} -z_R^{(1)}(2) & -1 \\ -z_R^{(1)}(3) & -1 \\ \dots & \dots \\ -z_R^{(1)}(n) & -1 \end{bmatrix}, \quad Y_R = \begin{bmatrix} -x_R(2) \\ -x_R(3) \\ \dots \\ -x_R(n) \end{bmatrix} \quad (5.8)$$

Denklem (5.4), (5.6)–(5.8)’deki z değeri denklem (5.9)’daki gibi ifade edilmekte olup, genel olarak λ değeri net sayı olarak 0,5 alınır.

$$\tilde{z}^{(1)}(k) = \tilde{\lambda} \tilde{x}^{(1)}(k-1) + (1 - \tilde{\lambda}) \tilde{x}^{(1)}(k), k = 2, 3, \dots n. \quad (5.9)$$

Açık olarak $\tilde{z}^{(1)}(k) = [z_L^{(1)}(k), z_M^{(1)}(k), z_R^{(1)}(k)]$ şeklinde ifade edilmektedir.

Denklem (5.4)’teki a gelişme parametresi net sayıdır ve a_L, a_M ve a_R ’nin ağırlıklı ortalamasından elde edilir (Denklem (5.11)). $\tilde{b}$ gri parametredir ve üçgen bulanık sayıdır. $\tilde{b} = [b_L, b_M, b_R]$ olarak ifade edilir.

Dolayısıyla, denklem (5.4) açık olarak denklem (5.10)’daki gibi ifade edilir.

$$\begin{aligned} [x_L^{(0)}(k), x_M^{(0)}(k), x_R^{(0)}(k)] + a [z_L^{(1)}(i), z_M^{(1)}(i), z_R^{(1)}(i)] \\ = [b_L, b_M, b_R] \end{aligned} \quad (5.10)$$

$$a = \alpha a_L + \beta a_M + \gamma a_R \quad (5.11)$$

Denklem (5.11)’de kullanılan ağırlıklılarda β , diğer katsayılarla eşit veya büyük olmalı ve üç katsayının toplamının da denklem (5.12)’de gösterildiği üzere “1” olmalıdır.

$$\alpha + \beta + \gamma = 1, \quad \beta \geq \alpha \text{ ve } \beta \geq \gamma \quad (5.12)$$

Adım 4. Terse birikimli üretim işlemi uygulanır. Zamana duyarlı seri sırasıyla; denklem (5.13), (5.14) ve (5.15) uygulanarak elde edilir.

$$\hat{\tilde{x}}^{(0)}(1) = \tilde{x}^{(0)}(1) \quad (5.13)$$

Denklem (5.13) ilk koşul olarak alınır.

$$\hat{\tilde{x}}^{(1)}(k) = \left(\tilde{x}^{(1)}(1) - \frac{\tilde{b}}{a} \right) e^{-a(k-1)} + \frac{\tilde{b}}{a}, k = 2, 3, \dots n \quad (5.14)$$

$$\hat{\tilde{x}}^{(0)}(k) = \hat{\tilde{x}}^{(1)}(k) - \hat{\tilde{x}}^{(1)}(k-1), k = 2, 3, \dots n \quad (5.15)$$

Denklem (5.14)’te elde edilen değer kümülatif tahmindir. Tahmin değeri denklem (5.15)’te ifade edildiği gibi bir önceki kümülatif değerden çıkararak elde edilir.



6. METASEZGİSELLER

Bilişim teknolojisinin gelişmesiyle birlikte, mühendislik, biyoinformatik, yöneylem araştırması ve jeofizik gibi çeşitli alanlarda çok sayıda optimizasyon problemi ortaya çıkmıştır. Ancak çoğu optimizasyon problemi belirli bir zaman aralığında çözülemeyecek düzeydedir. Bu gibi optimizasyon problemleri için sezgisel ve metasezgisel algoritmalara başvurulmaktadır. Sezgisel yöntemler daha çok belirli bir probleme odaklı iken metasezgisel yöntemler değildir. Yani sezgisel yöntemler bir problem için iyi bir yöntem iken; başka bir problemde iyi bir çözüm elde edemeyebilirler. Aralarındaki en temel fark bu şekilde açıklanabilir. (Abdal-Basset, 2018). “Meta” öneki Yunanca ileri seviye anlamına gelmektedir. Metasezgiseller, ileri seviye sezgiseller anlamına gelmektedir (Boussaïd ve diğ, 2013). Yüksek kaliteli çözümleri verimli bir şekilde üretmek için alt sezgisel yöntemlerin işlemlerini yönlendiren ve değiştiren yinelemeli bir ana süreçtir (Osman, 2002).

Metasezgisel (metaheuristic) kelimesi ilk kez 1986’da Fred Glover tarafından ortaya atılmıştır. Metasezgisellerin güçlü arama mekanizmaları, araştırma (çeşitlendirme) (exploration (diversification)) ve sömürme (yoğunlaştırma) (expoliation (intensification)) isimli iki şema arasındaki uyumdan kaynaklanmaktadır. Birincisi, en iyi çözümle çevrili alanlarda arama yapmaktan sorumluyken, ikincisi yeni arama alanlarını tarama eğilimindedir. Böylece metasezgiseller kabul edilebilir bir çözüme ulaşabilirken sezgiseller tüm optimizasyon problemlerini çözemeyebilirler.

Metasezgiseller, genellikle verilen probleme uyum sağlamak için yalnızca birkaç değişikliklerle çeşitli optimizasyon problemlerine uygulanan algoritmik bir yapılardır.

Metasezgisellerin temel özellikleri aşağıdaki gibi sıralanabilir (Abdal-Basset, 2018).

- Belirli bir probleme özgü oluşturulmazlar.
- Yaklaşık çözümler elde edebilirler.
- Arama alanını “yeterince iyi” bir çözüm bulmak için tararlar.
- Genellikle kolay bir paralel uygulamaya izin verirler.

- Temel yerel aramadan ileri öğrenme tekniklerine kadar uzanırlar.
- İstenmeyen yakınsamayı önlemek için çeşitli mekanizmaları kullanabilir.
- Sezgiseller belirli bir alana özgü bir bilgi olarak metasezgiseller tarafından kullanılabilirler.
- Gelişmiş metasezgisel yöntemler arama deneyimini hafızaya alan rehber bellekten yararlanırlar.

6.1 Metasezgisellerin Sınıflandırılması

Metasezgiseller literatürde çeşitli şekillerde sınıflandırılmışlardır. Metasezgisellerin birbirlerinden ayırt edici özelliklerine göre sınıflandırıldıkları görülmektedir. Sınıflandırma çeşitleri algoritmalara bakış açısıyla değişiklik göstermektedir (Blum ve Roli, 2003).

Metasezgisel algoritmaların literatürde en sık kullanılan sınıflandırma şekillerine aşağıda değinilmiştir.

- Tek çözüm (trajectory) tabanlı - popülasyon tabanlı (Gendreau ve Potvin, 2005; Talbi, 2009; Yang, 2010b)
- Doğadan esinlenen - doğadan esinlenmeyen (Yang, 2010b; Fister ve diğ, 2013)
- Dinamik - statik amaç fonksiyonu
- Tek - çeşitli komşuluk yapıları
- Bellek kullanan – bellek kullanmayan yöntemler (Blum ve Roli, 2003)

Ayrıca doğadan esinlenen algoritmalar, sürü zekası tabanlı, biyo - tabanlı (sürü zekası tabanlı olmayan), fizik ve kimya tabanlı ve diğer algoritmalar olmak üzere dört kategoride sınıflandırılmaktadır (Fister ve diğ, 2013).

Osman (2002), metasezgiselleri yerel tabanlı, yapı tabanlı ve popülasyon tabanlı olmak üzere üç kategoride sınıflandırmıştır. Yerel tabanlı metasezgiseller bir çözümde tekrar tekrar küçük değişiklikler yaparlar. Yapı tabanlı metasezgiseller, eksik bir çözüme her seferinde bir parça ekleyerek bileşen parçalarından çözümler oluştururlar. Popülasyon tabanlı metasezgiseller ise her bir iterasyonda çözüm kümelerini yenileriyle birleştirirerek çözüm oluştururlar.

Metasezgisel algoritmaların sınıflandırılmasına bir başka örnek ise, metafor tabanlı (metaphor - based) ve metafor tabanlı olmayan (non - metaphor based)

metasezgisellerdir. Metafor tabanlı metasezgiseller, doğadaki olayları, insan davranışını ve hatta matematiği simüle eden algoritmalarıdır. Öte yandan, metafora dayalı olmayan metasezgiseller, arama stratejilerini belirlemek için herhangi bir simülasyon kullanmamaktadır.

Metafor tabanlı metasezgiseller, biyoloji, fizik, kimya, sürü, sosyal, müzik, spor ve matematik tabanlı olmak üzere sekiz kategoriye ayrılmaktadırlar.

Metasezgisellerin önemli bir kısmı biyoloji tabanlı metasezgiseller sınıfına girmektedir. Bu tez çalışmasında kullanılan Genetik Algoritma (GA) ve Güve – Işık Optimizasyonu Algoritması (GIOA) biyoloji tabanlı metasezgisellerdir (Mirjalili, 2015).

Fizik tabanlı metasezgisellere örnek olarak Tavlama Benzetimi (TB) , Kara Delik Algoritması (KDA), Spiral Optimizasyonu (SO) verilebilir.

Sürü tabanlı metasezgisellere örnek olarak en çok bilinen Parçacık Sürü Optimizasyonu (PSO), yine tezde ele alınan metasezgisellerdendir (Eberhart ve Kennedy, 1995). Karınca Kolonisi Optimizasyonu (KKO), Yapay Arı Kolonisi (YAK), Yarasa Algoritması (BA) ise sürü tabanlı metasezgisellere verilebilecek diğer örneklerdir .

Beyin Fırtınası Optimizasyonu (BFO), Kültürel Algoritma (KA), Yapay Kabile Algoritması (YKA) ise sosyal tabanlı metasezgiseller için verilebilecek örneklerden bazılarıdır.

Kimyasal Reaksiyon Optimizasyonu (KRO), Gazların Brown Hareketi Optimizasyonu (GBHO) kimyasal tabanlı metasezgiseller sınıfında gruplanabilirler.

Müzik tabanlı metasezgisellere örnek olarak Armoni Arama (AA), Müzik Kompozisyonu Yöntemi (MKY) verilebilirken; spor tabanlı metasezgisellere örnek Altın Top (AT) ve Futbol Oyunu Algoritması (FOA)'dır.

Son olarak; matematik tabanlı metasezgisellere Sinüs Kosinüs Algoritması (SKA), Altın Sinüs Algoritması (ASA) örnek verilebilir.

Metafor tabanlı olmayan metasezgisellerin başında ise Tabu Arama (TA) Algoritması gelmektedir. Çapraz Entropi Yöntemi (ÇEY) de yine metafora dayalı olmayan metasezgisellerin başında gelmektedir.


Doğadan esinlenen - esinlenmeyen metasezgiseller sınıflandırmasında, matematik tabanlı metasezgiseller ve metafora dayalı olmayan metasezgiseller doğadan esinlenmeyen metasezgiseller sınıfında ele alınırken; biyoloji, sürü, müzik, fizik, kimya, spor ve sosyal tabanlı metasezgiseller doğadan esinlenen metasezgiseller sınıfında ele alınmaktadır.

Tüm bu sınıflandırmalar göz önünde bulundurularak kapsamlı bir incelemeyi gösteren metasezgisel sınıflandırma Şekil 6.1’de verilmiştir (Abdel- Basset, 2018).

6.2 Genetik Algoritma

Darwin’ın evrim teorisinin ana mekanizması olan doğal seçimden esinlenilen bir algoritma olan Genetik Algoritma (GA), ilk defa, 1960,1970’lerde J. Holland ve arkadaşları tarafından ortaya atılmıştır. Holland, uyarlanabilir ve yapay sistem çalışmalarında çaprazlama, mutasyon, yeniden üretme ve seçim gibi genetik operatörleri kullanan ilk kişidir. Genetik algoritmanın iki önemli avantajı vardır. Bunlar, kompleks problemlere uygun olması ve paralelliktir. Amaç fonksiyonu sabit veya değişken, doğrusal veya doğrusal olmayan, sürekli veya kesikli olsa da genetik algoritma ile çözülebilmektedir (Yang, 2010b; Yang, 2011).

GA, en popüler evrimsel algoritmaların başında gelmektedir. GA aynı zamanda popülasyon tabanlı bir algoritmadır. Modern evrimsel algoritmalar-direkt veya dolaylı olarak- genetik algoritmaya dayanmakta veya genetik algoritma ile büyük benzerlik göstermektedirler (Yang, 2021).



Şekil 6.1: Metasezgisellerin sınıflandırması (Abdel- Basset, 2018).

Genetik Algoritmanın temel özellikleri aşağıda açıklanmıştır (Roetzel ve diğ, 2020).

- GA parametrelerin kendileriyle değil; parametre kümelerinin kodlanması ile çalışır.
- GA aramayı tek bir noktadan değil; popülasyon adı verilen noktalar kümesinden başlatır.
- GA türevleri veya diğer yardımcı bilgileri değil; kazanç bilgilerini (uygunluk değeri) kullanır.

- GA deterministik değil, olasılığa dayalı geçiş kurallarını kullanır.

Genetik Algoritmanın çalışma prensibinde izlenen adımlar beş tanedir (Roetzel ve diğ, 2020; Yang, 2011).

Adım 1: Başlangıç popülasyonu oluştur. Stokastik olarak oluşturulan çözüm kümesine popülasyon adı verilir. Her bir çözüme koromozom ve her bir optimal değişkene de gen adı verilir. Aday çözüm grubu kodlanır.

Adım 2: Uygunluk değeri belirle. Her bir kromozomun uygunluk fonksiyonu hesaplanır. Bu işleme evrimleşme denir.

Adım 3: Yeni popülasyon oluştur. Seçilen kromozomlar genetik operatörler yardımıyla eşlenir. Bu operatörler, yeniden üretme, çaprazlama ve mutasyondur.

Uygunluk değeri en iyi olan kromozomlar ebeveyn olarak seçilir. Seçimde en sık kullanılan teknik rulet çemberi tekniğidir. Turnuva tekniği, doğrusal sıralama seçimi, uygunluk- oran seçimi diğer seçim tekniklerinden bazılarıdır.


Çaprazlamada seçilen kromozomların bir kısmı birbirini ile yer değiştirir. Çaprazlama oranı p_c büyük bir değerdir. Mutasyonda ise bir kromozomun bir kısmı rastgele değiştirilir. Mutasyon oranı p_m küçük bir değerdir. Mutasyon, yerel optimumdan kurtulmak için yapılmaktadır. Rassal çaprazlama örneği Şekil 6.2 'de, tek noktadan rassal mutasyon örneği ise Şekilde 6.3'de gösterilmiştir (Yang, 2021).

Adım 4: Durdurma kriteri kontrol et. Kriter karşılanmıyor ise 2. adıma gidilir.

Adım 5: Bitir ve en iyi çözümü göster.




Şekil 6.2: Genetik alitmada bir çaprazlama örneği (Yang, 2021).



Şekil 6.3: Genetik alitmada bir mutasyon örneği (Yang, 2021).

GA'nın çalışma prensibini gösteren akış şeması Şekil 6.4'te verilmiştir (Deb, 2001).



Şekil 6.4: Genetik algoritma akış şeması. (Deb, 2001).

Tüm bu açıklamalar ışığında oluşturulan GA'nın sözde kodu Şekil 6.5'te verilmiştir (Yang, 2021).

GENETİK ALGORİTMA

Veri: Amaç fonksiyonu $f(x)$

Sonuç: En iyi veya optimal çözüm

Çaprazlama oranı (p_c) ve mutasyon oranını (p_m) belirle;

Kromozomlara çözümleri kodla;

Uygunluk değerini hesapla, F ;

While $t < \text{maksimum jenerasyon sayısı}$ **do**

 Çaprazlama ve mutasyon ile yeni çözüm oluştur;

 Bir çaprazlama oranı (p_c) ile çaprazlama yap;

 Bir mutasyon oranı (p_m) ile değiştir (mutasyona uğrat);

 Uygunluk değeri daha iyi ise yeni çözümü kabul et;

 Güncel en iyiyi yeni jenerasyon için seç (elitizm);

 Güncelle $t=t+1$;

End

Sonuçları yazdır ve görselleştir;

Şekil 6.5: Genetik algoritma sözde kodu (Yang, 2021).

6.3 Parçacık Sürü Optimizasyonu

Parçacık Sürü Optimizasyonu (PSO) algoritması balık veya kuş sürüsü gibi hayvan topluluklarının davranışlarından esinlenerek 1995 yılında geliştirilmiş bir algoritmadır (Eberhart ve Kennedy).


PSO, esnekliği ve basitliği ile sürü zekası tabanlı algoritmalar arasında en yaygın kullanılan algoritmadır. Bir taraftan sürü davranışlarını taklit ederken bir yandan da evrimsel programlama ve genetik algoritma ile bağları bulunmaktadır. PSO'da da çözüm kümesi (popülasyon) rastgele seçilir ve en iyi çözüm için değerlendirme yapılır. Ancak algoritma, arama sürecinde her bir aday çözümün şimdiye kadar elde edilmiş

en iyi konum hafızasına ve hız vektörüne sahip olması ile evrimsel programlamadan ayrılır.

PSO, parçacık adı verilen bireysel ajanların yörüngelerini ayarlayarak amaç fonksiyonunun alanını tarar. Bu taramayı konumsal vektörler tarafından yarı stokastik bir şekilde oluşturulan parçalı yollarla yapar.

Her bir parçacık global en iyi g^* ve kendi en iyi konumu x_i^* tarafından çekilirken aynı zamanda da rassal olarak hareket etme eğilimindedir. Bir parçacık bulunduğu konumdan daha iyi bir konumla karşılaştığında yeni konumunu bulduğu en iyi konum olarak günceller. İterasyonlar boyunca, t zamanı için n tane parçacık en iyi konumu belirler. Amaç, belirli bir iterasyona veya artık amaç fonksiyonu iyileşme göstermeyene kadar, bulunan en iyiler içerisinde global en iyiyi bulmaktır. (Abdel-Basset ve diğ, 2018).

PSO adımlarında anlatılan bir parçacığın hareketi Şekil 6.6’da gösterilmektedir.



Şekil 6.6: PSO’da bir parçacığın yerel en iyiye ve global en iyiye hareketi (Yang, 2010a).

Parçacık Sürü Optimizasyonu algoritmasının adımları aşağıdaki şekilde sıralanabilir.

Adım 1: Konum ve hız vektörü oluşturarak (rastgele) başlangıç çözümü oluştur.

Adım 2: Her bir parçacık için uygunluk değerini (amaç fonksiyonu) hesapla.

Adım 3: Her bir parçacık için yerel en iyiyi (x_i^*) bul.

Adım 4: Global en iyiyi (g^*) bul.

Adım 5: Denklem 6.1 ve 6.2’yi kullanarak her bir parçacık için hız ve konum vektörünü güncelle.

Adım 6: Durma kriterini kontrol et. Durma kriteri sağlanana kadar Adım 2-5’i uygula.

Algoritmada ilk hız vektörü rassal olarak oluşturulduktan sonra yeni hız vektörü denklem (6.1)'deki gibi hesaplanmaktadır.

$$v_i^{t+1} = v_i^t + c_1 r_1 (g^* - x_i^t) + c_2 r_2 (x_i^{*(t)} - x_i^t) \quad (6.1)$$

x_i ve v_i , i. parçacığın konum ve hız vektörüdür. r_1 ve r_2 0 ile 1 arasında değer alan rassal sayılardır. c_1 ve c_2 ise öğrenme parametreleri veya ivme sabiti olarak adlandırılır ve genelde “2” değerini alırlar.

Denklem (6.2) ise konum vektörünün güncellenmesinde kullanılan eşitliği göstermektedir. Δt , zaman artışını ifade etmektedir. Parçacıkların ilk hızı 0 olarak alınmaktadır.

$$x_i^{t+1} = x_i^t + v_i^{t+1} \Delta t \quad (6.2)$$

PARÇACIK SÜRÜ OPTİMİZASYONU

Amaç fonksiyonu $f(x)$, $x = (x_1, \dots, x_p)^T$

n parçacık için konum (x_i) ve hız (v_i) vektörü oluştur.

$t = 0$ anında $\min \{f(x_1), \dots, f(x_n)\}$ 'den g^* 'ı bul

While

$t = t + 1$ (sözde zaman veya iterasyon sayacı)

For tüm n parçacık ve tüm p boyutları

Denklem 6.1'i kullanarak yeni hız vektörünü (v_i^{t+1}) güncelle

Yeni konum vektörünü hesapla (Denklem 6.1)

Yeni konum, x_i^{t+1} için amaç fonksiyonlarını değerlendir.

Her bir parçacık (x_i^*) için en iyiyi bul

End for


Şimdiye kadarki global en iyiyi, g^* bul

End While

Sonuçları yazdır (x_i^* ve g^*)

Şekil 6.7: PSO sözde kodu (Yang, 2010a).

Bu bölümde açıklanan ifadelerin özetlendiği PSO sözde kodu Sekil 6.7’de ve PSO’nun çalışma prensibi akış şeması olarak Şekil 6.8’de verilmiştir.



Şekil 6.8: PSO akış şeması.


6.4 Güve-Işık Optimizasyonu

İlk defa Mirjalili (2015) tarafından geliştirilen Güve- Işık Optimizasyonu Algoritması (GIOA), doğadan esinlenen, sürü zekası tabanlı yeni bir algoritmadır. Aynı zamanda yapılan sınıflandırmalarda popülasyon tabanlı algoritmalar sınıflandırmasında yer almaktadır.

Güveler ay ışığından yararlanarak uçarlar. Kelebek familyasına benzer böcekler olan güvelerin, geceleri yol bulmak için “enine yönlendirme (transverse orientation)” adı


verilen özel bir yöntemleri vardır. Güve-Işık Optimizasyonu (GIO) Algoritması, güvelerin bu özel uçuş yöntemlerinden esinlenerek ortaya çıkmıştır.

Şekil 6.9’da görüldüğü üzere, güveler söz konusu yön bulma yöntemiyle aya doğru sabit bir açıyla düz bir yol alarak uçmaktadırlar. Uzun mesafe uçuşlarında güvenin düz bir yol almasında bu yöntem oldukça efektif bir yöntemdir.



Şekil 6.9: Enine yönlendirme (Mirjalili, 2015).

Ancak güveler yapay ışık kaynakları için de aynı davranışı sergilerler. Enine yönlendirme yöntemi ışık kaynağı uzaktayken düz bir yol almada efektif olmasına rağmen; ışık kaynağı yakın olduğunda aynı şeyi söylemek mümkün olmamaktadır. Güveler aya göre oldukça yakın yapay ışık kaynaklarına da aynı davranışı sergilerler. Yapay ışık kaynağıyla da aynı sabit açıyı koruyacak şekilde uçmaya devam ederler. Bu durum ise güvelerin artık düz bir yol izlemesi yerine, Şekil 6.10’daki gibi spiral uçuş sergilemesine neden olmaktadır. Güve sonunda ışığa yaklaşacaktır. Güve-Işık Optimizasyonu algoritması da güvelerin bu uçuşlarından esinlenerek ortaya atılmıştır.



Şekil 6.10: Yakın ışık kaynakları etrafında spiral uçuş yolu (Mirjalili, 2015).

GIOA terimleri Çizelge 6.1’de tanımlanmıştır (Shehab ve diğ., 2020).

Çizelge 6.1: GIOA’nın özellikleri (Shehab ve diğ., 2020).

Algoritma tanımları	Güve-Işık Terimleri
Karar değişkeni	Her bir boyuttaki güve konumu
Çözümler	Güve konumu
İlk çözümler	Güvenin rassal konumu
Güncel çözümler	Güvenin güncel konumu
Yeni çözümler	Güvenin yeni konumu
En iyi çözüm	Işık konumu
Uygunluk fonksiyonu	Güve ile ışık arasındaki uzaklık
Yeni çözüm oluşturma süreci	Bir ışığa doğru gidilen spiral yol

GIOA altı adımdan oluşmaktadır (Zheng ve diğ., 2021).

Adım 1. Parametreleri tanımla. Güve ve ışık sayılarını, değişken sayısını, maksimum iterasyon sayısını, değişkenlerin üst ve alt sınırlarını tanımla. Denklem (6.3) ve denklem (6.4)’te sırasıyla üst ve alt sınırlar tanımlanmaktadır.

$$ub = [ub_1, ub_2, ub_3, \dots, ub_{n-1}, ub_n] \quad (6.3)$$

$$lb = [lb_1, lb_2, lb_3, \dots, lb_{n-1}, lb_n] \quad (6.4)$$

Adım 2. Güve ve ışıkların ilk konumlarını oluştur. Güve ve ışık küme matrisleri sırasıyla, denklem (6.5) ve (6.6)’da verilmiştir.

$$M = \begin{bmatrix} m_{1,1} & m_{1,2} & \dots & \dots & m_{1,d} \\ m_{2,1} & m_{2,2} & \dots & \dots & m_{2,d} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ m_{n,1} & m_{n,2} & \dots & \dots & m_{n,d} \end{bmatrix} \quad (6.5)$$

Denklem (6.6) ‘da n güve sayısını ve d çözüm uzayındaki boyut sayısını ifade etmektedir.

$$F = \begin{bmatrix} F_{1,1} & F_{1,2} & \cdots & \cdots & F_{1,d} \\ F_{2,1} & F_{2,2} & \cdots & \cdots & F_{2,d} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ F_{n,1} & F_{n,2} & \cdots & \cdots & F_{n,d} \end{bmatrix} \quad (6.6)$$

Adım 3. Uygunluk fonksiyonunu hesapla. Denklem (6.7) güvelerin, (6.8) ise ışıkların uygunluk fonksiyonunu ifade etmektedir. Denklem (6.5)'teki her güvenin konum vektörü (her bir satır), uygunluk fonksiyonuna aktarılır. Uygunluk fonksiyonunun çıktısı uygunluk değeri olarak karşılık gelen güveye atanır (örneğin OM_1).


$$OM = \begin{bmatrix} OM_1 \\ OM_2 \\ \vdots \\ OM_n \end{bmatrix} \quad (6.7)$$

$$OF = \begin{bmatrix} OF_1 \\ OF_2 \\ \vdots \\ OF_n \end{bmatrix} \quad (6.8)$$

Adım 4. Güvelerin konumlarını ışıklara göre güncelle. Hem güve hem de ışıklar algoritmanın çözümleridir. Aralarındaki fark eğitim ve güncelleme yönteminden gelmektedir. Güvelerin konumu ışıkların konumlarına göre güncellenerek oluşturulurken, güvelerin çözüm kümesi, güvelerin o aşamaya kadarki en iyi çözümlerinden oluşmaktadır. GIO, global optmale yaklaşmak için üç fonksiyon kullanmaktadır. Bunlar sırasıyla denklem (6.9), (6.10) ve (6.11)'da tanımlanmışlardır.

$$MFO = (I, P, T) \quad (6.9)$$

Güvelerin ışıklara göre eşleşmesi ve güncellenmesi Şekil 6.11'deki gibidir (Mehne ve Mirjalili, 2020).



Şekil 6.11: Güve-ışık eşleşmesi (Mehne ve Mirjalili, 2020).

I güvelerin ilk rassal konumunu, P güvelerin hareketini ve son olarak T arama sürecinin bitimini ifade etmektedir. Denklem (6.10) I fonksiyonunu ifade etmekte olup, ilk konumda rassal dağılım uygulanması için kullanılmaktadır.


$$m_{*,j} \text{ or } F_{*,j} = (ub_j - lb_j) \times rand() + lb_j \quad (6.10)$$

Daha önce ifade edildiği gibi algoritma güvelerin enine yönlendirme davranışından esinlenmektedir. Bu davranışa göre, her bir güvenin ışığa göre konumunu güncellemektedir. Bu durumu ifade eden matematiksel model denklem (6.11)'deki gibi ifade edilmektedir. M_i , i . güveyi, F_j , j . ışığı ve S , logaritmik spiral fonksiyonu ifade etmektedir. Denklem (6.12)'deki D_i , ışık ile güve arasındaki mesafeyi vermektedir.

$$M_i = S(M_i, F_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + F_j \quad (6.11)$$

$$D_i = |F_j - M_i| \quad (6.12)$$

t değişkeni güvenin ışığa bir sonraki konumda ne kadar yakın olması gerektiğini göstermektedir. Şekil 6.12'te de görüldüğü gibi t 'nin -1 olduğu durumda güve ışığa en yakın konumu almaktadır (Mirjalili, 2015). t , r ile 1 arasında rassal bir değer almakta iken; yakınsama sabiti olarak adlandırılan r ise, -1 den -2'ye doğrusal olarak azalan bir değer almaktadır.




Şekil 6.12: Logaritmik spiral, ışığın etrafındaki alan ve t 'ye göre konum (Mirjalili, 2015).

Adım 5. Işık sayısını güncelle. Algoritma ilerledikçe ışık boyutu azalmaktadır. Başlangıçta güve ve ışık popülasyonu aynı boyutta iken her bir iterasyonda boyut denklem (6.13)'deki gibi küçülmektedir.

$$ışık_{no} = yuvarla \left(N - l \times \frac{N - 1}{T} \right) \quad (6.13)$$

Adım 6. Durdurma kriteri oluştur. Eğer iterasyon sayısı " l ", maksimum iterasyon sayısından küçükse Adım 3'e dön; aksi durumda durdur ve optimal değerleri yazdır.

Algortimanın adımlarını görsel olarak anlatan Güve – Işık Optimizasyonu Algoritmasının akış şeması Şekil 6.13'te verilmiştir (Shehab ve diğ, 2020).



Şekil 6.13: Güve-ışık optimizasyonu algoritması akış şeması (Shehab ve diğ, 2020).

Güve Işık Optimizasyonu Algoritmasının sözde kodu Şekil 6.14'te gösterilmektedir (Bahrami ve diğ, 2018, s.139).

Begin

Algoritma parameterlerini ve ilk verileri tanımla

Güvelerin ilk pozisyonunu oluştur ve uygunluk değerlerini hesapla

While (durdurma kriteri karşılanmamış veya $I < I_{maks}$)

 Işık no güncelle

 OM= Uygunluk Fonksiyonu (M)

If iterasyon =1

 F=sort(M)

 OF=sort(OM)

Else

 F=sort($M_t - 1, M_t$)

 OF= sort($M_t - 1, M_t$)

End if

For i=1:N

For j=1:D

 r ve t'yi güncelle

 Karşılık gelen güveye göre D'yi hesapla

 Karşılık gelen güveye göre M(i,j)'yi güncelle

End j için

End i için

End While

Sonuçların sonradan işlenmesi ve görselleştirilmesi

End

Şekil 6.14: Güve - ışık algoritması sözde kodu (Bahrami ve diğ, 2018, s.139).

7. ÖNERİLEN MODELLER

7.1 ÜBGM(1,1) Parametre Optimizasyonu Modeli

Denklem (7.1)'deki $\tilde{x}^{(0)}$, üçgen bulanık sayı sıralı serisini ifade etmektedir.

$$\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}, \quad (7.1)$$

Açık olarak $\tilde{x}^{(0)}(k) = [x_L^{(0)}(k), x_M^{(0)}(k), x_R^{(0)}(k)]$ şeklinde ifade edilir. Buna göre parametre optimizasyonlu Üçgen Bulanık Gri Model (ÜBGM(1,1)) için uygulanan adımlar aşağıdaki gibidir.

1. Geleneksel GM(1,1)'de olduğu gibi birinci dereceden birikimli üretim işlemi (accumulated generating operation- AGO) (BÜİ), orjinal üçgen bulanık sıralı seri, $\tilde{x}^{(0)}$ 'a uygulanır. Böylece, $\tilde{x}^{(0)}$ monoton artan seriye dönüştürülür.

$$\tilde{x}^{(1)} = \{\tilde{x}^{(1)}(1), \tilde{x}^{(1)}(2), \dots, \tilde{x}^{(1)}(n)\}, \quad (7.2)$$

Denklem (7.2)'deki her bir $\tilde{x}$ değeri denklem (7.3)'teki gibi her bir $\tilde{x}$ değerinin bir önceki $\tilde{x}$ değeriyle toplanmasıyla hesaplanmaktadır.

$$\begin{aligned} \tilde{x}^{(1)}(k) &= \sum_{i=1}^k \tilde{x}^{(0)}(i) = \left[\sum_{i=1}^k x_L^{(0)}(i), \sum_{i=1}^k x_M^{(0)}(i), \sum_{i=1}^k x_R^{(0)}(i) \right] \\ &= [x_L^{(1)}(k), x_M^{(1)}(k), x_R^{(1)}(k)] \end{aligned} \quad (7.3)$$

2. ÜBGM(1,1) modelinin gri diferansiyel denklemi denklem (7.4)'teki gibi elde edilmektedir.

$$\tilde{x}^{(0)}(k) + a \times \tilde{z}^{(1)}(k) = \tilde{b}, k = 2, 3, \dots, n., \quad (7.4)$$

Dolayısıyla, denklem (7.4) 'ün açık ifadesi denklem (7.5)'teki gibidir.

$$\begin{aligned} & \left[x_L^{(0)}(k), x_M^{(0)}(k), x_R^{(0)}(k) \right] + a \left[z_L^{(1)}(k), z_M^{(1)}(k), z_R^{(1)}(k) \right] \\ & = [b_L, b_M, b_R] \end{aligned} \quad (7.5)$$

Denklem (7.5)'deki a gelişme parametresi net sayıdır ve (7.9)'da gösterildiği üzere, a_L, a_M ve a_R 'nin ağırlıklı ortalamasından elde edilir. $\tilde{b}$ gri parametredir ve üçgen bulanık sayıdır. $\tilde{b} = [b_L, b_M, b_R]$ olarak ifade edilir.

$\tilde{z}$ değeri, klasik ÜBGM(1,1) modelinde sıralı iki zamandaki değerlerin ortalamasını ifade eder ve bu yüzden λ parametresi 0,5 olarak kabul edilmektedir. Parametrelerin en iyilendiği bu modelde ise $\tilde{z}$ değeri denklem (7.7)'deki gibi ifade edilmektedir. $\tilde{\lambda}$ üçgen bulanık sayı olup, değeri 0 ile 1 arasında değişmektedir (denklem (7.8)).

$\tilde{z}^{(1)}(k) = [z_L^{(1)}(k), z_M^{(1)}(k), z_R^{(1)}(k)]$ olmak üzere,

$$\tilde{z}^{(1)}(k) = \tilde{\lambda} \tilde{x}^{(1)}(k-1) + (1 - \tilde{\lambda}) \tilde{x}^{(1)}(k), k = 2, 3, \dots n. \quad (7.7)$$

$$\tilde{\lambda} = [0, 1], \quad (7.8)$$

$$\lambda_R \geq \lambda_M \geq \lambda_L \quad (7.8a)$$

$$a = \alpha a_L + \beta a_M + \gamma a_R \quad (7.9)$$

Denklem (7.9) 'daki parametrelere ait kısıtlar denklem (7.10) – (7.12)'de verilmiştir.

$$\alpha + \beta + \gamma = 1 \quad (7.10)$$

$$\beta \geq \alpha \quad (7.11)$$

$$\beta \geq \gamma \quad (7.12)$$

3. En küçük kareler yöntemiyle denklem (7.13) elde edilmektedir. Matris işlemlerinde denklem (7.13a)-(7.13c)'den yararlanılmaktadır.

$$\begin{aligned} \begin{pmatrix} a_L \\ b_L \end{pmatrix} &= (A^T A)^{-1} A^T Y_L, & \begin{pmatrix} a_M \\ b_M \end{pmatrix} &= (B^T B)^{-1} B^T Y_M, \\ \begin{pmatrix} a_R \\ b_R \end{pmatrix} &= (C^T C)^{-1} C^T Y_R \end{aligned} \quad (7.13)$$

$$A = \begin{bmatrix} -z_L^{(1)}(2) & -1 \\ -z_L^{(1)}(3) & -1 \\ \dots & \dots \\ -z_L^{(1)}(n) & -1 \end{bmatrix}, Y_L = \begin{bmatrix} -x_L(2) \\ -x_L(3) \\ \dots \\ -x_L(n) \end{bmatrix} \quad (7.13a)$$

$$B = \begin{bmatrix} -z_M^{(1)}(2) & -1 \\ -z_M^{(1)}(3) & -1 \\ \dots & \dots \\ -z_M^{(1)}(n) & -1 \end{bmatrix}, Y_M = \begin{bmatrix} -x_M(2) \\ -x_M(3) \\ \dots \\ -x_M(n) \end{bmatrix} \quad (7.13b)$$

$$C = \begin{bmatrix} -z_R^{(1)}(2) & -1 \\ -z_R^{(1)}(3) & -1 \\ \dots & \dots \\ -z_R^{(1)}(n) & -1 \end{bmatrix}, Y_R = \begin{bmatrix} -x_R(2) \\ -x_R(3) \\ \dots \\ -x_R(n) \end{bmatrix} \quad (7.13c)$$

4. Terse birikimli üretim işlemi (Inverse Accumulated Generating Operation- IAGO) (TBÜİ) uygulanır. Zamana duyarlı seri, denklem (7.15) uygulanarak elde edilir. (7.14) ilk koşul olarak alınır.

$$\hat{\tilde{x}}^{(0)}(1) = \tilde{x}^{(0)}(1) \quad (7.14)$$

$$\hat{\tilde{x}}^{(1)}(k) = \left(\tilde{x}^{(1)}(1) - \frac{\tilde{b}}{a} \right) e^{-a(k-1)} + \frac{\tilde{b}}{a}, k = 2, 3, \dots, n \quad (7.15)$$

$\hat{\tilde{x}}^{(1)}(k)$ kümülatif tahmin değeri olup, tahmin değeri (7.16) ile elde edilir.

$$\hat{\tilde{x}}^{(0)}(k) = \left(\hat{\tilde{x}}^{(1)}(k) - \hat{\tilde{x}}^{(1)}(k-1) \right), k = 2, 3, \dots, n \quad (7.16)$$

7.1.1 GA ile ÜBGM(1,1) parametre optimizasyonu

GA tabanlı ÜBGM(1,1) modeli adımları aşağıdaki gibidir. (Hsu, 2009).

Orijinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir.

Adım1 ve 2 aynıdır.

Adım 3. Genetik algoritma ile parametre optimizasyonu yapılır. ($\tilde{\lambda}$, β , α ve γ .)

3.1. Başlangıç çözümü oluşturun.

3.2. Uygunluk fonksiyonu oluşturun. OMYH uygunluk fonksiyonunu oluşturun.

3.3. Yeni popülasyon oluştur.


3.4. Çaprazlama ve mutasyon

3.5. Durma kriterini kontrol et

3.6. Bitir ve en iyi çözümü yazdır.

Adım 4. En küçük kareler yöntemini uygula.

Adım 5. Tahmin değerlerini denklem (7.15) ve (7.16)'yı kullanarak hesapla. Modele ait akış şeması Şekil 7.1'de verilmiştir.



Şekil 7.1: GA-ÜBGM(1,1) modeline ait akış şeması.

7.1.2 PSO algoritması ile ÜBGM(1,1) parametre optimizasyonu

PSO tabanlı ÜBGM(1,1) modeli adımları aşağıdaki gibidir. (Ma ve diğ, 2013).

Orjinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir.

Adım1 ve 2 aynıdır.

Adım 3. Parçacık sürü optimizasyonu ile parametre optimizasyonu yapılır. ($\tilde{\lambda}$, β , α ve γ .)

3.1. Popülasyon büyüklüğünü (N) ve maksimum iterasyonu belirle. Rassal olarak parçacığın ilk hızını ve konumunu belirle.

3.2. Her bir parçacık için uygunluk fonksiyonu oluştur. OMYH uygunluk fonksiyonunu oluşturur.

3.3. Her bir parçacık için yerel en iyi konumu (x_i^*) bul. Global en iyiyi (g^*) hesapla.

3.4. Durma kriterini kontrol et. Durdurma kriteri sağlanıyorsa adım 6'ya git. Sağlanmıyorsa 5. adım ile devam et.


3.5. Denklem (6.1) ve (6.2)'yi kullanarak her bir parçacık için hız ve konum vektörünü güncelle.

3.6. Bitir ve en iyi çözümü ($\tilde{\lambda}^*, \alpha^*, \beta^*, \gamma^*$) yazdır.

Adım 4. En küçük kareler yöntemini uygula.

Adım 5. Tahmin değerlerini denklem (7.15) ve (7.16)'yı kullanarak hesapla.

Adımları verilen PSO-ÜBGM(1,1) modeline ait akış şeması Şekil 7.2'de sunulmuştur.



Şekil 7.2: PSO-ÜBGM(1,1) modeline ait akış şeması.

7.1.3 GIO algoritması ile ÜBGM(1,1) parametre optimizasyonu¹

GIOA tabanlı ÜBGM(1,1) modeli adımları aşağıdaki gibidir.

¹ Bu bölüm “Tanyolaç Bilgiç, C., Bilgiç, B. ve Çebi, F. (2022). Fuzzy Grey Forecasting Model optimized by Moth-Flame Optimization Algorithm for short time electricity consumption, Journal of Intelligence and Fuzzy Systems, 42 (1), 129-138.” isimli yayından alınmıştır.

Orjinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir.

Adım 1. Birinci mertebeden birikimli üretim işlemi orjinal üçgen bulanık sıralı seri $\tilde{x}^{(0)}$ 'a uygulanır. $\tilde{x}^{(0)}$ monoton artırımlı seriye dönüştürülür. $\tilde{x}^{(1)} = \{\tilde{x}^{(1)}(1), \tilde{x}^{(1)}(2), \dots, \tilde{x}^{(1)}(n)\}$

Adım 2. Parametre $\tilde{\lambda}$ denklem (7.7) gibi hesaplanır.

Adım 3. $\tilde{\lambda}$, β , α ve γ parametrelerini optimize etmek için Güve-Işık Optimizasyonu Algoritması uygulanır.

3.1. Parametreleri belirle.

3.2. İlk çözümleri oluştur.


3.3. Uygunluk fonksiyonunu oluştur. Modelin amaç fonksiyonu uygunluk fonksiyonudur. Model, tahmin hatasını minimize etmeyi amaçlamaktadır. OMYH hata ölçütü kullanılmıştır.

3.4. Işıklara göre güvelerin pozisyonunu güncelle.

3.5. Işık sayısını güncelle.

3.6. Maksimum iterasyona ulaşıldığında algoritmayı durdur.

En iyi çözümü veren parametreleri ($\tilde{\lambda}^*$, β^* , α^* ve γ^*) ve en iyi çözümü seç.



Şekil 7.3: GIO-ÜBGM(1,1) modeline ait akış şeması.


Adım 4. En küçük kareler yöntemini uygula.

Adım 5. Tahmin değerlerini denklem (7.15) ve (7.16)'yı kullanarak hesapla. Modele ait akış şeması Şekil 7.3'te gösterilmiştir.

7.2 Yuvarlanma Mekanizmalı ÜBGM(1,1)

Orjinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir. Yuvarlanma mekanizmalı Üçgen Bulanık Gri Model (1,1)'de k adet veri boyutu belirlenir. Bu durumda ilk veri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(k)\}$ olarak belirlenir. ÜBGM(1,1) veriye uygulanarak $\hat{\tilde{x}}^{(0)}(k+1)$ tahmin edilir. $\hat{\tilde{x}}^{(0)}(k+2)$ 'nin tahmini için $\tilde{x}^{(0)}(1)$ veriden çıkarılır ve sona $\tilde{x}^{(0)}(k+1)$ orjinal değeri eklenerek yine ÜBGM(1,1) modeli uygulanır.

Bu tez çalışmasında da olduğu gibi, veri test ve eğitim verisi olarak ayrıldığında, bu işlem $\hat{\tilde{x}}^{(0)}(n-t+1)$ tahmin edilene kadar devam eder. t, test veri boyutunu temsil etmektedir. $\hat{\tilde{x}}^{(0)}(n-t+1)$ değerinden sonraki test verilerini tahmin ederken verinin sonuna tahmin değeri eklenip serideki ilk değer çıkartılarak işlemler $\hat{\tilde{x}}^{(0)}(n)$ değeri tahmin edilene kadar yapılır. Çünkü test verisinin gerçek değerinin bilinmediği varsayılır. Yapılan işlemlerin akış şeması Şekil 7.4'te ayrıntılı olarak açıklanmıştır.



Şekil 7.4: Yuvarlanma mekanizmalı ÜBGM(1,1) modeli.

7.3 Yuvarlanma Mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu

7.3.1 Genetik algoritma ile yuvarlanma mekanizmalı ÜBGM(1,1) parametre optimizasyonu

Orjinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir. Veri boyutu, k belirlenir. Buna göre seri, $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(k)\}$ olarak belirlenir. Denklem (7.2) ve (7.4) uygulanır. Bu denklemler birinci ve ikinci adımı ifade etmektedir.

Adım 3. Genetik algoritma ile parametre optimizasyonu yapılır. ($\tilde{\lambda}$, β , α ve γ .)

3.1. Başlangıç çözümü oluştur.

3.2. Uygunluk fonksiyonu oluştur. OMYH uygunluk fonksiyonunu oluşturur.

3.3. Yeni popülasyon oluştur.

3.4. Çaprazlama ve mutasyon


3.5. Durma kriterini kontrol et

3.6. Bitir ve en iyi çözümü yazdır.

Adım 4. En küçük kareler yöntemini uygula.

Adım 5. Tahmin değerlerini denklem (7.15) ve (7.16)'yı kullanarak hesapla.

Modele ait akış şeması Şekil 7.5'te verilmiştir.



Şekil 7.5: GA-yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması.

7.3.2 PSO algoritması ile yuvarlanma mekanizmalı ÜBGM(1,1) parametre optimizasyonu

Orjinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir. Veri boyutu, k belirlenir. Buna göre seri, $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(k)\}$ olarak belirlenir. Denklem (7.2) ve (7.4) uygulanır. Bu denklemler birinci ve ikinci adımı ifade etmektedir.

Adım 3. Parçacık sürü optimizasyonu ile parametre optimizasyonu yapılır. ($\tilde{\lambda}$, β , α ve γ .)

3.1. Popülasyon büyüklüğünü (N) ve maksimum iterasyonu belirle. Rassal olarak parçacığın ilk hızını ve konumunu belirle.

3.2. Her bir parçacık için uygunluk fonksiyonu oluştur. OMYH uygunluk fonksiyonunu oluşturur.

3.3. Her bir parçacık için yerel en iyi konumu (x_i^*) bul. Global en iyiyi (g^*) hesapla.

3.4. Durma kriterini kontrol et. Durdurma kriteri sağlanıyorsa adım 6'ya git. Sağlanmıyorsa 5. adım ile devam et.

3.5. Denklem (6.1) ve (6.2)'yi kullanarak her bir parçacık için hız ve konum vektörünü güncelle.


3.6. Bitir ve en iyi çözümü ($\tilde{\lambda}^*, \alpha^*, \beta^*, \gamma^*$) yazdır.

Adım 4. En küçük kareler yöntemini uygula.

Adım 5. Tahmin değerlerini denklem (7.15) ve (7.16)'yı kullanarak hesapla.

İlk veri çıkarılıp k+1'inci veri seriye eklenerek işlemler tekrarlanır. Yuvarlanma mekanizmalı ÜBGM(1,1)deki adımlar algoritma kullanılarak uygulanır.

Adımları verilen PSO- Yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması Şekil 7.6'da sunulmuştur.



Şekil 7.6: PSO-yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması.

7.3.3 GIO algoritması ile yuvarlanma mekanizmalı ÜBGM(1,1) parametre optimizasyonu

Orjinal seri $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(n)\}$ 'dir. Veri boyutu, k belirlenir. Buna göre seri, $\tilde{x}^{(0)} = \{\tilde{x}^{(0)}(1), \tilde{x}^{(0)}(2), \dots, \tilde{x}^{(0)}(k)\}$ olarak belirlenir.

Adım 1. Birinci mertebeden birikimli üretim işlemi orjinal üçgen bulanık sıralı seri $\tilde{x}^{(0)}$ 'a uygulanır. $\tilde{x}^{(0)}$ monoton artırımlı seriye dönüştürülür. $\tilde{x}^{(1)} = \{\tilde{x}^{(1)}(1), \tilde{x}^{(1)}(2), \dots, \tilde{x}^{(1)}(k)\}$

Adım 2. Parametre $\tilde{\lambda}$ denklem (7.7) gibi hesaplanır.

Adım 3. $\tilde{\lambda}$, β , α ve γ parametrelerini optimize etmek için Güve-Işık Optimizasyonu Algoritması uygulanır.

3.1. Parametreleri belirle.

3.2. İlk çözümleri oluştur.

3.3. Uygunluk fonksiyonunu oluştur. Modelin amaç fonksiyonu uygunluk fonksiyonudur. Model, tahmin hatasını minimize etmeyi amaçlamaktadır. OMYH hata ölçütü kullanılmıştır.

3.4. Işıklara göre güvelerin pozisyonunu güncelle.

3.5. Işık sayısını güncelle.

3.6. Maximum iterasyona ulaşıldığında algoritmayı durdur.


En iyi çözümü veren parametreleri ($\tilde{\lambda}^*$, β^* , α^* ve γ^*) ve en iyi çözümü seç.

Adım 4. En küçük kareler yöntemini uygula.

Adım 5. Tahmin değerlerini denklem (7.15) ve (7.16)'yı kullanarak hesapla.

İlk veri çıkarılıp k+1'inci veri seriyeye eklenerek işlemler tekrarlanır. Yuvarlanma mekanizmalı ÜBGM(1,1)'deki adımlar algoritma kullanılarak uygulanır.

Modele ait akış şeması Şekil 7.7'de gösterilmiştir.



Şekil 7.7: GIOA-yuvarlanma mekanizmalı ÜBGM(1,1) modeline ait akış şeması.



8. ÜBGM(1,1) MODELLERİ VE GERÇEK HAYAT UYGULAMASI

Bu bölümde, Türkiye'nin saatlik elektrik tüketim verileriyle elektrik talebi tahmin edilmiştir. Talep tahminlerinde bir önceki bölümde sunulmuş olan modeller kullanılmıştır. Bir hata ölçütü olan ortalama mutlak yüzde hatası (OMYH) kullanılarak önerilen modellerin tahmin gücünü ölçülmüştür. Literatürde varolan ve bu çalışmada da detaylı açıklanan ÜBGM (1,1) modeli ile önerilen modeller OMYH hata ölçütü kullanılarak kıyaslanmıştır.

Bu tezde yapılan uygulamada, Yük Tevzi Bilgi Sistemi'nden alınan 5 Ocak 2021 - 13 Şubat 2021 tarih aralığındaki Türkiye'nin saatlik elektrik tüketim verisinden yararlanılmıştır (URL-1).

Türkiye dışındaki ülkeler için yapılan literatür çalışmalarında, saatlik elektrik tüketimi tahminlerinde ele alınan verilerde gün dörde ayrılmıştır. Ayrıca yine yapılan çalışmalarda tahmin modelleri uygulanırken haftaiçi - haftasonu olarak ayırım yapılmaktadır (Kumluca Topallı, 2003; Li, 2021).

Bu çalışmada Türkiye'nin saatlik elektrik tüketimi ele alındığından EPDK'nın bir günlük elektrik talebini üç döneme ayırdığı hesaba katılmıştır (Tektaş Sivrikaya, 2016). Türkiye'nin elektrik talebini tahmin etmek amaçlandığından, literatürde yapılan çalışmalarda olduğu gibi, bir gün dört döneme değil; üç döneme ayrılmıştır. 22:00-06:00 saatleri arasına gece saatleri, 06:00-17:00 saatleri arasına gündüz saatleri ve 17:00-22:00 saatleri arasına zirve saatler adı verilmektedir. Gece saatleri ara yük, zirve saatleri zirve yük, gündüz saatleri ise temel yük bloğu olarak ele alınmaktadır.

Uygulama çalışmasında ilk olarak gece saatleri dönemi ele alınmış olup, haftaiçi günlerden oluşan 4 Ocak-13 Şubat tarihlerine ait 30 günlük elektrik talebi Çizelge 8.1'de verilmiştir. 1. Gündeki minimum tüketim değeri 4 Ocak 22:00- 5 Ocak 06:00 saatleri arasındaki saatlik elektrik tüketiminin en küçük değerini; maksimum tüketim değeri en büyük değerini ve nihayet ortalama tüketim değeri ise gece saatlerinin ortalama değerini ifade etmektedir. Kalan 29 veri de bu şekilde elde edilmiş olup; üçgen bulanık sayı olarak sırasıyla alt sınır, üst sınır ve orta değeri ifade etmektedirler.

Diğer yük bloklarında da aynı düzenleme yapılmış olup, temel yük bloğu Çizelge 8.2 ve zirve yük bloğu Çizelge 8.3'te verilmiştir. Modellerde sırasıyla %70 ve %80 eğitim verisi kullanılmıştır. İlk olarak 30 adet verinin 21 adedi eğitim, dokuz adedi test verisi; daha sonra 24 adedi eğitim, altı adedi test verisi olarak kullanılmıştır. Tahmin modellerinin performansı, test verilerinin OMYH değeri hesaplanarak kıyaslanmıştır.

Çizelge 8.1: Ara yük bloğuna ait 30 günlük elektrik yükü.

Gün	TÜKETİM (MWh)		
	Minimum	Ortalama	Maksimum
1	29476,93	32113,69	36626,77
2	29901,92	32394,89	37034,63
3	30291,93	32791,21	37484,73
4	30128,43	32806,01	37491,88
5	29795,31	32629,16	36945,26
6	29912,56	32536,54	37030,03
7	29657,64	32145,83	36548,78
8	30037,83	32583,79	37295,74
9	30243,69	33080,84	37948,7
10	30140,92	32969,74	37621,98
11	30874,21	33713,44	38772,55
12	31389,41	34264,95	39518,96
13	31427,68	34271,64	39519,29
14	31300,17	34227,1	39562,63
15	30714,93	33652,85	38556,8
16	30469,48	33273,52	37963,85
17	30483,68	33221,54	37855,97
18	30941,6	33666,41	38415,9
19	31413,86	34142,73	38909,35
20	30495,85	33698,2	38583,16
21	29728,87	32321,91	36881,24
22	29572,31	32303,91	36800,13
23	29565,54	32205,86	36710,79
24	29576,88	32161,84	36680,4
25	29360,91	31927,74	36211,15
26	29064,75	31452,15	35675,14
27	29176,8	31593,2	35861,28
28	29421,44	31886,15	36115,32
29	29213,15	31837,16	36203,31
30	29712,41	32314,45	36543,46

Çizelge 8.2: Temel yük bloğuna ait 30 günlük elektrik yükü.

Gün	TÜKETİM (MWh)		
	Minimum	Ortalama	Maksimum
1	28131,28	37662,74364	41225,04
2	30390,61	38435,56636	41557,1
3	30932,47	38822,00182	42060,75
4	31222,08	38848,27364	41869,71
5	31161,58	38509,08818	41710,85
6	29135,16	38529,04636	41925,3
7	30873,68	38436,12727	41439,1
8	30685,35	39306,86636	42582,13
9	30989,53	40028,04545	43366,74
10	31421,99	40105,47727	43692,1
11	29174,83	40790,02636	44887,05
12	31920,36	41793,37909	45611,43
13	32461,45	42316,12273	46056,56
14	32422,13	41981,65091	45802,42
15	32550,2	41110,19091	45207,33
16	29653,54	39837,03364	43388,03
17	31591,37	39940,39	43060,43
18	30944,79	40451,63455	43825,19
19	31958,8	41351,89545	44709,71
20	32460,57	41109,12545	44951,67
21	28814,06	39372,68364	43694,93
22	30736,61	38940,73818	42414,03
23	30793,79	38243,73818	41251,33
24	30710,53	38057,81	41359,51
25	30534,26	37744,23727	41456,54
26	28226,42	37504,00364	41111,7
27	30060,74	37394,22455	40612,59
28	30234,38	37551,15636	40729,39
29	30363,19	37479,04909	40325,62
30	30349,29	38448,63727	42025,27

Çizelge 8.3: Zirve yük bloğuna ait 30 günlük elektrik yükü.

Gün	TÜKETİM (MWh)		
	Minimum	Ortalama	Maksimum
1	37269.25	39209.336	40588.05
2	37586.09	39521.504	41003.71
3	38202.24	39905.584	41263.52
4	38070.15	40046.27	41561.29
5	37690.66	39334.596	40594.73
6	37737.87	39652.78	41096.85
7	37359.16	39270.454	40770.99
8	38051.48	40253.77	42062.55
9	38652.63	40869.52	42620.22
10	38304.51	40431.286	42123.59
11	39644.43	42067.834	43978.22
12	40256.72	42479.234	44067.24
13	40316.03	42667.474	44391.9
14	40323.63	42555.266	44091.07
15	39274.1	41209.536	42675.54
16	38693.7	40740.94	42352.93
17	38653.74	40632.65	42158.7
18	39148.65	41363.67	43052.09
19	39742.19	41929.096	43434.24
20	39276.85	41203.66	42533.73
21	37451.05	39280.644	40572.95
22	37390.85	39016.324	40030.87
23	37390.68	38745.98	39629.93
24	37259.39	38592.882	39294.59
25	36761.35	37851.798	38543.52
26	36387.19	37975.756	38892.56
27	36619.72	37872.274	38597.61
28	36635.55	37798.572	38458.38
29	36891.37	38113.868	38929.74
30	37162.33	38846.11	39783.06

İlk olarak, sırasıyla Çizelge 8.1, 8.2 ve 8.3’de verilen, ara yük, temel yük ve zirve yük blokları elektrik talepleri eğitim ve test verisi (%70 eğitim, %30 test verisi) olarak ayrılmıştır. Daha sonra eğitim-test verisi oranı % 80-20 olarak ele alınmış ve aynı modellerle elde edilen tahmin sonuçları sunulmuştur.

Optimizasyonlarda kullanılan algoritmalar için belirlenen parametre değerleri Çizelge 8.4’te verilmiştir.

Alt bölümlerde belirlenen parametrelerle 30 koşum sonucu elde edilen en iyi sonuçlar (amaç fonksiyonları) ve süreler verilmiştir.

Çizelge 8.4: Algoritmaların parametre değerleri.

Katsayılar	GA	PSO	GIOA
Maksimum İterasyon Sayısı	100	100	100
Popülasyon Sayısı	80	-	-
Çaprazlama Oranı (p_c)	0,8	-	-
Mutasyon Oranı (p_m)	0,1	-	-
Sürü Boyutu	-	80	-
c_1 öğrenme katsayısı		2	
c_2 öğrenme katsayısı		2	
Arama Ajanları	-	-	80

8.1 ÜBGM(1,1) ile Elektrik Yüğü Tahmini

İlk 21 güne ÜBGM(1,1) modeli uygulanmış ve sonraki dokuz gün ÜBGM(1,1) modeli ile tahmin edilmiştir.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.5’te verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 6,7962 ‘dir.

Çizelge 8.5: Ara yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(31146,92 , 33835,37 , 38648,98)
23	(31203,34 , 33896,66 , 38718,99)
24	(31259,87 , 33958,07 , 38789,13)
25	(31316,5 , 34019,58 , 38859,4)
26	(31373,23 , 34081,21 , 38929,8)
27	(31430,06 , 34142,95 , 39000,32)
28	(31487 , 34204,8 , 39070,97)
29	(31544,03 , 34266,76 , 39141,74)
30	(31601,18 , 34328,84 , 39212,65)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5 , 0,5 , 0,5), 0,25 , 0,5 , 0,25

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.6’da verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 9,3928’dir.

Çizelge 8.6: Temel yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(32625,22, 41105,12, 44418,74)
23	(32719,9, 41224,41, 44547,65)
24	(32814,85, 41344,04, 44676,93)
25	(32910,09, 41464,03, 44806,59)
26	(33005,59, 41584,36, 44936,62)
27	(33101,38, 41705,04, 45067,03)
28	(33197,44, 41826,07, 45197,82)
29	(33293,78, 41947,46, 45328,99)
30	(33390,41, 42069,19, 45460,54)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5 , 0,5 , 0,5), 0,25 , 0,5 , 0,25

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.7’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 9,7529’dır.

Çizelge 8.7: Zirve yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(39614,97, 41651,26, 43277,76)
23	(39698,24, 41738,81, 43368,73)
24	(39781,69, 41826,55, 43459,90)
25	39865,31, 41914,47, 43551,25)
26	(39949,11, 42002,58, 43642,80)
27	(40033,09, 42090,87, 43734,54)
28	(40117,24, 42179,35, 43826,47)
29	(40201,57, 42268,01, 43918,60)
30	(40286,08, 42356,86, 44010,92)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5 , 0,5 , 0,5), 0,25 , 0,5 , 0,25

30 günlük elektrik yükü verisini %80 eğitim verisi ve %20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir.

İlk 24 güne ÜBGM(1,1) modeli uygulanmış ve sonraki altı gün ÜBGM(1,1) modeli ile tahmin edilmiştir.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.8’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 4,4779’dur.

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.9’da verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları

gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 6,5111'dir.

Çizelge 8.8: Ara yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(30509,39, 33180,35, 37942,60)
26	(30518,04, 33189,76, 37953,37)
27	(30526,70, 33199,18, 37964,14)
28	(30535,36, 33208,60, 37974,91)
29	(30544,03, 33218,02, 37985,68)
30	(30552,69, 33227,45, 37996,46)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Çizelge 8.9: Temel yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(31507,70, 40248,68, 43596,87)
26	(31535,98, 40284,80, 43636,00)
27	(31564,28, 40320,95, 43675,16)
28	(31592,61, 40357,14, 43714,36)
29	(31620,96, 40393,36, 43753,59)
30	(31649,34, 40429,61, 43792,86)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.10'da verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 6,3346'dır.

Çizelge 8.10: Zirve yük bloğuna ait ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(38345,66, 40458,40, 42169,29)
26	(38343,21, 40455,82, 42166,60)
27	(38340,77, 40453,24, 42163,91)
28	(38338,32, 40450,66, 42161,22)
29	(38335,88, 40448,08, 42158,53)
30	(38333,43, 40445,50, 42155,84)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

8.2 GA-ÜBGM(1,1) Parametre Optimizasyonu ile Elektrik Yüğü Tahmini

İlk 21 günlük elektrik tüketim verisi kullanılarak dokuz günlük elektrik yükü tahmin edilmiştir. Denklem (8.1)'de de görüldüğü üzere, bir önceki modelden farklı olarak sabit değerler kullanılarak uygulanan modelin parametreleri, hata ölçütü OMYH'nın en küçüklenmesi amaçlanarak optimize edilmiştir.

$$\begin{aligned} \min Z &= OMYH \\ &= 0,25 \times \frac{100}{9} \sum_{k=22}^{30} \left| \frac{\hat{x}_L^{(0)}(k) - x_L^{(0)}(k)}{x_L^{(0)}(k)} \right| + 0,50 \\ &\times \frac{100}{9} \sum_{k=22}^{30} \left| \frac{\hat{x}_M^{(0)}(k) - x_M^{(0)}(k)}{x_M^{(0)}(k)} \right| + 0,25 \\ &\times \frac{100}{9} \sum_{k=22}^{30} \left| \frac{\hat{x}_R^{(0)}(k) - x_R^{(0)}(k)}{x_R^{(0)}(k)} \right| \end{aligned} \quad (8.1)$$

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.11'de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,963026, 0,971999, 0,987148)$, $\alpha = 0,4936$, $\beta = 0,4948$ ve $\gamma = 0,011$ 'dir. Aynı zamanda amaç fonksiyonu olan, dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 6,40'dır.

Çizelge 8.11: Ara yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(31050,12, 33724,26, 38517,67)
23	(31102,95, 33781,64, 38583,2)
24	(31155,86, 33839,12, 38648,84)
25	(31208,87, 33896,69, 38714,6)
26	(31261,97, 33954,36, 38780,47)
27	(31315,16, 34012,13, 38846,45)
28	(31368,44, 34070, 38912,54)
29	(31421,81, 34127,96, 38978,75)
30	(31475,27, 34186,03, 39045,06)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,963026, 0,971999, 0,987148), 0,4936, 0,4948, 0,0116

Çizelge 8.12: Temel yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(32316,38, 40675,49,43940,64)
23	(32396,94, 40776,89,44050,18)
24	(32477,7, 40878,54, 44159,99)
25	(32558,66, 40980,45, 44270,08)
26	(32639,83, 41082,61, 44380,44)
27	(32721,2, 41185,02, 44491,07)
28	(32802,77, 41287,69, 44601,98)
29	(32884,54, 41390,61, 44713,17)
30	(32966,51, 41493,79, 44824,63)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,999753, 0,99998, 0,999994), 0,42, 0,42, 0,16

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.12’de verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,999753, 0,99998, 0,999994)$, $\alpha = 0,42$, $\beta = 0,42$ ve $\gamma = 0,16$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 8,0898 ‘dir.

Çizelge 8.13: Zirve yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(39563,87, 41593,81, 43219,27)
23	(39646,64, 41680,83, 43309,68)
24	(39729,58, 41768,02, 43400,29)
25	(39812,70, 41855,41, 43491,09)
26	(39895,99, 41942,97, 43582,07)
27	(39979,45, 42030,72, 43673,25)
28	(40063,09, 42118,65, 43764,61)
29	(40146,91, 42206,76, 43856,17)
30	(40230,90, 42295,06, 43947,92)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,992846, 0,99589293, 0,997717), 0,363,0,372,0,265

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.13’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,992846, 0,99589293, 0,997717)$, $\alpha = 0,363$, $\beta = 0,372$ ve $\gamma = 0,265$ ’tir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 9,5946‘dır.

30 günlük elektrik yükü verisini %80 eğitim verisi ve %20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak altı günlük elektrik yükü tahmin edilmiştir. Test veri boyutu değiştiğinden amaç fonksiyonu denklem (8.2)’deki gibi düzenlenmiştir.

$$\begin{aligned}
\min Z &= OMYH \\
&= 0,25 \times \frac{100}{6} \sum_{k=25}^{30} \left| \frac{\hat{x}_L^{(0)}(k) - x_L^{(0)}(k)}{x_L^{(0)}(k)} \right| + 0,50 \\
&\times \frac{100}{6} \sum_{k=25}^{30} \left| \frac{\hat{x}_M^{(0)}(k) - x_M^{(0)}(k)}{x_M^{(0)}(k)} \right| + 0,25 \\
&\times \frac{100}{6} \sum_{k=25}^{30} \left| \frac{\hat{x}_R^{(0)}(k) - x_R^{(0)}(k)}{x_R^{(0)}(k)} \right|
\end{aligned} \tag{8.2}$$

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.14’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,082565, 0,830536, 0,915253)$, $\alpha = 0,416$, $\beta = 0,417$ ve $\gamma = 0,167$ ’dir. OMYH değeri ise % 4,3792’dir.

Çizelge 8.14: Ara yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(30489,46, 33150,07, 37905,92)
26	(30497,16, 33158,45, 37915,50)
27	(30504,87, 33166,83, 37925,09)
28	(30512,58, 33175,21, 37934,67)
29	(30520,29, 33183,60, 37944,26)
30	(30528,01, 33191,98, 37953,85)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,082565, 0,830536, 0,915253), 0,416, 0,417, 0,167

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.15’te verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,10120, 0,94255, 0,97328)$, $\alpha = 0,4165$, $\beta = 0,4165$ ve $\gamma = 0,167$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 6,1666’dır.

Çizelge 8.15: Temel yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(31435,89, 40122,76, 43451,22)
26	(31460,77, 40154,51, 43485,61)
27	(31485,67, 40186,29, 43520,02)
28	(31510,59, 40218,10, 43554,47)
29	(31535,53, 40249,93, 43588,94)
30	(31560,49, 40281,79, 43623,44)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,10120, 0,94255, 0,97328), 0,4165, 0,4165, 0,167

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.16’da verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,01916, 0,02388, 0,03226)$, $\alpha = 0$, $\beta = 0,54$ ve $\gamma = 0,46$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 5,8069 ‘dur.

Çizelge 8.16: Zirve yük bloğuna ait GA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(38178,06, 40276,90, 41971,83)
26	(38168,45, 40266,75, 41961,26)
27	(38158,83, 40256,61, 41950,69)
28	(38149,22, 40246,47, 41940,12)
29	(38139,60, 40236,33, 41929,55)
30	(38130, 40226,19, 41918,99)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,01916, 0,02388, 0,03226), 0, 0,54, 0,46

8.3 PSO-ÜBGM(1,1) Parametre Optimizasyonu ile Elektrik Yükü Tahmini

GA-ÜBGM(1,1) modelinde olduğu gibi, ilk 21 günlük elektrik tüketim verisi kullanılarak dokuz günlük elektrik yükü tahmin edilmiştir. Amaç fonksiyonu denklem (8.1)’deki gibi olup, OMYH’nın en küçüklenmesi amaçlanmış ve buna göre parametre optimizasyonu yapılmıştır.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.17’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 6,3909 ‘dur.

Çizelge 8.17: Ara yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(31047,3144, 33721,385, 38515,441)
23	(31100,09382, 33778,711, 38580,916)
24	(31152,96296, 33836,133, 38646,502)
25	(31205,92197, 33893,654, 38712,2)
26	(31258,97102, 33951,272, 38778,01)
27	(31312,11025, 34008,988, 38843,931)
28	(31365,33981, 34066,802, 38909,965)
29	(31418,65986, 34124,714, 38976,11)
30	(31472,07055, 34182,725, 39042,368)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1,1,1), 0,5, 0,5, 0

Çizelge 8.18: Temel yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(32163,36, 40420,57, 43665,1)
23	(32234,1, 40509,47, 43761,14)
24	(32305, 40598,57, 43857,39)
25	(32376,05, 40687,86, 43953,85)
26	(32447,26, 40777,35, 44050,52)
27	(32518,63, 40867,04, 44147,41)
28	(32590,15, 40956,92, 44244,51)
29	(32661,83, 41047, 44341,82)
30	(32733,67, 41137,28, 44439,35)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1,1), 0,5, 0,5, 0

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.18’de verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,1,1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 7,3269’dur. Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.19’da verilmiştir. OMYH değeri % 9,593127’dir.

Çizelge 8.19: Zirve yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(39561,41, 41591,47, 43217,03)
23	(39644,09, 41678,39, 43307,35)
24	(39726,94, 41765,49, 43397,85)
25	(39809,96, 41852,78, 43488,55)
26	(39893,16, 41940,24, 43579,43)
27	(39976,53, 42027,89, 43670,51)
28	(40060,08, 42115,73, 43761,77)
29	(40143,8, 42203,74, 43853,23)
30	(40227,69, 42291,94, 43944,88)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1,1,1), 0,3333, 0,3334, 0,3333

30 günlük elektrik yükü verisini % 80 eğitim verisi ve % 20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak altı günlük elektrik yükü tahmin edilmiştir. Amaç fonksiyonu Denklem (8.2)’deki gibi hesaplanmaktadır.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.20’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,000026, 1, 1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak, modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 4,33365’dir.

Çizelge 8.20: Ara yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(30479,10, 33135,46, 37890,63)
26	(30486,35, 33143,35, 37899,65)
27	(30493,61, 33151,24, 37908,68)
28	(30500,87, 33159,13, 37917,70)
29	(30508,13, 33167,03, 37926,73)
30	(30515,39, 33174,92, 37935,76)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,000026, 1, 1), 0,5 0,5, 0

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.21’de verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,1,1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 5,8948’dir.

Çizelge 8.21: Temel yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(31366,12, 40027,66, 43349,41)
26	(31387,99, 40055,57, 43379,64)
27	(31409,88, 40083,50, 43409,88)
28	(31431,78, 40111,45, 43440,15)
29	(31453,70, 40139,42, 43470,44)
30	(31475,63, 40167,41, 43500,75)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0, 1, 1), 0,5 0,5, 0

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.22’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,0,0)$, $\alpha = 0$, $\beta = 0,50$ ve $\gamma = 0,50$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 5,7489’dur.

Çizelge 8.22: Zirve yük bloğuna ait PSO-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(38159,69, 40257,38, 41951,00)
26	(38149,32, 40246,43, 41939,59)
27	(38138,94, 40235,49, 41928,18)
28	(38128,57, 40224,54, 41916,78)
29	38118,20, 40213,61, 41905,38)
30	(38107,83, 40202,67, 41893,98)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0, 0, 0), 0, 0,5, 0,5

8.4 GIOA-ÜBGM(1,1) Parametre Optimizasyonu ile Elektrik Yüğü Tahmini

Diğer modellerde olduğu gibi bu model ile de ilk 21 günlük elektrik tüketim verisi kullanılarak dokuz günlük elektrik yüğü tahmin edilmiştir. Amaç fonksiyonu da diğer modellerde olduğu gibidir. En küçüklenen hata değerleri ve bu hata değerlerinin elde edilmesini sağlayan parametre değerleri aşağıda verilmiştir.

Çizelge 8.23: Ara yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(31047,3144, 33721,385, 38515,441)
23	(31100,09382, 33778,711, 38580,916)
24	(31152,96296, 33836,133, 38646,502)
25	(31205,92197, 33893,654, 38712,2)
26	(31258,97102, 33951,272, 38778,01)
27	(31312,11025, 34008,988, 38843,931)
28	(31365,33981, 34066,802, 38909,965)
29	(31418,65986, 34124,714, 38976,11)
30	(31472,07055, 34182,725, 39042,368)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1,1,1), 0,5, 0,5, 0

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.23'teki gibidir. PSO-ÜBGM(1,1) ile elde edilen tahmin sonuçları ile aynı sonuçları vermiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 6,3909 'dur.

Çizelge 8.24: Temel yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(32163,36, 40420,57, 43665,1)
23	(32234,1, 40509,47, 43761,14)
24	(32305, 40598,57, 43857,39)
25	(32376,05, 40687,86, 43953,85)
26	(32447,26, 40777,35, 44050,52)
27	(32518,63, 40867,04, 44147,41)
28	(32590,15, 40956,92, 44244,51)
29	(32661,83, 41047, 44341,82)
30	(32733,67, 41137,28, 44439,35)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1,1), 0,5, 0,5, 0

Çizelge 8.25: Zirve yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
22	(39561,41, 4159147, 43217,02)
23	(39644,08, 41678,39, 43307,34)
24	(39727,93, 41765,49, 43397,85)
25	(39809,96, 41852,77, 43488,54)
26	(39893,16, 41940,24, 43579,43)
27	(39976,53, 42028,89, 43670,51)
28	(40060,07, 42115,72, 43761,77)
29	(40144,79, 42203,74, 43853,23)
30	(40227,69, 42291,94, 43944,87)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1,1,1), 0,33333, 0,33333, 0,33333

Temel yük bloğunda olduğu gibi, temel yük bloğu için de elde edilen sonuçlar PSO-ÜBGM(1,1) modeliyle elde edilen sonuçlarla aynıdır. Tahmin sonuçları Çizelge 8.24'te verilmiştir. OMYH değeri % 7,3269'dur.

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.25'te verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,3333$, $\beta = 0,3334$ ve $\gamma = 0,3333$ 'tür. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 9,5931 'dir.

30 günlük elektrik yükü verisini %80 eğitim verisi ve %20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak altı günlük elektrik yükü tahmin edilmiştir. Amaç fonksiyonu denklem (8.2)'deki gibi hesaplanmaktadır.

Çizelge 8.26: Ara yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(30479,10, 33135,46, 37890,63)
26	(30486,35, 33143,35, 37899,65)
27	(30493,61, 33151,24, 37908,68)
28	(30500,87, 33159,13, 37917,70)
29	(30508,13, 33167,03, 37926,73)
30	(30515,39, 33174,92, 37935,76)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,000026, 1, 1), 0,5 0,5, 0

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.26'da verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0, 1, 1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak, modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 4,33365'dir. PSO-ÜBGM(1,1) modeliyle aynı tahmin sonuçları elde edilmiştir. Ancak optimum sonucu veren parametrelerde farklılıklar vardır. Bu durum OMYH değerinde çok düşük bir fark yaratmakta olup, tahmin sonuçlarını etkilememektedir. Hassas bir tahmin elde edilmek istenirse GIOA-ÜBGM(1,1) modelinin

daha optimum bir sonuç yakaladığı bilinmelidir (4,3336541=PSO-ÜBGM(1,1) ve 4,3336539=GIOA-ÜBGM(1,1)).

Çizelge 8.27: Temel yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(31366,12, 40027,66, 43349,41)
26	(31387,99, 40055,57, 43379,64)
27	(31409,88, 40083,50, 43409,88)
28	(31431,78, 40111,45, 43440,15)
29	(31453,70, 40139,42, 43470,44)
30	(31475,63, 40167,41, 43500,75)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0, 1, 1), 0,5 0,5, 0

Çizelge 8.28: Zirve yük bloğuna ait GIOA-ÜBGM(1,1) ile elektrik talebi tahmini.

Gün	TÜKETİM (MWh)
25	(38159,69, 40257,38, 41951,00)
26	(38149,32, 40246,43, 41939,59)
27	(38138,94, 40235,49, 41928,18)
28	(38128,57, 40224,54, 41916,78)
29	38118,20, 40213,61, 41905,38)
30	(38107,83, 40202,67, 41893,98)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0, 0, 0), 0, 0,5, 0,5

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.27’de verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,1,1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 5,8948’dir.

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.28’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,0,0)$, $\alpha = 0$, $\beta = 0,50$ ve $\gamma = 0,50$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 5,7489’dur.

8.5 Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yüğü Tahmini

Öncelikle ilk 21 günlük elektrik tüketim verisi kullanılarak yuvarlanma mekanizmalı ÜBGM(1,1) ile veri boyutu (k) 5 için dokuz günlük elektrik yüğü tahmin edilmiştir.

Ara yük bloğı için elde edilen tahmin sonuçları Çizelge 8.29’da verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 6,7004’tür.

Temel yük bloğı için elde edilen tahmin sonuçları Çizelge 8.30’da verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 4,8154’tür.

Çizelge 8.29: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(29734,5, 32319,14, 36846,13)
23	(28728,83, 31495,52, 35969,02)
24	(28032,72, 30906,56, 35392,7)
25	(28189,66, 30360,38, 34545,87)
26	(27122,86, 29754,86, 33983,18)
27	(26604,45, 29279,36, 33493,89)
28	(26302,91, 28683,35, 32764,36)
29	(26042,12, 28054,1, 31894,06)
30	(24932,29, 27730,68, 31788,1)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Çizelge 8.30: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(31223,01, 39621,47, 42226,08)
23	(29783,79, 38430,06, 42098,05)
24	28900,96, 37586,47, 41449,21)
25	(27864,67, 37848,4, 41311,58)
26	(29508,37, 36189,13, 38443,82)
27	(26938,81, 35975,86, 40291,46)
28	(27027,47, 35524,03, 38673,57)
29	(26564,84, 34913,27, 37568,89)
30	(27593,29, 33693,52, 36484,26)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Çizelge 8.31: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(37003,06, 39255,88, 40963,1033)
23	(36249,61, 38018,87, 39140,8255)
24	(35350,21, 37052,62, 38291,2915)
25	(34553,02, 36476,88, 37879,5477)
26	(33477,27, 35445,79, 36869,959)
27	(33332,09, 34725,47, 35564,771)
28	(32142,95, 33921,92, 35323,3004)
29	(31302,08, 33136,44, 34418,4508)
30	(30870,17, 32420,55, 33478,1265)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.31’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları

gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 7,3030'dur.

Çizelge 8.32: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=7$).

Gün	TÜKETİM (MWh)
22	(30387,65, 33096,85, 37712,27)
23	(30142,49, 32841,16, 37450,43)
24	(29718,81, 32429,79, 37033,48)
25	(29330,87, 32088,47, 36633,95)
26	(29151,93, 32004,53, 36586,2)
27	(29424,84, 31887,54, 36324,23)
28	(28895,33, 31517,23, 35934,35)
29	(28657,64, 31309,7, 35753,72)
30	(28482,81, 31150,73, 35584,67)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Ara yük bloğunda veri boyutu yedi iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.32'de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,6344 'tür.

Temel yük bloğunda veri boyutu altı iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.33'te verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan OMYH değeri ise % 2,5831'dir.

Çizelge 8.33: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).

Gün	TÜKETİM (MWh)
22	(31418,11, 40687,44, 43640,01)
23	(30866,98, 39397,35, 42270,09)
24	(29061,21, 38487,99, 41826,64)
25	(28336,47, 37639,50, 41150,47)
26	(28181,09, 37539,05, 41268,73)
27	(28500,39, 37395,38, 41042,08)
28	(29613,53, 36849,57, 39927,69)
29	(29834,69, 37060,22, 40221,33)
30	(29459,31, 37208,32, 40927,67)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Çizelge 8.34: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=7$).

Gün	TÜKETİM (MWh)
22	(38194,97, 40311,43, 42025,96)
23	(37919,08, 39952,81, 41444,70)
24	(37296,38, 39339,37, 40783,73)
25	(36931,23, 38805,32, 40084,02)
26	(36775,53, 38583,87, 39916,28)
27	(36559,01, 38509,47, 39995,99)
28	(35877,20, 37888,59, 39438,58)
29	(35723,85, 37594,33, 38876,36)
30	(35486,06, 37326,95, 38617,60)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Zirve yük bloğunda veri boyutu 7 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.34’te verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini

için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Dokuz güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan OMYH değeri ise % 2,3247'dir.

30 günlük elektrik yükü verisini %80 eğitim verisi ve % 20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak altı günlük elektrik yükü tahmin edilmiştir. Amaç fonksiyonu denklem (8.2)'deki gibi hesaplanmaktadır.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.35'te verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9682'dir.

Çizelge 8.35: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(29463,73, 32110,28, 36620,64)
26	(29375,35, 32095,48, 36546,08)
27	(29448,39, 31984,09, 36493,01)
28	(29334,56, 31954,01, 36435,97)
29	(29243,32, 31930,26, 36387,21)
30	(29241,54, 31863,60, 36300,71)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,5, 0,25

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.36'da verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 3,5646'dır.

Çizelge 8.36: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(27554,03, 38733,79, 43219,19)
26	(31498,76, 37189,07, 39619,81)
27	(29482,52, 37557,46, 40908,31)
28	(28635,40, 37384,57, 41208,39)
29	(27852,10, 37408,67, 41131,73)
30	(31792,64, 35916,41, 37845,64)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,5, 0,25

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.37’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,1417’dir.

Çizelge 8.37: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(36310,34, 38319,77, 39833,06)
26	(36918,76, 38121,85, 38731,13)
27	(36512,65, 37874,17, 38773,53)
28	(36056,52, 37697,90, 38688,65)
29	(35649,97, 37436,74, 38790,30)
30	(36390,87, 37243,66, 37489,23)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,5, 0,25

Ara yük bloğunda veri boyutu yine 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.34 ile aynı olup yeniden Çizelge 8.38’de verilmiştir. OMYH % 0,9682’dir.

Çizelge 8.38: Ara yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).

Gün	TÜKETİM (MWh)
25	(29463,73, 32110,28, 36620,64)
26	(29375,35, 32095,48, 36546,08)
27	(29448,39, 31984,09, 36493,01)
28	(29334,56, 31954,01, 36435,97)
29	(29243,32, 31930,26, 36387,21)
30	(29241,54, 31863,60, 36300,71)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Temel yük bloğunda veri boyutu 14 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.39’da verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan OMYH değeri ise % 2,2671’dir.

Çizelge 8.39: Temel yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=14$).

Gün	TÜKETİM (MWh)
25	(29345,02, 38591,99, 42100,98)
26	(29276,36, 38170,04, 41601,88)
27	(29231,67, 37886,92, 41302,27)
28	(29153,29, 37688, 41056,78)
29	(28877,56, 37611,09, 40822,50)
30	(28848,08, 36991,30, 40155,68)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

Zirve yük bloğunda veri boyutu 4 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.40’ta verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için kullanılan parametreler modelde sabit değer olup; tablonun son satırında verilmiştir. Altı güne ait tahmin sonuçları gerçekleşen sonuçlarla kıyaslanarak modelin performansını değerlendirmek için kullanılan OMYH değeri ise % 1,5199’dur.

Çizelge 8.40: Zirve yük bloğuna ait yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=4$).

Gün	TÜKETİM (MWh)
25	(36595,64, 38358,03, 39592,11)
26	(37183,94, 38131,40, 38616,81)
27	(36213, 38004,03, 39054,67)
28	(36259,25, 37691,93, 38823,50)
29	(36816,69, 37569,61, 37639,22)
30	(34807,35, 37386,25, 39323,61)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5, 0,5, 0,5), 0,25, 0,50, 0,25

8.6 GA-Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yükü Tahmini

İlk 21 günlük elektrik tüketim verisi kullanılarak dokuz günlük elektrik yükü GA-yuvarlanma mekanizmalı ÜBGM(1,1) modeli ile tahmin edilmiştir. Denklem (8.1) amaç fonksiyonunu ifade etmektedir.

Çizelge 8.41: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).

Gün	TÜKETİM (MWh)
22	(29898,9715, 32470,2683, 37008,5466)
23	(29137,8999, 31990,783, 36545,3631)
24	(28801,92, 31757,8441, 36375,6004)
25	(29208,7292, 31350,5898, 35635,0911)
26	(28486,7159, 31376,0683, 35864,2768)
27	(28419,2431, 31282,5963, 35794,5203)
28	(28574,0541, 31055,4512, 35446,0137)
29	(28626,9978, 30809,5829, 34996,7952)
30	(27830,8547, 31260,6398, 35934,4425)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,9999, 0,9999, 0,9999), 0,42, 0,42, 0,16

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.41’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,9999, 0,9999, 0,9999)$, $\alpha = 0,42$, $\beta = 0,42$ ve $\gamma = 0,16$ ’dır. Dokuz güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,7234’tür.

Çizelge 8.42: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(31342,03, 39835,87, 42349,17)
23	(30160,24, 39038,69, 42883,19)
24	(29605,33, 38578,54, 42517,67)
25	(28311,55, 38531,97, 41977,32)
26	(30877,08, 38036,34, 40327,2)
27	(28179,3, 37868,27, 42771,77)
28	(28664,43, 37692,59, 40623,38)
29	(28378,57, 37454,05, 40347,22)
30	(30347,01, 37325,8, 40515,05)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,5590, 0,8146, 0,8195), 0,005, 0,985, 0,010

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.42’de verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,5590, 0,8146, 0,8195)$, $\alpha = 0,005$, $\beta = 0,985$ ve $\gamma = 0,010$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 2,4819’dur.

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.43’te verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,9999, 0,9999, 0,9999)$, $\alpha = 0,35$, $\beta = 0,37$ ve $\gamma = 0,28$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,6924’tür.

Çizelge 8.43: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(37390,85, 39016,32, 40030,87)
23	(37390,68, 38745,98, 39629,93)
24	(37259,39, 38592,88, 39294,59)
25	(36761,35, 37851,8, 38543,52)
26	(36387,19, 37975,76, 38892,56)
27	(36619,72, 37872,27, 38597,61)
28	(36635,55, 37798,57, 38458,38)
29	(36891,37, 38113,87, 38929,74)
30	(37162,33, 38846,11, 39783,06)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,9999, 0,9999, 0,9999), 0,35, 0,37, 0,28

Çizelge 8.44: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k*=6).

Gün	TÜKETİM (MWh)
22	(30350,99, 32980,78, 37547,23)
23	(29840,02, 32569,68, 37209,08)
24	(29383,06, 32173,96, 36730,30)
25	(29141,70, 32050,13, 36664,13)
26	(29739,93, 32085,10, 36510,54)
27	(29082,79, 31793,11, 36263,57)
28	(28922,51, 31724,24, 36301,07)
29	(28955,72, 31676,99, 36140,94)
30	(28982,08, 31589,61, 36057,75)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,998, 0,999, 0,999), 0, 1, 0

Ara yük bloğunda veri boyutu 6 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.44'te verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini

için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,998, 0,999, 0,999)$, $\alpha = 0, \beta = 1$ ve $\gamma = 0$ 'dır. Dokuz güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,1663'tür.

Çizelge 8.45: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=10$).

Gün	TÜKETİM (MWh)
22	(30547,35, 39244,57, 42643,21)
23	(30404,89, 39071,97, 42531,44)
24	(30298,87, 39048,15, 42501,16)
25	(30050,50, 39344,18, 42624,42)
26	(29923,24, 38429,73, 41669,20)
27	(29335,58, 38247,93, 41707,23)
28	(29011,95, 37640,82, 41146,44)
29	(28822,26, 37453,18, 41097,29)
30	(28667,99, 37783,72, 41353,07)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,143722, 0,14531, 0,17074), 0,46, 0,50, 0,04

Temel yük bloğunda veri boyutu 10 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.45'te verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,143722, 0,14531, 0,17074)$, $\alpha = 0,46$, $\beta = 0,50$ ve $\gamma = 0,04$ 'tür. Dokuz güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 2,1902'dir.

Zirve yük bloğunda veri boyutu yine 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.46'da verilmiş olup; tabloda Çizelge 8.41 ile aynı sonuçlar yer almaktadır. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,9999, 0,9999, 0,9999)$, $\alpha = 0,35$, $\beta = 0,37$ ve $\gamma = 0,28$ 'dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,6924'tür.

Çizelge 8.46: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).

Gün	TÜKETİM (MWh)
22	(37390,85, 39016,32, 40030,87)
23	(37390,68, 38745,98, 39629,93)
24	(37259,39, 38592,88, 39294,59)
25	(36761,35, 37851,8, 38543,52)
26	(36387,19, 37975,76, 38892,56)
27	(36619,72, 37872,27, 38597,61)
28	(36635,55, 37798,57, 38458,38)
29	(36891,37, 38113,87, 38929,74)
30	(37162,33, 38846,11, 39783,06)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,9999, 0,9999, 0,9999), 0,35, 0,37, 0,28

30 günlük elektrik yükü verisini %80 eğitim verisi ve % 20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak sonraki altı günlük elektrik yükü tahmin edilmiştir. Test veri boyutu değiştiğinden, denklem (8.2) amaç fonksiyonunu ifade etmektedir.

Çizelge 8.47: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).

Gün	TÜKETİM (MWh)
25	(29455,16, 32101,30, 36611,88)
26	(29317,78, 32031,39, 36474,40)
27	(29432,28, 31971,08, 36478,39)
28	(29289,10, 31902,62, 36379,72)
29	(29158,12, 31837,27, 36284,14)
30	(29153,46, 31769,97, 36195,70)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,4278, 0,4436, 0,4679), 0,02, 0,96, 0,02

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.47’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,4278, 0,4436, 0,4679)$, $\alpha = 0,02$, $\beta = 0,96$ ve $\gamma = 0,02$ ’dir. Altı güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9249’dur.

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.48’de verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,000003, 0,999996, 0,999996)$, $\alpha = 0,002$, $\beta = 0,998$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 2,8995’dir.

Çizelge 8.48: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(26923,74, 37729,32, 42260,24)
26	(30871,10, 37464,41, 39652,63)
27	(29662,59, 37336,26, 40853,50)
28	(28383,73, 37161,27, 40990,67)
29	(27485,59, 37059,90, 40736,99)
30	(31240,94, 36965,43, 38546,11)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,000003, 0,999996, 0,999996), 0,002, 0,998, 0

Çizelge 8.49: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(36332,94, 38398,33, 39973,27)
26	(37121,08, 38253,42, 38775,77)
27	(36711,12, 38127,76, 39090,03)
28	(36334,25, 38015,94, 39020,2)
29	(36080,24, 37914,07, 39331,79)
30	(37124,09, 37835,72, 37898,26)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,811, 0,815, 0,815), 0,036, 0,928, 0,036

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.49’da verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,811, 0,815, 0,815)$, $\alpha = 0,036$, $\beta = 0,928$ ve $\gamma = 0,036$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,3405’dir.

Çizelge 8.50: Ara yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).

Gün	TÜKETİM (MWh)
25	(29455,16, 32101,30, 36611,88)
26	(29317,78, 32031,39, 36474,40)
27	(29432,28, 31971,08, 36478,39)
28	(29289,10, 31902,62, 36379,72)
29	(29158,12, 31837,27, 36284,14)
30	(29153,46, 31769,97, 36195,70)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,4278, 0,4436, 0,4679), 0,02, 0,96, 0,02

Ara yük bloğunda veri boyutu 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.50’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,4278, 0,4436, 0,4679)$, $\alpha = 0,02$, $\beta = 0,96$ ve $\gamma = 0,02$ ’dir. Altı güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9249’dur.

Temel yük bloğunda veri boyutu 4 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.51’de verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,00014, 0,99984, 0,99886)$, $\alpha = 0,0002$, $\beta = 0,0007$ ve $\gamma = 0,0001$ ’dir. Altı güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,9153’tür.

Çizelge 8.51: Temel yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=4$).

Gün	TÜKETİM (MWh)
25	(29231,82, 37748,40, 41097,12)
26	(30892,19, 37644,48, 40261,59)
27	(29382,20, 37506,66, 41538,13)
28	(29283,77, 37452,28, 39703,8)
29	(31099,58, 37389,76, 40831,33)
30	(27958,60, 37362,82, 41450,43)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,00014, 0,99984, 0,99886), 0,0002, 0,9997, 0,0001

Zirve yük bloğunda veri boyutu 6 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.52’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,999, 1, 1)$, $\alpha = 0,26$, $\beta = 0,70$ ve $\gamma = 0,04$ ’tür. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,3174’tür.

Çizelge 8.52: Zirve yük bloğuna ait GA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).

Gün	TÜKETİM (MWh)
25	(36009,38, 38127,16, 39732,96)
26	(36542,97, 38015,69, 38943,37)
27	(36432,06, 37764,91, 38528,54)
28	(36164,15, 37582,17, 38516,38)
29	(35783,27, 37503,93, 38597,23)
30	(35579,78, 37491,12, 38936,50)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,999, 1, 1), 0,26, 0,70, 0,04

8.7 PSO-Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yükü Tahmini

İlk 21 günlük elektrik tüketim verisi kullanılarak dokuz günlük elektrik yükü PSO-yuvarlanma mekanizmalı ÜBGM(1,1) modeli ile tahmin edilmiştir. Denklem (8.1) amaç fonksiyonunu ifade etmektedir.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.53'te verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,499995$, $\beta = 0,499996$ ve $\gamma = 0,000009$ 'dur. Dokuz güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,7152 'dir.

Çizelge 8.53: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(29865,90, 32434,33, 36967,59)
23	(29139,16, 31991,79, 36546,38)
24	(28837,81, 31797,56, 36421,15)
25	(29135,61, 31270,67, 35543,75)
26	(28504,21, 31393,70, 35884,03)
27	(28439,71, 31304,80, 35819,80)
28	(28523, 30997,23, 35379,28)
29	(28562,70, 30738,77, 34915,76)
30	(27917, 31353,12, 36039,52)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1, 1, 1), 0,499995, 0,499996, 0,000009

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.54'te verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,547324, 0,831824, 0,831828)$, $\alpha = 0,008$, $\beta = 0,992$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 2,4777'dir.

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.55'te verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,499996$, $\beta = 0,500004$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,6258'dir.

Çizelge 8.54: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(31317,10, 39816,43, 42322,71)
23	(30148,81, 39034,16,42880,10)
24	(29599,70, 38578,58, 42515,39)
25	(28313,73, 38539,32, 41981,33)
26	(30841,55, 38026,24, 40307,60)
27	(28207,30, 37899,01, 42817,78)
28	(28665,95, 37710,16, 40622,85)
29	(28383,87, 37478,91, 40373,04)
30	(30337,67, 37350,66, 40538,78)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,547324, 0,831824, 0,831828), 0,008, 0,992, 0

Çizelge 8.55: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(37524,40, 39864,44, 41655,88)
23	(36990,42, 38714,52, 39757,03)
24	(36510,88, 38303,75, 39646,38)
25	(36310,26, 38373,74, 39865,30)
26	(35862,30, 37978,25, 39509,74)
27	(36123,72, 37466,06, 38202,88)
28	(35565,26, 37778,82, 39615,54)
29	(35512,04, 37499,66, 38763,70)
30	(35592,40, 37300,39, 38501,33)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1, 1, 1), 0,499996, 0,500004, 0

Ara yük bloğunda veri boyutu 6 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.56’da verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, α

$=0,499998$, $\beta = 0,5000002$ ve $\gamma = 0$ 'dır. Dokuz güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,0633'tür.

Çizelge 8.56: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).

Gün	TÜKETİM (MWh)
22	(30242,10, 32862, 37412,03)
23	(29778,75, 32501,78, 37131,26)
24	(29366,35, 32155,35, 36709,24)
25	(29223,93, 32140,65, 36767,81)
26	(29490,34, 31812,31, 36199,20)
27	(29041,18, 31744,89, 36208,19)
28	(28928,60, 31729,82, 36307,14)
29	(28918,04, 31635,39, 36093,65)
30	(28882,10, 31479,05, 35931,35)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1, 1, 1), 0,499998, 0,5000002, 0

Çizelge 8.57: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini($k^*=10$)

Gün	TÜKETİM (MWh)
22	(30513,02, 39199,40, 42588,93)
23	(30364,01, 39018,89, 42469,91)
24	(30251,89, 38987,34, 42432,41)
25	(30014,97, 39298,37, 42572,56)
26	(29843,95, 38326,67, 41553,06)
27	(29279,73, 38175,13, 41620,01)
28	(28943,41, 37551,58, 41040,44)
29	(28755,73, 37366,65, 40994,80)
30	(28621,99, 37724,87, 41282,28)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,154928, 0,15497, 0,154981), 0,499975, 0,499977, 0,000048

Temel yük bloğunda veri boyutu 10 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.57'de verilmiştir. Temel yük bloğuna ait elektrik talebinin

tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,154928, 0,15497, 0,154981)$, $\alpha = 0,499975$, $\beta = 0,499977$, ve $\gamma = 0,000048$ 'dir. Dokuz güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 2,1314'tür.

Zirve yük bloğunda veri boyutu yine 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.58'de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,499996$, $\beta = 0,500004$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,6258'dir.

Çizelge 8.58: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).

Gün	TÜKETİM (MWh)
22	(37524,40, 39864,44, 41655,88)
23	(36990,42, 38714,52, 39757,03)
24	(36510,88, 38303,75, 39646,38)
25	(36310,26, 38373,74, 39865,30)
26	(35862,30, 37978,25, 39509,74)
27	(36123,72, 37466,06, 38202,88)
28	(35565,26, 37778,82, 39615,54)
29	(35512,04, 37499,66, 38763,70)
30	(35592,40, 37300,39, 38501,33)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1, 1, 1), 0,499996, 0,500004, 0

30 günlük elektrik yükü verisini %80 eğitim verisi ve % 20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak sonraki altı günlük elektrik yükü tahmin edilmiştir. Test veri boyutu değiştiğinden, denklem (8.2) amaç fonksiyonunu ifade etmektedir.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.59'da verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,07906, 0,07929, 0,99628)$, $\alpha = 0,00001$, $\beta = 0,50$ ve $\gamma = 0,49999$ 'dur. Altı güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin

performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9175'dir.

Çizelge 8.59: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(29431,39, 32071,88, 36638,75)
26	(29342,53, 32049,37, 36514,39)
27	(29408,11, 31960,95, 36507,84)
28	(29293,81, 31895,90, 36437,37)
29	(29168,47, 31837,16, 36377,03)
30	(29183,74, 31807,87, 36275,36)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,07906, 0,07929, 0,99628), 0,00001, 0,50, 0,49999

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.60'da verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0, 1, 1)$, $\alpha = 0,021$, $\beta = 0,907$ ve $\gamma = 0,072$ 'dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 2,8995'dir.

Çizelge 8.60: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(26934,60, 37744,24, 42276,88)
26	(30907,56, 37504, 39694,21)
27	(29657,48, 37319,94, 40837,63)
28	(28368,80, 37148,84, 40976,14)
29	(27494,58, 37077,11, 40757,15)
30	(31271,56, 36995,59, 38576,33)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1,1), 0,021, 0,907, 0,072

Çizelge 8.61: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(35845,62, 37946,49, 39538,27)
26	(37013,50, 38335,76, 38814,02)
27	(36573,98, 37955,92, 38953,99)
28	(36091,20, 37854,20, 38851,91)
29	(35632,36, 37558,17, 38997,59)
30	(37162,32, 38225,30, 38185,07)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,47,1,1), 0,000006, 0,499999, 0,499995

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.61’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,47, 1, 1)$, $\alpha = 0,000006$, $\beta = 0,499999$ ve $\gamma = 0,499995$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,1417’dir.

Çizelge 8.62: Ara yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k*=5).

Gün	TÜKETİM (MWh)
25	(29431,39, 32071,88, 36638,75)
26	(29342,53, 32049,37, 36514,39)
27	(29408,11, 31960,95, 36507,84)
28	(29293,81, 31895,90, 36437,37)
29	(29168,47, 31837,16, 36377,03)
30	(29183,74, 31807,87, 36275,36)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,07906, 0,07929, 0,99628), 0,00001, 0,50, 0,49999

Ara yük bloğunda veri boyutu 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.62’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,07906, 0,07929, 0,99628)$, $\alpha = 0,00001$, $\beta = 0,50$ ve $\gamma = 0,49999$ ’dur. Altı güne ait tahmin

sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9175'dir.

Çizelge 8.63: Temel yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini($k^*=4$)

Gün	TÜKETİM (MWh)
25	(29448,10, 38031,24, 41406,90)
26	(30885,08, 37480,11, 40081,17)
27	(29335,78, 37639,92, 41678,72)
28	(29429,10, 37551,16, 39809,63)
29	(30916,36, 36931,35, 40325,62)
30	(27737,04, 37732,37, 41871,52)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1,1), 0,1536, 0,8111, 0,0353

Temel yük bloğunda veri boyutu 4 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.63'te verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0, 1, 1)$, $\alpha = 0,1536$, $\beta = 0,8111$ ve $\gamma = 0, 0,0353$ 'tür. Altı güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,9153'tür.

Çizelge 8.64: Zirve yük bloğuna ait PSO- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).

Gün	TÜKETİM (MWh)
25	(36262,99, 38395,34, 40012,48)
26	(36653,27, 38125,64, 39051,08)
27	(36519,02, 37856,03, 38622,66)
28	(36291,43, 37715,11, 38653,24)
29	(36008,10, 37738,19, 38837,66)
30	(35875,11, 37800,16, 39255,55)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1 1,1), 0,50, 0,50, 0

Zirve yük bloğunda veri boyutu 6 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.64'te verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1, 1, 1)$, $\alpha = 0,50$, $\beta = 0,50$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,1274'tür.

8.8 GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) ile Elektrik Yükü Tahmini

İlk 21 günlük elektrik tüketim verisi kullanılarak dokuz günlük elektrik yükü PSO-yuvarlanma mekanizmalı ÜBGM(1,1) modeli ile tahmin edilmiştir. Denklem (8.1) amaç fonksiyonunu ifade etmektedir.

Çizelge 8.65: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(29865,89, 32434,32, 36967,59)
23	(29139,16, 31991,79, 36546,38)
24	(28837,81, 31797,56, 36421,16)
25	(29135,61, 31270,67, 35543,74)
26	(28504,22, 31393,70, 35884,04)
27	(28439,71, 31304,81, 35819,80)
28	(28522,99, 30997,23, 35379,28)
29	(28562,70, 30738,77, 34915,75)
30	(27917,01, 31353,13, 36039,52)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1,1,1), 0,5, 0,5, 0

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.65'te verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,50$, $\beta = 0,50$ ve $\gamma = 0$ 'dır. Dokuz güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,7152'dir.

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.66'da verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,543146, 0,832804,$

0,832819), $\alpha = 0,008771$, $\beta = 0,991229$ ve $\gamma = 0$ 'dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 2,4777'dir.

Çizelge 8.66: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(31313,65, 39814,82, 42320,66)
23	(30146,78, 39032,80, 42878,93)
24	(29597,50, 38577,08, 42513,67)
25	(28314,04, 38539,85, 41981,72)
26	(30831,98, 38023,13, 40303,88)
27	(28210,91, 37899,13, 42818,99)
28	(28662,27, 37709,92, 40621,27)
29	(28381,63, 37478,97, 40373,30)
30	(30328,46, 37348,50, 40536,51)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,543146, 0,832804, 0,832819), 0,008771, 0,991229, 0

Çizelge 8.67: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
22	(37521,84, 39861,73, 41653,05)
23	(36990,50, 38714,64, 39757,19)
24	(36509,87, 38302,68, 39645,27)
25	(36308,21, 38371,59, 39863,09)
26	(35859,93, 37975,76, 39507,17)
27	(36124,58, 37466,99, 38203,88)
28	(35561,68, 37775,05, 39611,63)
29	(35510,32, 37497,90, 38761,95)
30	(35591,23, 37299,19, 38500,11)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,543146, 0,832804, 0,832819), 0,498464 0,498464, 0,003072

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.67’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,543146, 0,832804, 0,832819)$, $\alpha = 0,498464$, $\beta = 0,498464$, ve $\gamma = 0,003072$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,6256’dır.

Çizelge 8.68: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).

Gün	TÜKETİM (MWh)
22	(30242,10, 32862, 37412,03)
23	(29778,75, 32501,78, 37131,26)
24	(29366,35, 32155,35, 36709,24)
25	(29223,93, 32140,65, 36767,81)
26	(29490,34, 31812,31, 36199,20)
27	(29041,18, 31744,89, 36208,19)
28	(28928,60, 31729,82, 36307,14)
29	(28918,04, 31635,39, 36093,65)
30	(28882,10, 31479,05, 35931,35)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1, 1, 1), 0,5, 0,5, 0

Ara yük bloğunda veri boyutu 6 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.68’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1,1,1)$, $\alpha = 0,5$, $\beta = 0,5$ ve $\gamma = 0$ ’dır. Dokuz güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 1,0633’tür.

Temel yük bloğunda veri boyutu 10 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.69’da verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,1556771, 0,1556892, 0,155705)$, $\alpha = 0,499999$, $\beta = 0,5000001$, ve $\gamma = 0$ ’dır. Dokuz güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 2,1314’tür.

Çizelge 8.69: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=10$).

Gün	TÜKETİM (MWh)
22	(30513,17, 39199,54, 42589,06)
23	(30364,20, 39019,11, 42470,15)
24	(30252,13, 38987,64, 42432,74)
25	(30015,24, 39298,79, 42572,99)
26	(29844,40, 38327,18, 41553,61)
27	(29280,30, 38175,91, 41620,88)
28	(28944,19, 37552,57, 41041,55)
29	(28756,68, 37367,88, 40996,17)
30	(28623,08, 37726,34, 41283,88)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1556771, 0,1556892, 0,155705), 0,4999999, 0,5000001, 0

Çizelge 8.70: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k=5$).

Gün	TÜKETİM (MWh)
22	(37521,84, 39861,73, 41653,05)
23	(36990,50, 38714,64, 39757,19)
24	(36509,87, 38302,68, 39645,27)
25	(36308,21, 38371,59, 39863,09)
26	(35859,93, 37975,76, 39507,17)
27	(36124,58, 37466,99, 38203,88)
28	(35561,68, 37775,05, 39611,63)
29	(35510,32, 37497,90, 38761,95)
30	(35591,23, 37299,19, 38500,11)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,543146, 0,832804, 0,832819), 0,498464 0,498464, 0,003072

Zirve yük bloğunda veri boyutu yine 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.70’de verilmiştir ve tabloda Çizelge 8.67 ile aynı sonuçlar yer almaktadır. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,543146, 0,832804, 0,832819)$, $\alpha = 0,498464$, $\beta = 0,498464$ ve $\gamma = 0,003072$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,1274’tür.

30 günlük elektrik yükü verisini %80 eğitim verisi ve % 20 test verisi olarak ele aldığımızda tahmin sonuçları çizelgelerde verilmiştir. İlk 24 günlük elektrik tüketim verisi kullanılarak altı günlük elektrik yükü tahmin edilmiştir. Amaç fonksiyonu denklem (8.2)’deki gibi hesaplanmaktadır.

Ara yük bloğu için elde edilen tahmin sonuçları Çizelge 8.71’de verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,0774, 0,0774, 1)$, $\alpha = 0$, $\beta = 0,50$ ve $\gamma = 0,50$ ’dir. Altı güne ait tahmin sonuçları, gerçek veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9175’dir.

Çizelge 8.71: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(29431,31, 32071,77, 36639)
26	(29342,59, 32049,38, 36514,48)
27	(29408,04, 31960,95, 36508,09)
28	(29293,88, 31895,91, 36437,75)
29	(29168,54, 31837,15, 36377,57)
30	(29183,94, 31808,1, 36275,74)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,0774, 0,0774, 1), 0, 0,50, 0,50

Temel yük bloğu için elde edilen tahmin sonuçları Çizelge 8.72’de verilmiştir. Optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,1,1)$, $\alpha = 0,021$, $\beta = 0,907$ ve $\gamma = 0,072$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 2,8914’tür.

Çizelge 8.72: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(26934,60, 37744,24, 42276,88)
26	(30907,56, 37504, 39694,21)
27	(29657,48, 37319,94, 40837,63)
28	(28368,80, 37148,84, 40976,14)
29	(27494,58, 37077,11, 40757,15)
30	(31271,56, 36995,59, 38576,33)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1,1), 0,021, 0,907, 0,072

Zirve yük bloğu için elde edilen tahmin sonuçları Çizelge 8.73’de verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,46929,1,1)$, $\alpha = 0$, $\beta = 0,5$ ve $\gamma = 0,5$ ’dir. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,1417’dir.

Çizelge 8.73: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini (k=5).

Gün	TÜKETİM (MWh)
25	(35845,62, 37946,49, 39538,27)
26	(37013,50, 38335,76, 38814,02)
27	(36573,98, 37955,92, 38953,99)
28	(36091,20, 37854,20, 38851,91)
29	(35632,36, 37558,17, 38997,59)
30	(37162,32, 38225,30, 38185,07)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,46929,1,1), 0, 0,5, 0,5

Ara yük bloğunda veri boyutu 5 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.74’te verilmiştir. Ara yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0,0774, 0,0774, 1)$, $\alpha = 0$, $\beta = 0,50$ ve $\gamma = 0,50$ ’dir. Altı güne ait tahmin sonuçları, gerçek veri ile

kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 0,9175'dir.

Çizelge 8.74: Ara yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=5$).

Gün	TÜKETİM (MWh)
25	(29431,31, 32071,77, 36639)
26	(29342,59, 32049,38, 36514,48)
27	(29408,04, 31960,95, 36508,09)
28	(29293,88, 31895,91, 36437,75)
29	(29168,54, 31837,15, 36377,57)
30	(29183,94, 31808,1, 36275,74)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,0774, 0,0774, 1), 0, 0, 0,50, 0,50

Temel yük bloğunda veri boyutu 4 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.75'te verilmiştir. Temel yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (0, 1, 1)$, $\alpha = 0,1536$, $\beta = 0,8111$ ve $\gamma = 0, 0,0353$ 'tür. Altı güne ait tahmin sonuçları, gerçekleşen veri ile kıyaslanarak modelin performansını değerlendirmek için kullanılan hata ölçütü, OMYH değeri ise % 2,8914'tür.

Çizelge 8.75: Temel yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=4$).

Gün	TÜKETİM (MWh)
25	(29448,10, 38031,24, 41406,90)
26	(30885,08, 37480,11, 40081,17)
27	(29335,78, 37639,92, 41678,72)
28	(29429,10, 37551,16, 39809,63)
29	(30916,36, 36931,35, 40325,62)
30	(27737,04, 37732,37, 41871,52)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(0,1,1), 0,1536, 0,8111, 0,0353

Zirve yük bloğunda veri boyutu 6 iken en iyi tahmin sonucu elde edilmektedir. Tahmin sonuçları Çizelge 8.76’da verilmiştir. Zirve yük bloğuna ait elektrik talebinin tahmini için optimum parametreler tablonun son satırında verilmiş olup, $\tilde{\lambda} = (1, 1, 1)$, $\alpha = 0,50$, $\beta = 0,50$ ve $\gamma = 0$ ’dır. Aynı zamanda amaç fonksiyonu olan, OMYH değeri ise % 1,1274’tür.

Çizelge 8.76: Zirve yük bloğuna ait GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) ile elektrik talebi tahmini ($k^*=6$).

Gün	TÜKETİM (MWh)
25	(36262,99, 38395,34, 40012,48)
26	(36653,27, 38125,64, 39051,08)
27	(36519,02, 37856,03, 38622,66)
28	(36291,43, 37715,11, 38653,24)
29	(36008,10, 37738,19, 38837,66)
30	(35875,11, 37800,16, 39255,55)
$\tilde{\lambda}, \alpha, \beta, \gamma$	(1 1,1), 0,50, 0,50, 0

8.9 Sonuçların Değerlendirilmesi

Tahmin modellerinin performanlarını ölçmek için kullandığımız OMYH hata ölçütü değerleri 9 günlük test verisi için Çizelge 8.77’de ve 6 günlük test verisi için Çizelge 8.78’de bir araya getirilmiştir.

Çizelge 8.77’ye göre en düşük hata oranı tüm yük blokları için, veri boyutu optimum iken, GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) modeli ile elde edilmiştir. Diğer optimizasyon modelleri arasında da en iyi sonuç GIOA ile elde edilmiştir. Yük blokları için OMYH değerleri sırasıyla, 1,0632, 2,1314 ve 1,6256’dır.

Çizelge 8.78 test verisi oranı %20 iken elde edilen tahmin sonuçlarına göre hata oranlarının özetini vermekte olup, yine en düşük hata oranını, yük bloğu sırasıyla, 0,9175, 0,91529 ve 1,1274 ile GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) modeli vermektedir.

Çizelge 8.77: Dokuz adet test verisi için OMYH değerleri.

% 30 test verisi	OMYH		
	Ara Yük Bloğu	Temel Yük Bloğu	Zirve Yük Bloğu
ÜBGM(1,1)	6,7961	9,3928	9,7529
GA-ÜBGM(1,1)	6,4000	8,0898	9,5946
PSO-ÜBGM(1,1)	6,3910	7,3269	9,593127
GIOA-ÜBGM(1,1)	6,3910	7,3269	9,593121
Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	6,7004	4,8154	7,3030
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	1,7234	2,4819	1,6924
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	1,7151987	2,47774	1,6258
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	1,7151982	2,47773	1,6256
Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	1,6344	2,5831	2,3247
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	1,1663	2,1902	1,6232
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	1,0632941	2,131438	1,6258
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	1,0632938	2,131431	1,6256

Çizelge 8.78: Altı adet test verisi için OMYH değerleri.

% 20 test verisi	OMYH		
	Ara Yük Bloğu	Temel Yük Bloğu	Zirve Yük Bloğu
ÜBGM(1,1)	4,4779	6,5111	6,3346
GA-ÜBGM(1,1)	4,3792	6,1666	5,8069
PSO-ÜBGM(1,1)	4,3336541	5,8948	5,7489
GIOA-ÜBGM(1,1)	4,3336539	5,8948	5,7489
Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	0,9682	3,5647	1,5220
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	0,9249	2,8995	1,3405
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	0,917542	2,891381	1,14170
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	0,917536	2,891379	1,14169
Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	3,1482	3,6931	1,5199
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	0,9249	1,9913	1,3174
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	0,917543	1,91529	1,1274
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	0,917536	1,91529	1,1274

30'ar koşumda tüm yük bloklarına ait, tüm optimizasyon modelleri ile elde edilen sonuçların süresini veren özet tablolar Çizelge 8.79 - 8.84'te gösterilmektedir.

Çizelge 8.79: Ara yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (%30) test verisi).

Modeller	Ara Yük Bloğu Süreler		
	En küçük süre	Ortalama süre	Std. Sapma
GA-ÜBGM(1,1)	7,953	8,066	0,067
PSO-ÜBGM(1,1)	2,202	2,315	0,142
GIOA-ÜBGM(1,1)	2,605	2,767	0,101
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	13,993	15,435	0,292
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,024	4,130	0,316
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,534	4,780	0,204
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	10,377	12,900	0,478
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	3,325	3,370	0,027
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	4,109	4,646	0,196

Çizelge 8.79'da belirtildiği gibi % 30 test verisi ile yapılan ara yük bloğu tahminlerinde kullanılan Genetik Algoritma ile elde edilen sonuçlar en uzun süreye sahiptir. Buna karşılık, Güve- Işık Optimizasyonu Algoritması ile elde edilen sonuçların en düşük süreleri, ortalamaları ve standart sapmaları Parçacık Sürü Optimizasyonu ile elde edilen sonuçların işlem sürelerine yakın değerler içermektedir.

Çizelge 8.80'de ise, % 20 test verisi ile yapılan tahminlerde kullanılan Genetik Algoritma ile elde edilen sonuçlar en uzun süreye sahiptir. Güve – Işık Optimizasyonu

Algoritması ile elde edilen sonuçlardaki süreler ise yine Parçacık Sürü Optimizasyonu ile elde edilen sonuçların işlem süreleri ile yakın değerleri vermektedir.

Çizelge 8.80: Ara yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 20 test verisi).

% 20 test verisi	Ara Yük Bloğu Süreler		
Modeller	En küçük süre	Ortalama süre	Std. Sapma
GA-ÜBGM(1,1)	7,953218	8,065564	0,067109
PSO-ÜBGM(1,1)	2,102618	2,135665	0,031895
GIOA-ÜBGM(1,1)	2,643129	2,803089	0,078952
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	13,08606	13,22499	0,10988
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,291576	4,395893	0,268545
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	3,510388	4,097993	0,316524
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	13,08606	13,22499	0,10988
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	4,291576	4,395893	0,268545
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	3,510388	4,097993	0,316524

Çizelge 8.81’de belirtildiği gibi % 30 test verisi ile yapılan temel yük bloğu tahminlerinde kullanılan Genetik Algoritma ile elde edilen sonuçlar en uzun işlem süresine sahiptir. Buna karşılık, Güve- Işık Optimizasyonu Algoritması ile elde edilen sonuçların en düşük işlem süreleri, ortalamaları ve standart sapmaları Parçacık Sürü Optimizasyonu ile elde edilen sonuçların işlem sürelerine yakın değerler içermektedir.

Çizelge 8.81: Temel yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 30 test verisi).

% 30 test verisi	Temel Yük Bloğu Süreler		
	En küçük süre	Ortalama süre	Std. Sapma
GA-ÜBGM(1,1)	7,929408	8,064001	0,165503
PSO-ÜBGM(1,1)	2,272483	2,326937	0,046066
GIOA-ÜBGM(1,1)	2,639415	2,753563	0,067613
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	13,17216	13,48319	0,242695
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	5,552337	5,613684	0,077515
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	3,677447	4,160088	0,311062
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	17,81466	18,00199	0,148547
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	4,878176	4,924576	0,058572
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	2,585489	3,034095	0,282278

Çizelge 8.82’de ise, % 20 test verisi ile yapılan tahminlerde kullanılan Genetik Algoritma ile elde edilen sonuçlar en uzun süreye sahiptir. Güve – Işık Optimizasyonu Algoritması ile elde edilen sonuçlardaki süreler ise yine Parçacık Sürü Optimizasyonu ile elde edilen sonuçların süreleri ile yakın değerleri vermektedir.

Çizelge 8.82: Temel yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 20 test verisi).

% 20 test verisi	Temel Yük Bloğu Süreler		
	En küçük süre	Ortalama süre	Std. Sapma
GA-ÜBGM(1,1)	8,555061	8,704496	0,066172
PSO-ÜBGM(1,1)	2,236288	2,288068	0,040536
GIOA-ÜBGM(1,1)	2,746393	2,832316	0,060581
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	13,82458	14,04836	0,087424
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	6,66479	6,798776	0,198416
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,690121	4,920118	0,10405
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	10,78243	13,13223	0,450139
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	4,901189	4,941473	0,03693
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	4,418518	5,017769	0,236891

Zirve yük bloğuna ait % 30 test verisi için GA, PSO ve GIOA ile elde edilen sonuçlara ait işlem süreleri Çizelge 8.83'te gösterilmiştir. Genetik Algoritma ile elde edilen sonuçlar en uzun işlem süresine sahiptir. Buna karşılık, Güve- Işık Optimizasyonu Algoritması ile elde edilen sonuçların en düşük işlem süreleri, ortalamaları ve standart sapmaları Parçacık Sürü Optimizasyonu ile elde edilen sonuçların işlem sürelerine yakın değerler içermektedir.

Çizelge 8.84'te ise, % 20 test verisi ile yapılan tahminlerde kullanılan Genetik Algoritma ile elde edilen sonuçlar en uzun işlem süresine sahiptir. Güve – Işık Optimizasyonu Algoritması ile elde edilen sonuçlardaki işlem süreleri ise yine

Parçacık Sürü Optimizasyonu ile elde edilen sonuçların süreleri ile yakın değerleri vermektedir.

Çizelge 8.83: Zirve yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (%30 test verisi).

% 30 test verisi		Zirve Yük Bloğu Süreler		
Modeller	En küçük süre	Ortalama süre	Std. Sapma	
GA-ÜBGM(1,1)	9,22308	9,410245	0,194024	
PSO-ÜBGM(1,1)	2,18023	2,228848	0,039953	
GIOA-ÜBGM(1,1)	1,719702	1,921128	0,101588	
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	14,14358	14,34989	0,533755	
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	2,723672	2,753812	0,036696	
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,193613	4,628179	0,207513	
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	14,14358	14,34989	0,533755	
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	2,723672	2,753812	0,036696	
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	4,193613	4,628179	0,207513	


Çizelge 8.84: Zirve yük bloğu için GA, PSO ve GIOA ile elde edilen sonuçlara ait süreler (% 20 test verisi).

% 20 test verisi	Zirve Yük Bloğu Süreler		
	En küçük süre	Ortalama süre	Std. Sapma
GA-ÜBGM(1,1)	9,32336	9,571309	0,268469
PSO-ÜBGM(1,1)	2,132119	2,170642	0,030315
GIOA-ÜBGM(1,1)	2,393354	2,67868	0,11907
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	13,4716	13,76175	0,550701
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,529252	4,573322	0,025122
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=5)	4,008571	4,631113	0,284675
GA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	15,25837	15,38423	0,17718
PSO- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	3,800339	3,844505	0,073473
GIOA- Yuvarlanma Mekanizmalı ÜBGM(1,1) (k=opt)	3,511866	4,630131	0,290779

Bu çalışmada önerilen GIOA tabanlı gri modellerin PSO tabanlı gri modeller ile yakın sürelerde tahmin sonuçları verdiği görülmektedir. Çizelgelere göre Genetik Algoritma için işlem süreleri daha uzun iken; Güve- Işık Optimizasyonu Algoritması ile elde edilen modellerin işlem süreleri, Parçacık Sürü Optimizasyonuna daha yakındır.


Elde edilen hata oranlarının 100 iterasyondaki seyrini de incelersek GIOA tabanlı modellerin performansını ve kullanımının uygunluğunu bu şekilde de test etmiş oluruz. Bu düşünceden yola çıkarak, tüm optimizasyon modelleri ile elde edilen tahmin sonuçlarının 100 iterasyon için hata değerlerini karşılaştırmalı olarak veren grafikler Şekil 8.1- Şekil 8.18’de gösterilmiştir.

Ara yük bloğunda, ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.1'deki grafikte gösterildiği gibidir. Ara yük bloğu için GA-ÜBGM(1,1) modeli için hata oranı 60. iterasyonda, PSO-ÜBGM(1,1) modeli için 29. iterasyonda ve GIOA-ÜBGM(1,1) modeli için ise 11. iterasyonda optimuma ulaşmıştır. PSO ve GIO Algoritmaları daha iyi sonuç verirken; GIOA-ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.




Şekil 8.1: Ara yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi.

Temel yük bloğunda, ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.2'deki grafikte gösterildiği gibidir. Temel yük bloğu için GA-ÜBGM(1,1) modeli için hata oranı 88. iterasyonda, PSO-ÜBGM(1,1) modeli için 32. iterasyonda ve GIOA-ÜBGM(1,1) modeli için ise 13. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA-ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.



Şekil 8.2: Temel yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi.




Şekil 8.3: Zirve yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi.

Zirve yük bloğunda, ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil

8.3'teki grafikte gösterildiği gibidir. Zirve yük bloğu için GA-ÜBGM(1,1) modeli için hata oranı 44. iterasyonda, PSO-ÜBGM(1,1) modeli için 40. iterasyonda ve GIOA-ÜBGM(1,1) modeli için ise 37. iterasyonda optimuma ulaşmıştır. İterasyon sayıları birbirine yakın olsa da; en iyi optimum sonuca, en az iterasyon sayısı ile GIOA-ÜBGM(1,1) modeli ile ulaşılmıştır.


Ara yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.4'teki grafikte gösterildiği gibidir. Ara yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 56. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 27. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise sekizinci iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.



Şekil 8.4: Ara yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi.


Temel yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.5'teki grafikte gösterildiği gibidir. Temel yük

bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 15. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 22. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 55. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli ile optimum değere daha erken ulaşılmış olsa da en iyi değere GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli ile ulaşılmaktadır.




Şekil 8.5: Temel yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) ($k=5$) modellerinin 100 iterasyondaki hata oranlarının değişimi.

Zirve yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.6'daki grafikte gösterildiği gibidir. Zirve yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 32. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 5. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 44. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli optimum değere en son ulaşmış olsa da en iyi sonuca ulaşan modeldir.




Şekil 8.6: Zirve yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi.




Şekil 8.7: Ara yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi.

Ara yük bloğunda, veri boyutunun (optimum) altı olduğu Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.7'deki grafikte gösterildiği gibidir. Ara yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 19. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 20. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 17. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli en iyi sonuç ile optimum değere ilk önce ulaşmıştır.



Şekil 8.8: Temel yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi.

Temel yük bloğunda, veri boyutunun (optimum) 10 olduğu Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.8'deki grafikte gösterildiği gibidir. Temel yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 50. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 74. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 86. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli en iyi optimum değere ulaşmıştır ve PSO ile yakın iterasyon sayısına sahiptir.




Şekil 8.9: Zirve yük bloğu için GA, PSO ve GIOA tabanlı yuvarlanma mekanizmalı ÜBGM(1,1) ($k=opt$) modellerinin 100 iterasyondaki hata oranlarının değişimi.


Zirve yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.9'daki grafikte gösterildiği gibidir. Zirve yük bloğu için GA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 32. iterasyonda, PSO- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 5. iterasyonda ve GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 44. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli optimum değere en son ulaşmış olsa da en iyi sonuca ulaşan modeldir.

Bundan sonraki grafikler % 20 test verisi ile yapılan tahminlerin sonuçlarına dayanan grafiklerdir.

Ara yük bloğunda, ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.10'daki grafikte gösterildiği gibidir. Ara yük bloğu için GA- ÜBGM(1,1) modeli için hata oranı 30. iterasyonda, PSO- ÜBGM(1,1) modeli için 19. iterasyonda ve GIOA- ÜBGM(1,1) modeli için ise 14. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.




Şekil 8.10: Ara yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).




Şekil 8.11: Temel yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).

Temel yük bloğunda, ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.11'deki grafikte gösterildiği gibidir. Temel yük bloğu için GA- ÜBGM(1,1) modeli için hata oranı 36. iterasyonda, PSO- ÜBGM(1,1) modeli için 28. iterasyonda ve GIOA- ÜBGM(1,1) modeli için ise 10. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.




Şekil 8.12: Zirve yük bloğu için GA-ÜBGM(1,1), PSO-ÜBGM(1,1) ve GIOA-ÜBGM(1,1) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).

Zirve yük bloğunda, ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.12'deki grafikte gösterildiği gibidir. Zirve yük bloğu için GA- ÜBGM(1,1) modeli için hata oranı 98. iterasyonda, PSO- ÜBGM(1,1) modeli için 27. iterasyonda ve GIOA- ÜBGM(1,1) modeli için ise 18. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.



Şekil 8.13: Ara yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).


Ara yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.13'teki grafikte gösterildiği gibidir. Ara yük bloğu için GA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 27. iterasyonda, PSO- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 22. iterasyonda ve GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 20. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.




Şekil 8.14: Temel yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).

Temel yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.14'teki grafikte gösterildiği gibidir. Temel yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 31. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 31. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 53. iterasyonda optimuma ulaşmıştır. GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli en iyi optimum değere ulaşmış olup, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeline yakın sürede daha düşük hata oranı elde edilmiştir.

Zirve yük bloğunda, Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.15'teki grafikte gösterildiği gibidir. Zirve yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 22. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 23. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 26. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli optimum değeri diğer modellere göre daha düşük hata oranına sahiptir.




Şekil 8.15: Zirve yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=5) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).



Şekil 8.16: Ara yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).


Ara yük bloğunda, veri boyutunun (optimum) beş olduğu Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.16'daki grafikte gösterildiği gibidir. Ara yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 27. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 22. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 20. iterasyonda optimuma ulaşmıştır. Sonuç olarak, GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli optimum değere ilk önce ulaşmıştır.



Şekil 8.17: Temel yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).

Temel yük bloğunda, veri boyutunun (optimum) dört olduğu Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.17'deki grafikte gösterildiği gibidir. Temel yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 20. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 17. iterasyonda ve GIOA-Yuvarlanma mekanizmalı

ÜBGM(1,1) modeli için ise 28. iterasyonda optimuma ulaşmıştır. GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli en iyi optimum değere ulaşmıştır.



Şekil 8.18: Zirve yük bloğu için GA, PSO ve GIOA- yuvarlanma mekanizmalı ÜBGM(1,1) (k=opt) modellerinin 100 iterasyondaki hata oranlarının değişimi (%20 test).

Zirve yük bloğunda, veri boyutunun (optimum) altı olduğu Yuvarlanma mekanizmalı ÜBGM (1,1) parametre optimizasyonu için üç algoritmaya ait tahmin sonuçlarının her 100 iterasyondaki hata oranları (amaç fonksiyonu) Şekil 8.18'deki grafikte gösterildiği gibidir. Temel yük bloğu için GA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için hata oranı 58. iterasyonda, PSO-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için 25. iterasyonda ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modeli için ise 20. iterasyonda optimuma ulaşmıştır. GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) modeli en iyi optimum değere ilk önce ulaşmıştır.

Tüm modellerin 100 iterasyonluk grafikleri incelendiğinde GIOA tabanlı modeller her iki test verisi oranlarında da PSO tabanlı modellere yakın ancak daha uzun işlem süresine sahip olsa da; daha düşük iterasyonlarda optimum hata oranına veya daha iyi bir optimum değere ulaşmaktadır. Burada, GIOA tabanlı gri modellerin tahmin performanslarının, literatürde kabul edilen PSO ve GA algoritmaları ile kıyaslanarak kabul edilebilir ölçüde güçlü olduğu sonucuna varılmaktadır.

9. SONUÇLAR

Gri sistem teorisi küçük örneklem ve bilgi eksikliği içeren problemlere odaklanan yeni bir yöntemdir. Belirsiz sistemlerde mevcut olan kısmi bilgileri kullanarak yararlı bilgiler elde eder. Gri sistem teorisi, literatür çalışmalarında oldukça yaygın görülmeye başlanan bir konudur. Gerçek hayatta da küçük örneklem ve bilgi eksikliği içeren alanlar oldukça fazla olduğundan gri teorisinin uygulanabileceği alanlar da oldukça fazladır. Gri teorisinin ele alındığı birçok alan bulunmaktadır. Bunlara örnek olarak gri karar verme teknikleri, gri ilişkisel analiz ve bu tez çalışmasının da konusu olan, gri tahmin yöntemleri verilebilir.

Bu çalışmanın amacı, mevcut gri tahmin modelleri dışında hibrit bir optimizasyon modeli oluşturarak literatüre katkı sağlamaktır. Bu çalışmada, öncelikle gri teori ile ilgili bir giriş yapılmış daha sonra mevcut modeller açıklanmıştır. Önerilen modellerin temelini oluşturan bulanık gri model bir sonraki bölümde sunulmuştur. Daha sonra, önerilen modellerde parametre optimizasyonu için kullanılacak metasezgisel algoritmalar detaylıca anlatılmıştır. Mevcut modeller ve metasezgiseller tanıtıldıktan sonra önerilen modeller detaylıca açıklanmıştır ve önerilen modeller ile gerçek hayat uygulaması yapılmıştır. Literatürde varolan model ile kıyaslandığında hata oranının oldukça düşürüldüğü gözlemlenmiştir.

Güve- Işık Optimizasyonu Algoritması literatürde yeni kullanılan metasezgisellerden olup, gri tahmin çalışmaları oldukça azdır. Bu çalışmada parametre optimizasyonu için GIOA kullanılmıştır.

GIOA-ÜBGM(1,1) ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modelleri önerilmiş ve gri tahmin modelleriyle optimizasyon çalışmalarında sıklıkla görülen Genetik Algoritma ve Parçacık Sürü Optimizasyonu Algoritmaları ile kıyaslanmıştır. Böylece önerilen modelin tahmin performansının literatürde kabul gören algoritmalar gibi güçlü olduğu sonucuna varılmıştır. Ayrıca algoritmaların çalışma süreleri kıyaslandığında Genetik Algoritmaya göre sürede azalma elde edilmiştir. PSO ile kıyaslandığında ise literatürde yaygın kullanılan söz konusu algoritmaya yakın veya daha iyi çalışma süreleri elde edilmiştir. Ayrıca optimum parametre sonuçlarına GIOA

ile daha kısa sürede ulaşılmış olup; yine önerilen modellerle Genetik algoritmaya kıyasla çok daha küçük iterasyonlarda optimum sonuca ulaşılmıştır. PSO ile kıyaslandığında ise yakın performans sergilemektedir.

GIOA-ÜBGM(1,1) ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modelleri literatürde varolan ÜBGM(1,1) modelinden daha iyi bir tahmin performansına sahip olduğu sonucuna varılmış olup, yapılan uygulama ile Genetik Algoritma ile entegre edilen modelden de daha güçlü bir tahmin performansı ortaya koymuştur. Literatürde sıklıkla kullanılan PSO algoritması ile kıyaslandığında en az onun kadar iyi bir tahmin sonucu verdiğine dair kanıtlar elde edilmiştir. Böylece, bu çalışma ile ilk defa kullanılan GIOA-ÜBGM(1,1) ve GIOA-Yuvarlanma mekanizmalı ÜBGM(1,1) modellerinin başarılı tahmin performansı sergilediği sonucuyla literatüre katkı sağlanmıştır.

Bu çalışmada kullanılan algoritmalar belirli parametre değerleri altında çalıştırılmıştır. Belirlenen parametre değerleri ile çalışma sınırlandırılmıştır. Farklı parametre değerleri ile de analizler tekrarlanarak yorumlanabilir.

Gün geçtikçe literatüre eklenen yeni metasezgiseller olduğu gözlemlenmektedir. Bu metasezgiseller kullanılarak parametre optimizasyonu tahminleri ileriki çalışmalarda yapılabilir.

Başka alanlarda bulanık sayıların önemli olmadığı(alt ve üst sınırların) verilerle kullanımı uygun olmayabilir.

Ayrıca, uygulama alanları enerji ile sınırlı kalmayıp, yine bulanık gri modellere uygun olan hava sıcaklığı tahmini çalışmaları yapılabilir.

Bu çalışma tek değişkenli model ile sınırlandırılmıştır. Saatlik veya günlük elektrik tüketimi tahminleri tek değişkenli olarak ele alındığı gibi; hava sıcaklığı ve/veya nem değerleri gibi değişkenler de hesaba katılarak çok değişkenli tahmin modelleri (GM(1,N)) kullanılabilir. Ancak bunun için bölgesel elektrik tüketiminin ele alınması gerekmektedir.

İleriki çalışmalarda, NGBM(1,1), Gri Markov, Fourier serleri ve mevsimsel modeller de eklenerek tahmin çalışmaları yapılabilir.

KAYNAKLAR

- Abdel-Basset, M., Abdel-Fatah, L., ve Sangaiah, A. K.** (2018). Metaheuristic Algorithms: A Comprehensive Review. In A. K. Sangaiah, M. Sheng, Z. Zhang (Eds.), *Intelligent Data-Centric Systems Computational Intelligence for Multimedia Big Data on the Cloud with Engineering Applications* (10. Bölüm, s.185-231). Alıntı <https://www.sciencedirect.com/science/article/pii/B9780128133149000104>
- Acaroğlu, O., Ozdemir, L., ve Asbury, B.** (2008). A fuzzy logic model to predict specific energy requirement for TBM performance prediction. *Tunneling and Underground Sapce Technology*, 23, 600-608.
- Akay, D., ve Atak, M.** (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy*, 32, 1670–1675.
- Al-Musaylh, M.S., Deo, R.C., Adamowski, J.F., ve Li, Y.** (2018). Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia. *Advanced Engineering Informatics*, 35, 1-16.
- An, X., Jiang, D., Zhao, M. ve Liu, C.** (2012). Short-term Prediction of Wind Power Using EMD and Chaotic Theory. *Communications in Nonlinear Science and Numerical Simulation*, 17 (2), 1036-1042.
- Bahrami, M., Bozorg-Haddad, O., ve Chu, X.** (2018). Moth-Flame Optimization (MFO) Algorithm. In O. Bozorg-Haddad (Ed.), *Advanced Optimization by Nature-Inspired Algorithms, Studies in Computational Intelligence* (720, s.131-141). Singapore: Springer Nature.
- Bahrami, S., Hoosmand, R.A., ve Parastegari, M.** (2014). Short term electric load forecasting by wavelet transform and grey model improved by PSO (particle swarm optimization) algorithm. *Energy*, 72, 434-442.
- Benítez, R. B. C., Paredes, R.B.C., Lodewijks, G., ve Nabais, J. L.** (2013). Damp trend Grey Model forecasting method for airline industry. *Expert Systems with Applications*, 40(12), 4915-4921.
- Bhesdadiya, R. H., Trivedi, I. N., Jangir, P., Kumar, A., Jangir, N., ve Totlani, R.** (2017). A novel hybrid approach particle swarm optimizer with moth-flame optimizer algorithm. In *Advances in Computer and Computational Sciences*. 569-577. Singapore: Springer.
- Blum, C., ve Roli, A.** (2003). Metaheuristics in combinatorial optimization: Overview and conceptual comparison, *ACM Computer Survey*, 35 (3), 268–308.
- Boussaïd, I., Lepagnot, J., ve Siarry P.** (2013). A survey on optimization metaheuristics. *Information Sciences*, 237, 82-117.

- Chapman, S. N.** (2006). *The Fundamentals of Production Planning and Control*. Upper Saddle River, New Jersey: Pearson.
- Chauhan, S. S., ve Kotecha, P.** (2016). Single level production planning in petrochemical industries using Moth-flame optimization. *In Region 10 Conference (TENCON)*, 2016 IEEE, 263–266.
- Chen, C.-I., Hsin, P.-H., ve Wu, C.-S.** (2010). Forecasting Taiwan's major Stock indices by the Nash nonlinear grey Bernoulli model. *Expert Systems with Applications*, 37, 7557-7562.
- Chen, H.-B., Pei, L.-L. ve Zhao, Y.-Z.** (2021). Forecasting seasonal variations in electricity consumption and electricity usage efficiency of industrial sectors using a grey modeling approach, *Energy*, 222,119952.
- Deb, K.** (2001). *Multi-objective optimization using evolutionary algorithms*. (1. Baskı). Chichester, England: John Wiley&Sons.
- Deng, J.** (1982). The Control Problems of Grey Systems. *Systems &Control Letters*, 1(5), 288-294.
- Deng, J.** (1989). Introduction to Grey System Theory. *The Journal of Grey System*, 1, 1-24.
- de Oliveira, E.M., ve Cyrino Oliveira, F.L.** (2018). Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods. *Energy*, 114, 776-788.
- Ding, S., Hipel, K.W., ve Dang, Y.-g.** (2018). Forecasting China's electricity consumption using a new grey prediction model. *Energy*, 149, 314-328.
- Eberhart, R., Kennedy, J.** (1995). A new optimizer using particle swarm theory. *Proceedings of the Sixth International Symposium on Micro Machine and Human Science (MHS'95)*, 39-43.
- El Aziz, M. A., Ewees, A. A., ve Hassanien, A. E.** (2017). Whale optimization algorithm and Moth-flame optimization for multilevel thresholding image segmentation. *Expert Systems with Applications*, 83, 242–256.
- Ene, S., ve Öztürk, N.** (2017). Grey modelling based forecasting system for return flow of end-of-life vehicles. *Technological Forecasting & Social Change*, 115, 155–166.
- Ervural, B.C., ve Ervural, B.** (2018). Improvement of grey prediction models and their usage for energy demand forecasting. *Journal of Intelligent & Fuzzy Systems*, 34, 2679-2688.
- Fister, Jr, I., Fister, D., Yang, X. S.** (2013). A hybrid bat algorithm, *arXiv preprint arXiv:1303.6310*.
- Gendreau, M., Potvin, JY.** (2005). Metaheuristics in Combinatorial Optimization. *Ann Oper Res*, 140, 189–213.
- Gope, S., Dawn, S., Goswami, A. K., ve Tiwari, P. K.** (2016). Profit maximization with integration of wind farm in contingency constraint deregulated power market using Moth flame optimization algorithm. *In Region 10 Conference (TENCON)*, 2016 IEEE.1462–1466

- Hammad, M. A., Jereb, B., Rosi, B., ve Dragan, D.** (2020). Methods and models for electric load forecasting: A comprehensive review. *Logistics & Sustainable Transport*, 11, 51–76.
- Hamzaçebi, C.** (2007). Forecasting of Turkey's net electricity energy consumption on sectoral bases, *Energy Policy*, 35, 2009–2016.
- Hamzacebi, C., ve Es, H.A.** (2014). Forecasting the annual electricity consumption of Turkey using an optimized grey model, *Energy*, 70, 165-171.
- Heizer, J., ve Render, B.** (2011) Principles of Operations Management. 8th Edition, Prentice Hall, Upper Saddle River.
- Hsu, L.-C.** (2009). Forecasting the output of integrated circuit industry using genetic algorithm based multivariable grey optimization models. *Expert Systems with Applications*, 36, 7898–7903.
- Huang, M., He, Y. ve Cen, H.** (2007). Predictive analysis on electric-power supply and demand in China. *Renewable Energy*, 32 (7), 1165-1174.
- Huang, Y.P. ve Huang, C.H.** (1997). Real-valued genetic algorithms for fuzzy grey prediction system. *Fuzzy Sets and Systems*, 87, 265-276.
- Jamil, R.** (2020). Hydroelectricity consumption forecast for Pakistan using ARIMA modeling and supply-demand analysis for the year 2030, *Renewable Energy*, 154, 1-10.
- Jangir, P.** (2017). Optimal power flow using a hybrid particle Swarm optimizer with moth flame optimizer. *Global Journal of Research In Engineering*.
- Kayacan, E., Ulutas, B., ve Kaynak, O.** (2010). Grey system theory-based models in time series prediction. *Expert Systems with Applications*, 37(2), 1784-1789.
- Kaytez, F., Taplamacioğlu, M.C., Cam, E. ve Hardalac, F.** (2015). Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines, *Electrical Power and Energy Systems*, 67, 431-438.
- Krajewsky L. J., Ritzman L. P. ve Malhotra M. K.** (2010). Operations Management, Processes and Supply Chains. 9. Baskı, Prentice Hall, Pearson.
- Kumluca Topallı, Ayça.** (2003). *Hybrid learning algorithm for intelligent short-term load forecasting*. (Doktora Tezi). Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Kuranga, C., ve Pillay, N.** (2022). A comparative study of nonlinear regression and autoregressive techniques in hybrid with particle swarm optimization for time-series forecasting. *Expert Systems with Applications*, 190, 116163.
- Kobu, B.** (2008). Üretim Yönetimi, 14. Baskı, Beta.
- Lebotsa, M. E., Sigauke, C., Bere, A., Fildes, R., and Boylan, J.E.** (2018). Short term electricity demand forecasting using partially linear additive quantile regression with an application to the unit commitment problem, *Applied Energy*, 222, 104-118.

- Lee, Y.S., ve Tong, L.I.** (2011). Forecasting energy consumption using a grey model improved by incorporating genetic programming. *Energy Conversion and Management*, 52(1), 147-152.
- Li, C.** (2021). A fuzzy theory-based machine learning method for workdays and weekends short-term load forecasting. *Energy and Buildings*, 245, 111072.
- Li, D.-C., Chang, C.J., Chen, C.-C., ve Chen, W.-C.** (2012). Forecasting short-term electricity consumption using the adaptive grey-based approach—An Asian case. *Omega*, 40, 767-773.
- Li, S., Ma, X., Yang, C.** (2018). Prediction of spontaneous combustion in the coal stockpile based on an improved metabolic grey model. *Process Safety and Environmental Protection*, 116, 564–577.
- Li, W. K., Wang, W. L., ve Li, L.** (2018). Optimization of water resources utilization by multi-objective moth-flame algorithm. *Water Resources Management*, 1–14.
- Lin, C.T. ve Yang, S.Y.** (2003). Forecast of the Output Value of Taiwan's Opto-Electronics Industry Using the Grey Forecasting Model. *Technological Forecasting & Social Change*, 70 (2), 177-186.
- Lin Y., Chen M., ve Liu S.** (2003). Theory of Grey Systems: Capturing Uncertainties of Grey Information. *Kybernetes*, 33, 196-218.
- Liu, L., Wang, Q., Liu, M., ve Li, L.** (2014). An Intelligence Optimized Rolling Grey Forecasting Model Fitting to Small Economic Dataset. *Abstract and Applied Analysis*, 2014, 10.
- Liu S., ve Lin Y.** (2006). Grey Information: Theory and Practical Applications. Springer.
- Lu, J., Xie, W., Zhou, H., ve Zhang, A.** (2016). An optimized nonlinear grey Bernoulli model and its applications. *Neurocomputing*, 177, 206–214.
- Luo, D., Ambreen, M., Latif, A., ve Wang, X.** (2020). Forecasting Pakistan's electricity based on improved discrete grey polynomial model. *Grey Sytems: Theory and Application*, 10(2), 215-230.
- Ma, W., Zhu X., ve Wang, M.** (2013). Forecasting iron ore import and consumption of China using grey model optimized by particle swarm optimization algorithm. *Resources Policy*, 38, 613-620.
- Mehne, S.H. H., ve Mirjalili, S.** (2020). Moth-Flame Optimization (MFO) Algorithm: Theory, Literature Review, and Application in Optimal Nonlinear Feedback Control Design. In S. Mirjalili ve diğ., (Eds), *Nature-Inspired Optimizers, Studies in Computational Intelligence* (811, s.143-166). Switzerland: Springer Nature.
- Mirjalili, S.** (2015). Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm. *Knowledge Based Systems*, 89, 228-249.
- Nai-ming, X., Yuan, C.Q., ve Yang, Y.J.** (2015). Forecasting China's energy demand and Self-sufficiency Rate by Grey Forecasting Model and Markov Model. *International Journal of Electrical Power and Energy Systems*, 66, 1-8.

- Nguyen, N.T., Phan, V. T. ve Malara, Z.** (2019). Nonlinear grey Bernoulli model based on Fourier transformation and its application in forecasting the electricity consumption in Vietnam. *Journal of Intelligent & Fuzzy Systems*, 37, 7631-7641.
- Oğcu, G., Demirel, O. F., ve Zaim, S.** (2012). Forecasting Electricity Consumption with Neural Networks and Support Vector Regression, *Procedia - Social and Behavioral Sciences*, 58, 1576 – 1585.
- Olgun S.** (2009). Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemleri ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması, Yüksek lisans tezi, İstanbul Üniversitesi, İstanbul.
- Osman, I. H.** (2002). Focused issue on applied meta-heuristics. *Knowledge Based System Computers & Industrial Engineering*, 44, 205-207.
- Özcan, T. ve Tüysüz, F.** (2018). C. Kahraman, Y.I. Topcu (eds.), Operations Research Applications in Health Care Management, *International Series in Operations Research & Management Science*, 262, Springer International Publishing AG. Alıntı https://doi.org/10.1007/978-3-319-65455-3_7.
- Pao, H.-T., ve Tsai, C.-M.** (2011). Modelling and forecasting the CO2 emissions, energy consumption, and economic growth in Brazil. *Energy*, 36, 2450-2458.
- Roetzel, W., Luo, X., ve Chen, D.** (2020). Optimal design of heat exchanger networks. In W. Roetzel, X. Luo, ve D. Chen (Eds.), *Design and Operation of Heat Exchangers and their Networks* (6. Bölüm, s.231-317). Alıntı <https://www.sciencedirect.com/science/article/pii/B9780128178942000066>
- Sahu, P. C., Prusty, R. C., ve Panda, S.** (2017). MFO algorithm based fuzzy-PID controller in automatic generation control of multi-area system. In *2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT)*, 1–6.
- Sarma, A., Bhutani, A., ve Goel, L.** (2017). Hybridization of moth flame optimization and gravitational search algorithm and its application to detection of food quality. In *Intelligent Systems Conference (IntelliSys)*, 2017, 52–60.
- Savsani, V., ve Tawhid, M.A.** (2017). Non-dominated sorting moth flame optimization (NS-MFO) for multi-objective problems. *Engineering Applications of Artificial Intelligence*, 63, 20-32.
- Sayed, G. I., ve Hassanien, A. E.** (2017). Moth-flame swarm optimization with neutrosophic sets for automatic mitosis detection in breast cancer histology images. *Applied Intelligence*, 47(2), 397–408.
- Sayed, G.I., ve Hassanien, A. E.** (2018). A hybrid SA-MFO algorithm for function optimization and engineering design problems, *Complex & Intelligent Systems*, 4, 195–212.

- Sayed, G. I., Hassanien, A. E., Nassef, T. M., ve Pan, J. S.** (2016). Alzheimers disease diagnosis based on Moth flame optimization. *In International Conference on Genetic and Evolutionary Computing*, 298–305. Springer, Cham.
- Sayed, G. I., Soliman, M., ve Hassanien, A. E.** (2016). Bio-inspired swarm techniques for thermogram breast cancer detection. *In Medical Imaging in Clinical Applications*, 487–506. Springer, Cham.
- Shang, W. ve Pei, G.** (2009). Research on Chinese Rural GDP Forecasting Using Grey Model Optimized by PSO Method. *2009 International Conference on Industrial and Information Systems*, 216-219.
- Shehab, M., Abualigah, L., Al Hamad, H., Ala-bool, H., Alshinwan, M., ve Khasawneh, A.M.** (2020). Moth-flame optimization algorithm: variants and applications. *Neural Computing and Applications*, 32, 9859-9884.
- Sifeng, L., Forrest, J., ve Yingjie, Y.** (2011). A Brief Introduction to Grey Systems Theory. *IEEE International Conference on Grey Systems and Intelligence Services*, 1-9.
- Soliman, G. M., Khorshid, M. M., ve Abou-El-Enien, T. H.** (2016). Modified moth-flame optimization algorithms for terrorism prediction. *International Journal of Application or Innovation in Engineering and Management*, 5, 47–58.
- Sudheer, G. ve Suseelatha, A.** (2015). Short term load forecasting using wavelet transform combined with Holt-Winters and weighted nearest neighbor models. *Journal of Electric Power & Energy Systems*, 64, 340-346.
- Şahin, A. E.** (2001). Eğitim Araştırmalarında Delphi Tekniği ve Kullanımı. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 20, 215-220.
- Şahin, U.** (2019). Forecasting of Turkey's greenhouse gas emissions using linear and nonlinear rolling metabolic grey model based on optimization. *Journal of Cleaner Production*, 239, 118079.
- Şahin, U.** (2020). Projections of Turkey's electricity generation and installed capacity from total renewable and hydro energy using fractional nonlinear grey Bernoulli model and its reduced forms. *Sustainable Production and Consumption*, 23, 52–62.
- Şahin, U.** (2021). Future of renewable energy consumption in France, Germany, Italy, Spain, Turkey and UK by 2030 using optimized fractional nonlinear grey Bernoulli model. *Sustainable Production and Consumption*, 25, 1–14.
- Talbi, E.-G.** (2009). Metaheuristics from Design to Implementation. John Wiley & Sons, Inc., Hoboken, New Jersey, ISBN: 978-0-470-27858-1.
- Tang, H.W.V. ve Yin, M.S.** (2012). Forecasting performance of grey prediction for education expenditure and school enrollment. *Economics of Education Review*, 31 (4), 452-462.
- Tang, L., Wang, X., Wang, X., Shao, C., Liu, S., ve Tian, S.** (2019). Long-term electricity consumption forecasting based on expert prediction and fuzzy Bayesian theory. *Energy*, 167, 1144-1154.

- Tektaş Sivrikaya, B.** (2016). *Elektrik üreticileri perspektifinden uzun dönem elektrik üretimi yatırımlarının planlanmasına yönelik bir karar destek modeli*. (Doktora Tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Tengilimoğlu, D. ve Yiğit, V.** (2013). *Sağlık İşletmelerinde Tedarik Zinciri ve Malzeme Yönetimi*, Nobel Yayınları.
- Tsaur, R.C.** (2006). Forecasting analysis by fuzzy grey model (1,1). *Journal of the Chinese Institute of Industrial Engineers*, 23(5), 415-422.
- Tüysüz, F., ve Kahraman, C.** (2010). Modeling a flexible manufacturing cell using stochastic Petri nets with fuzzy parameters. *Expert Systems with Applications*, 37(5), 3910-3920.
- Upper, N., Hemeida, A. M., ve Ibrahim, A. A.** (2017). Moth-flame algorithm and loss sensitivity factor for optimal allocation of shunt capacitor banks in radial distribution systems. *In Power Systems Conference (MEPCON), 2017 Nineteenth International Middle East*. 851–856
- URL-1** <https://ytbsbilgi.teias.gov.tr/ytbsbilgi/frm_istatistikler.jsf>, erişim tarihi 21.03.2021.
- Wang, J., Du, P., Lu, J., Yang W., ve Niu, T.** (2018). An improved grey model optimized by multi-objective ant lion optimization algorithm for annual electricity consumption forecasting. *Applied Soft Computing*, 72, 321-337.
- Wang, J., Zhu, S., Zhao, W. ve Zhu, W.** (2011). Optimal parameters estimation and input subset for grey model based on chaotic particle swarm optimization algorithm, *Expert Systems with Applications*, 38, 8151-8158.
- Wang, Q., Liu, L., Wang, S., Wang, J.-Z., ve Liu, M.** (2017). Predicting Beijing's tertiary industry with an improved grey model. *Applied Soft Computing*, 57, 482–494.
- Wang, Z.-X., ve Hao, P.** (2016). An improved grey multivariable model for predicting industrial energy consumption in China. *Applied Mathematical Modelling*, 40, 5745–5758.
- Wang, Z.-X., Hipel, K. W., Wang, Q., ve He, S.-W.** (2011). An optimized NGBM (1,1) model for forecasting the qualified discharge rate of industrial wastewater in China. *Applied Mathematical Modelling*, 35(12), 5524-5532.
- Wen, J.-C., Huang, K.-H., ve Wen, K.-L.** (2000). The study of α in GM (1,1) model. *Journal of the Chinese Institute of Engineers*, 23(5), 583-589
- Xiuwen, W.** (1994). Grey prediction of Datong-Yanggao earthquake and its development tendency in Chinese. *Earthquake (Beijing)*, 3(3), 78-84.
- Yang, X-S.** (2010a). *Nature-Inspired Metaheuristic Algorithms*. Luniver Press:UK.
- Yang, X-S.** (2010b). Optimization Algorithms. In S. Koziel ve X.-S. Yang (Eds.), *Computational Optimization, Methods and Algorithms* (356, s.13-31). Springer-Verlag Berlin Heidelberg.

- Yang, X.-S.** (2011). *Engineering Optimization: An Introduction with Metaheuristic Applications*. Wiley: New Jersey.
- Yang, X.-S.** (2021). Genetic Algorithms. In C. Katsaropoulos (Ed.), *Nature-Inspired Optimization Algorithms* (2. Baskı, s.91-100). Alıntı <https://www.sciencedirect.com/science/article/pii/B9780128219867000135>.
- Yiğit, F.** (2019). *Stok yönetimi için gri tahminleme ve sürü zekası esaslı bir karar verme metodolojisi önerisi*. (Doktora Tezi). İstanbul Üniversitesi - Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Yongwei, C., Dong, M., Huanyu, R., Tijun, F., ve Jianbang, D.** (2020). Using temporal input-output approach to analyze the ripple effect of China's energy consumption, *Energy*, 211, 118641.
- Yuan, J., Farnham, C., Azuma, C., ve Emura, K.** (2018). Predictive artificial neural network models to forecast the seasonal hourly electricity consumption for a University Campus. *Sustainable Cities and Society*, 42, 82-92.
- Zadeh, L.A.** (1965). Fuzzy sets. *Information and Control*, 8(3),338-353.
- Zeng, B., Luo, C., Liu, S., ve Li, C.** (2016). A novel multi-variable grey forecasting model and its application in forecasting the amount of motor vehicles in Beijing. *Computers & Industrial Engineering*, 101, 479-489.
- Zeng, X., Shu, L., Huang, G., Jiang, J.** (2016). Triangular fuzzy series forecasting based on grey model and neural network. *Applied Mathematical Modeling*, 40,1717-1727.
- Zhang, L., Mistry, K., Neoh, S. C., ve Lim, C. P.** (2016). Intelligent facial emotion recognition using moth-firefly optimization. *Knowledge-Based Systems*, 111, 248–267.
- Zhao, H., Zhao H., ve Guo, S.** (2016). Using GM (1,1) Optimized by MFO with Rolling Mechanism to Forecast the Electricity Consumption of Inner Mongolia. *Applied Sciences*, 6 (1), 20.
- Zhao, Z., Wang, J., Zhao, J., ve Su, Z.** (2012). Using a Grey model optimized by Differential Evolution algorithm to forecast the per capita annual net income of rural households in China. *Omega*, 40, 525–532.
- Zheng, C., Wu, W.-Z., Xie, W., ve Li, Q.** (2020). Forecasting Natural Gas Consumption of China Using a Novel Grey Model. *Complexity*, 2020,1-9.
- Zheng, C., Wu, W.-Z., Xie, W., ve Li, Q.** (2021). A MFO-based conformable fractional nonhomogeneous grey Bernoulli model for natural gas production and consumption forecasting. *Applied Soft Computing Journal*, 99, 106891.
- Zheng, C., Wu, W.-Z., Xie, W., ve Li, Q. ve Zhang, T.** (2021). Forecasting the hydroelectricity consumption of China by using a novel unbiased nonlinear grey Bernoulli model, *Journal of Cleaner Production*, 278, 123903.
- Zheng, Y. ve Lewis, R.W.** (1993). On the optimization concept of grey systems. *Applied Mathematical Modeling*, 17(7), 388-392.

- Zhou, J., Fang, R., Li, Y., Zhang, Y., ve Peng, B.** (2009). Parameter optimization of nonlinear grey Bernoulli model using particle swarm optimization. *Applied Mathematics and Computation*, 207, 292–299.
- Zhou, P., Ang, B.W., ve Poh, K.L.** (2006). A trigonometric grey prediction approach to forecasting electricity demand. *Energy*, 31(14), 2839-2847.





EKLER

EK A: Elektrik Tüketim Verileri

EK B : ÜBGM(1,1) MATLAB kodları

EK C : ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

EK D : Yuvarlanma mekanizmalı ÜBGM(1,1) MATLAB kodları

EK E : Yuvarlanma mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları





EK A : Elektrik tüketim verileri**Çizelge A.1 : 4-10 Ocak Türkiye'nin elektrik tüketimi (URL-1).**

TÜKETİM (MWh)							
Saat	4 Ocak	5 Ocak	6 Ocak	7 Ocak	8 Ocak	9 Ocak	10 Ocak
01:00	30.120	33.522	33.605	34.147	34.178	34.237	32.413
02:00	28.764	31.817	31.892	32.357	32.405	32.599	30.839
03:00	27.660	30.561	30.827	31.200	31.193	31.268	29.482
04:00	26.881	29.768	30.080	30.387	30.355	30.359	28.504
05:00	26.831	29.477	29.902	30.292	30.128	29.795	28.195
06:00	27.284	29.806	30.242	30.342	30.403	29.924	28.064
07:00	28.131	30.391	30.932	31.222	31.162	30.107	28.071
08:00	30.632	32.208	32.739	32.980	33.062	30.842	28.081
09:00	35.473	36.217	36.943	37.216	37.075	32.342	27.713
10:00	39.059	39.515	40.138	40.325	39.988	34.168	29.191
11:00	40.647	41.061	41.460	41.349	41.264	35.810	30.815
12:00	41.225	41.557	42.061	41.870	41.711	37.041	32.134
13:00	39.808	40.315	40.600	40.416	40.236	36.699	32.402
14:00	40.084	40.446	40.845	40.742	39.411	37.305	33.297
15:00	40.430	40.876	40.934	40.934	40.416	37.553	33.423
16:00	39.307	40.203	40.210	40.060	39.666	36.914	32.902
17:00	39.493	40.002	40.179	40.218	39.608	36.773	33.411
18:00	40.559	40.808	40.984	41.278	40.341	37.718	34.806
19:00	40.588	41.004	41.264	41.561	40.595	38.870	36.255
20:00	39.482	39.804	40.264	40.299	39.578	38.002	35.826
21:00	38.149	38.405	38.815	39.023	38.468	37.012	35.058
22:00	37.269	37.586	38.202	38.070	37.691	36.180	34.258
23:00	36.627	37.035	37.485	37.492	36.945	35.441	33.773
24:00	35.331	35.576	36.120	36.295	35.905	34.301	32.823

Çizelge A.2 : 11-17 Ocak Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)							
Saat	11 Ocak	12 Ocak	13 Ocak	14 Ocak	15 Ocak	16 Ocak	17 Ocak
01:00	31.445	34.005	33.380	33.898	34.618	34.534	33.241
02:00	30.005	32.291	31.872	32.176	32.671	32.801	31.381
03:00	28.865	31.031	30.694	31.018	31.306	31.420	29.905
04:00	28.159	30.090	29.899	30.118	30.565	30.628	29.008
05:00	27.895	29.913	29.658	30.038	30.244	30.192	28.561
06:00	28.231	30.150	29.880	30.214	30.650	30.141	28.401
07:00	29.135	30.874	30.685	30.990	31.422	30.373	28.308
08:00	31.562	32.563	32.542	32.843	33.292	31.122	28.044
09:00	36.246	36.491	36.418	37.205	37.521	32.666	27.390
10:00	39.763	39.361	39.596	40.487	41.118	34.609	28.878
11:00	41.360	40.535	41.256	42.195	42.866	36.483	30.983
12:00	41.925	41.439	42.282	43.109	43.692	38.033	32.817
13:00	40.616	40.301	41.289	42.241	42.380	38.170	33.492
14:00	41.000	40.505	41.934	42.849	41.731	38.914	34.275
15:00	41.210	40.650	42.582	43.367	42.816	39.114	34.236
16:00	40.614	40.100	42.028	42.693	42.343	38.600	34.011

Çizelge A.2 (devam): 11-17 Ocak Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)							
Saat	11 Ocak	12 Ocak	13 Ocak	14 Ocak	15 Ocak	16 Ocak	17 Ocak
17:00	40.388	39.978	41.762	42.331	41.978	38.381	34.255
18:00	41.041	40.771	42.063	42.620	42.124	38.690	34.996
19:00	41.097	40.714	41.861	42.355	41.926	39.363	36.687
20:00	39.923	39.500	40.451	41.190	40.587	38.660	36.309
21:00	38.465	38.008	38.843	39.530	39.215	37.568	35.681
22:00	37.738	37.359	38.051	38.653	38.305	36.885	34.974
23:00	37.030	36.549	37.296	37.949	37.622	36.137	34.543
24:00	35.783	35.234	35.913	36.643	36.420	34.846	33.524

Çizelge A.3 : 18-24 Ocak Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)							
Saat	18 Ocak	19 Ocak	20 Ocak	21 Ocak	22 Ocak	23 Ocak	24 Ocak
01:00	31.747	35.160	35.861	35.725	35.665	35.430	32.154
02:00	30.171	33.335	33.730	33.825	33.637	33.156	30.428
03:00	28.812	31.819	32.346	32.389	32.399	32.196	29.198
04:00	27.993	31.195	31.620	31.608	31.637	31.131	28.462
05:00	27.961	30.874	31.389	31.428	31.300	30.732	28.248
06:00	28.299	30.968	31.548	31.660	31.729	30.715	28.597
07:00	29.175	31.920	32.461	32.422	32.550	31.059	29.654
08:00	31.642	33.795	34.533	34.640	34.627	31.704	31.977
09:00	36.921	38.326	39.230	39.424	39.279	33.562	37.090
10:00	41.172	42.410	43.354	43.335	42.597	35.559	40.501
11:00	43.300	44.616	45.228	44.974	44.563	37.057	42.335
12:00	44.887	45.611	46.057	45.802	45.207	38.312	43.388
13:00	44.023	44.598	45.128	44.486	43.532	38.030	42.385
14:00	44.395	44.938	45.292	44.460	42.497	38.485	42.848
15:00	44.796	45.227	45.342	44.649	42.984	38.216	43.194
16:00	44.281	44.446	44.677	43.962	42.401	37.580	42.471
17:00	44.100	43.840	44.176	43.643	41.975	37.314	42.366
18:00	43.978	44.006	44.348	44.087	42.587	37.869	42.353
19:00	43.718	44.067	44.392	44.091	42.676	39.484	42.188
20:00	42.299	42.739	42.971	43.006	41.435	38.883	40.999
21:00	40.700	41.327	41.311	41.268	40.077	38.098	39.471
22:00	39.644	40.257	40.316	40.324	39.274	37.263	38.694
23:00	38.773	39.519	39.519	39.563	38.557	36.588	37.964
24:00	37.584	38.106	38.019	37.886	37.306	35.347	36.735

Çizelge A.4 : 25- 31 Ocak Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)							
Saat	25 Ocak	26 Ocak	27 Ocak	28 Ocak	29 Ocak	30 Ocak	31 Ocak
01:00	32.154	34.668	34.803	35.230	35.763	35.518	33.280
02:00	30.428	33.088	32.943	33.193	33.848	33.660	31.452
03:00	29.198	31.844	31.577	32.000	32.376	32.135	29.960
04:00	28.462	30.746	30.771	31.132	31.513	31.061	29.048
05:00	28.248	30.469	30.484	30.942	31.414	30.553	28.407
06:00	28.597	30.673	30.637	31.174	31.564	30.496	28.282
07:00	29.654	31.591	30.945	31.959	32.461	30.893	28.258
08:00	31.977	33.420	33.231	34.082	34.265	31.444	28.210
09:00	37.090	37.543	37.298	38.221	38.675	33.059	27.791
10:00	40.501	40.494	40.652	41.728	42.255	35.463	29.208
11:00	42.335	42.042	42.499	43.649	43.801	37.104	31.045
12:00	43.388	43.060	43.710	44.660	44.952	38.789	32.487
13:00	42.385	41.989	42.900	43.700	43.823	38.638	33.023
14:00	42.848	42.517	43.351	44.235	42.739	39.483	33.565
15:00	43.194	42.744	43.825	44.710	43.726	39.483	33.640
16:00	42.471	42.169	43.308	44.192	43.033	38.820	33.030
17:00	42.366	41.775	43.250	43.736	42.470	38.547	32.904
18:00	42.353	42.059	43.052	43.434	42.373	38.324	33.614
19:00	42.188	42.159	42.785	43.075	42.534	39.045	35.734
20:00	40.999	40.822	41.755	42.554	41.724	38.887	36.147
21:00	39.471	39.470	40.078	40.840	40.110	37.617	35.644
22:00	38.694	38.654	39.149	39.742	39.277	36.709	34.771
23:00	37.964	37.856	38.416	38.909	38.583	36.196	34.309
24:00	36.735	36.701	37.244	37.754	37.580	34.993	33.321

Çizelge A.5 : 1-7 Şubat Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)							
Saat	1 Şubat	2 Şubat	3 Şubat	4 Şubat	5 Şubat	6 Şubat	7 Şubat
01:00	31.801	33.837	33.958	33.647	33.383	33.282	31.586
02:00	30.089	32.150	32.004	31.847	31.779	31.763	30.043
03:00	28.883	30.651	30.838	30.671	30.620	30.449	28.685
04:00	28.078	29.943	29.928	29.957	29.866	29.674	27.902
05:00	27.985	29.729	29.572	29.566	29.577	29.408	27.652
06:00	28.014	29.846	29.863	29.870	29.825	29.361	27.360
07:00	28.814	30.737	30.794	30.711	30.534	29.845	27.492
08:00	31.254	32.363	32.461	32.297	32.124	30.242	27.217
09:00	36.782	36.706	36.611	36.806	36.495	32.045	27.078
10:00	40.686	40.087	39.986	39.647	39.568	33.609	28.263
11:00	42.417	41.736	41.116	40.812	40.905	34.827	29.738
12:00	43.695	42.414	41.251	41.360	41.457	35.749	30.814
13:00	42.431	40.960	39.651	39.704	39.946	34.876	31.220
14:00	42.505	41.156	39.925	39.064	38.551	35.592	31.695
15:00	42.286	41.374	40.207	39.988	39.210	35.353	31.704
16:00	41.398	40.538	39.439	39.290	38.429	34.546	31.143
17:00	40.832	40.278	39.241	38.959	37.967	33.981	31.240
18:00	40.573	40.014	39.180	39.063	38.073	34.652	31.990

Çizelge A.5 (devam): 1-7 Şubat Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)							
Saat	1 Şubat	2 Şubat	3 Şubat	4 Şubat	5 Şubat	6 Şubat	7 Şubat
19:00	40.488	40.031	39.630	39.253	38.439	36.394	33.697
20:00	39.594	39.466	39.382	39.295	38.544	36.738	34.650
21:00	38.297	38.179	38.147	38.094	37.442	35.847	34.013
22:00	37.451	37.391	37.391	37.259	36.761	35.102	33.100
23:00	36.881	36.800	36.711	36.680	36.211	34.451	32.716
24:00	35.538	35.468	35.379	35.565	35.274	33.362	31.676

Çizelge A.6 : 8-13 Şubat Türkiye'nin elektrik tüketimi (URL-1).

TÜKETİM (MWh)						
Saat	8 Şubat	9 Şubat	10 Şubat	11 Şubat	12 Şubat	13 Şubat
01:00	30.431	32.792	32.965	33.253	33.198	33.651
02:00	28.964	31.169	31.333	31.713	31.645	32.186
03:00	27.733	29.898	30.107	30.441	30.270	31.059
04:00	27.085	29.278	29.290	29.564	29.651	30.056
05:00	26.956	29.065	29.177	29.421	29.213	29.712
06:00	27.234	29.230	29.456	29.567	29.494	29.836
07:00	28.226	30.061	30.234	30.363	30.349	30.195
08:00	30.322	31.471	31.702	31.954	31.979	30.255
09:00	35.205	35.836	35.975	36.336	36.371	32.506
10:00	38.436	38.590	38.842	38.714	39.420	34.408
11:00	40.187	39.811	39.825	39.857	40.944	36.045
12:00	41.112	40.613	40.729	40.326	42.025	37.214
13:00	40.014	39.197	39.455	39.119	40.866	37.071
14:00	40.171	39.212	39.519	39.262	39.791	37.368
15:00	40.224	39.519	39.571	39.484	40.865	37.203
16:00	39.567	38.684	38.785	38.645	40.421	36.156
17:00	39.081	38.344	38.426	38.209	39.903	35.972
18:00	38.893	38.385	38.131	38.246	39.783	36.421
19:00	38.843	38.448	38.290	38.714	39.545	37.349
20:00	38.565	38.598	38.458	38.930	39.515	37.861
21:00	37.191	37.311	37.478	37.789	38.225	36.938
22:00	36.387	36.620	36.636	36.891	37.162	35.871
23:00	35.675	35.861	36.115	36.203	36.543	35.127
24:00	34.510	34.557	35.014	35.023	35.472	33.813

EK B : ÜBGM(1,1) MATLAB kodları

Parametre değerleri sabitken;

```
Xv=[29476.9300000000,32113.6937500000,36626.7700000000;  
.....;  
29712.4100000000,32314.4512500000,36543.4600000000];  
function [mape,mape1,mapem,mape2,Tahmin_Xl, Tahmin_Xm,  
Tahmin_Xr,tahminroll,tahminrolm,tahminrolr,a,al,am,ar] =  
fuzzygrey_lambdasbtt_mape_w_test  
(Xv,w,lambdal,lambdam,lambdar,alfa,beta,gama)  
nn=length(Xv);  
xl=Xv(:,1);  
xm=Xv(:,2);  
xr=Xv(:,3);  
toplaml=0; toplamm=0; toplamr=0;  
for i=1:nn-1-w  
    Yl(i)=xl(i+1);  
    Ym(i)=xm(i+1);  
    Yr(i)=xr(i+1);  
end  
for i=1:nn-w  
    X1l(i)=xl(i)+toplaml;  
    toplaml=X1l(i);  
    X1m(i)=xm(i)+toplamm;  
    toplamm=X1m(i);  
    X1r(i)=xr(i)+toplamr;  
    toplamr=X1r(i);  
end  
for i=2:nn-w  
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);  
    Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);  
    Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);  
end  
Zl(1)=[]; Zm(1)=[]; Zr(1)=[];  
for i=1:nn-1-w  
    Bl(i,1)=-Zl(i); Bl(i,2)=1; Bm(i,1)=-Zm(i); Bm(i,2)=1; Br(i,1)=-Zr(i); Br(i,2)=1;  
end
```

```

Yl=Yl';
Ym=Ym';
Yr=Yr';
al=(Bl'*Bl)^-1*Bl'*Yl;
am=(Bm'*Bm)^-1*Bm'*Ym;
ar=(Br'*Br)^-1*Br'*Yr;
a=alfa*al(1)+beta*am(1)+gama*ar(1);
tahminroll=Tahmin_Xl(:,end);
tahminrolm=Tahmin_Xm(:,end);
tahminrolr=Tahmin_Xr(:,end);
for i=2:nn
pel(i)=(abs(Tahmin_Xl(i)-Xv(i,1))/Xv(i,1));
pem(i)=(abs(Tahmin_Xm(i)-Xv(i,2))/Xv(i,2));
per(i)=(abs(Tahmin_Xr(i)-Xv(i,3))/Xv(i,3));
end
    mapel=mean(apel);
    mapem=mean(apem);
    maper=mean(aper);
end

```

EK C : ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

GA-ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

```
function o = GA_testmin(x)
Xv=[29476.93000000000,32113.6937500000,36626.77000000000;
....
29712.41000000000,32314.4512500000,36543.46000000000];
nn=length(Xv);
w=9;
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=x(:,6);
xl=Xv(:,1);
xm=Xv(:,2);
xr=Xv(:,3);
toplaml=0;
toplamm=0;
toplamr=0;
for i=1:nn-1-w
    Yl(i)=xl(i+1);
    Ym(i)=xm(i+1);
    Yr(i)=xr(i+1);
end
for i=1:nn-w
    X1l(i)=xl(i)+toplaml;
    toplaml=X1l(i);
    X1m(i)=xm(i)+toplamm;
    toplamm=X1m(i);
    X1r(i)=xr(i)+toplamr;
    toplamr=X1r(i);
end
for i=2:nn-w
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
```

```

Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);
Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
end
Zl(1)=[];
Zm(1)=[];
Zr(1)=[];
for i=1:nn-1-w
    Bl(i,1)=-Zl(i); Bl(i,2)=1; Bm(i,1)=-Zm(i); Bm(i,2)=1; Br(i,1)=-Zr(i); Br(i,2)=1;
end
Yl=Yl';
Ym=Ym';
Yr=Yr';
al=(Bl'*Bl)^-1*Bl'*Yl;
am=(Bm'*Bm)^-1*Bm'*Ym;
ar=(Br'*Br)^-1*Br'*Yr;
aa=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1);
Tahmin_Xl(2)=Tahmin_X1l(2)-(X1l(1));
    Tahmin_Xm(2)=Tahmin_X1m(2)-(X1m(1));
    Tahmin_Xr(2)=Tahmin_X1r(2)-(X1r(1));
for i=3:nn
    Tahmin_Xl(i)=Tahmin_X1l(i)-Tahmin_X1l(i-1);
    Tahmin_Xm(i)=Tahmin_X1m(i)-Tahmin_X1m(i-1);
    Tahmin_Xr(i)=Tahmin_X1r(i)-Tahmin_X1r(i-1);
end
tahminroll=Tahmin_Xl(:,end);
tahminrolm=Tahmin_Xm(:,end);
tahminrolr=Tahmin_Xr(:,end);
for i=2:nn
    pel(i)=(abs(Tahmin_Xl(i)-Xv(i,1)))/Xv(i,1));
    pem(i)=(abs(Tahmin_Xm(i)-Xv(i,2)))/Xv(i,2));
    per(i)=(abs(Tahmin_Xr(i)-Xv(i,3)))/Xv(i,3));
end
mapel=mean(apel);
mapem=mean(apem);

```

```

    maper=mean(aper);
end

```

PSO-ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

```

function o = PSO_test21(x)

```

```

Xv=[37269.25000000000,39209.33600000000,40588.05000000000;

```

```

    ....

```

```

    37162.33000000000,38846.11000000000,39783.06000000000];

```

```

nn=length(Xv);

```

```

lambdal=x(:,1);

```

```

lambdam=x(:,2);

```

```

lambdar=x(:,3);

```

```

alfa=x(:,4);

```

```

gama=x(:,5);

```

```

beta=1-alfa-gama;

```

```

w=9;

```

```

lambdal=x(:,1);

```

```

lambdam=x(:,2);

```

```

lambdar=x(:,3);

```

```

alfa=x(:,4);

```

```

gama=x(:,5);

```

```

beta=1-alfa-gama;

```

```

xl=Xv(:,1);

```

```

xm=Xv(:,2);

```

```

xr=Xv(:,3);

```

```

toplaml=0;

```

```

toplamm=0;

```

```

toplamr=0;

```

```

for i=1:nn-1-w

```

```

    Yl(i)=xl(i+1);

```

```

    Ym(i)=xm(i+1);

```

```

    Yr(i)=xr(i+1);

```

```

end

```

```

for i=1:nn-w

```

```

    X1l(i)=xl(i)+toplaml;

```

```

    toplaml=X1l(i);
    X1m(i)=xm(i)+toplamm;
    toplamm=X1m(i);
    X1r(i)=xr(i)+toplamr;
    toplamr=X1r(i);
end
for i=2:nn-w
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
    Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);
    Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
end
Zl(1)=[];
Zm(1)=[];
Zr(1)=[];
for i=1:nn-1-w
    Bl(i,1)=-Zl(i);
    Bl(i,2)=1;
    Bm(i,1)=-Zm(i);
    Bm(i,2)=1;
    Br(i,1)=-Zr(i);
    Br(i,2)=1;
end
Yl=Yl';
Ym=Ym';
Yr=Yr';
al=(Bl'*Bl)^-1*Bl'*Yl;
am=(Bm'*Bm)^-1*Bm'*Ym;
ar=(Br'*Br)^-1*Br'*Yr;
aa=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1);
Tahmin_Xl(2)=Tahmin_X1l(2)-(X1l(1));
Tahmin_Xm(2)=Tahmin_X1m(2)-(X1m(1));
Tahmin_Xr(2)=Tahmin_X1r(2)-(X1r(1));
for i=3:nn
    Tahmin_Xl(i)=Tahmin_X1l(i)-Tahmin_X1l(i-1);

```

```

    Tahmin_Xm(i)=Tahmin_X1m(i)-Tahmin_X1m(i-1);
    Tahmin_Xr(i)=Tahmin_X1r(i)-Tahmin_X1r(i-1);
end
tahminroll=Tahmin_Xl(:,end);
tahminrolm=Tahmin_Xm(:,end);
tahminrolr=Tahmin_Xr(:,end);
for i=2:nn
    pel(i)=(abs(Tahmin_Xl(i)-Xv(i,1))/Xv(i,1));
    pem(i)=(abs(Tahmin_Xm(i)-Xv(i,2))/Xv(i,2));
    per(i)=(abs(Tahmin_Xr(i)-Xv(i,3))/Xv(i,3));
end
    mapel=mean(apel);
    mapem=mean(apem);
    maper=mean(aper);
end
end

```

GIOA-ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

Anadosya.m dosyası

```

SearchAgents_no=80;
Function_name="";
Max_iteration=100;
[lb,ub,dim,fobj]=Get_Functions_details(Function_name);
[Best_score,Best_pos,cg_curve]=MFO(SearchAgents_no,Max_iteration,lb,ub,dim,fobj);
Get_Functions_details.m
function [lb,ub,dim,fobj] = Get_Functions_details(F)
end
end

```

Get_Functions_details.m dosyası

```

function o = TFGM1(x)
Xv=[29476.9300000000,32113.6937500000,36626.7700000000;
...
29712.4100000000,32314.4512500000,36543.4600000000];
nn=length(Xv);

```

```

w=9;
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
xl=Xv(:,1);
xm=Xv(:,2);
xr=Xv(:,3);
toplaml=0;
toplamm=0;
toplamr=0;
for i=1:nn-1-w
    Yl(i)=xl(i+1);
    Ym(i)=xm(i+1);
    Yr(i)=xr(i+1);
end
for i=1:nn-w
    X1l(i)=xl(i)+toplaml;
    toplaml=X1l(i);
    X1m(i)=xm(i)+toplamm;
    toplamm=X1m(i);
    X1r(i)=xr(i)+toplamr;
    toplamr=X1r(i);
end
for i=2:nn-w
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
    Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);

```

```

    Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
end
Zl(1)=[];Zm(1)=[];Zr(1)=[];
for i=1:nn-1-w
    Bl(i,1)=-Zl(i);Bl(i,2)=1;Bm(i,1)=-Zm(i);Bm(i,2)=1;Br(i,1)=-Zr(i); Br(i,2)=1;
end
Yl=Yl';Ym=Ym';Yr=Yr';
al=(Bl'*Bl)^-1*Bl'*Yl;
am=(Bm'*Bm)^-1*Bm'*Ym;
ar=(Br'*Br)^-1*Br'*Yr;
aa=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1);
Tahmin_Xl(2)=Tahmin_X1l(2)-(X1l(1));
Tahmin_Xm(2)=Tahmin_X1m(2)-(X1m(1));
Tahmin_Xr(2)=Tahmin_X1r(2)-(X1r(1));
for i=3:nn
    Tahmin_Xl(i)=Tahmin_X1l(i)-Tahmin_X1l(i-1);
    Tahmin_Xm(i)=Tahmin_X1m(i)-Tahmin_X1m(i-1);
    Tahmin_Xr(i)=Tahmin_X1r(i)-Tahmin_X1r(i-1);
end
tahminroll=Tahmin_Xl(:,end);
tahminrolm=Tahmin_Xm(:,end);
tahminrolr=Tahmin_Xr(:,end);
for i=2:nn pel(i)=(abs(Tahmin_Xl(i)-Xv(i,1))/Xv(i,1));
pem(i)=(abs(Tahmin_Xm(i)-Xv(i,2))/Xv(i,2));
per(i)=(abs(Tahmin_Xr(i)-Xv(i,3))/Xv(i,3));
end
mapel=mean(apel);
mapem=mean(apem);
maper=mean(aper);
else
    o=1000;
end
end
end

```



EK D : Yuvarlanma mekanizmalı ÜBGM(1,1) MATLAB kodları

Xv=[];%gerçek veriyi buraya ata

fgrol_sbt_tahmin.m

function [Tahmin_Xl, Tahmin_Xm, Tahmin_Xr,tahminroll,tahminrolm,tahminrolr]
= fgrol_sbt_tahmin(Xv,lambdal,lambdam,lambdar,alfa,beta,gama)

nn=length(Xv);

xl=Xv(:,1);

xm=Xv(:,2);

xr=Xv(:,3);

toplaml=0;

toplamm=0;

toplamr=0;

for i=1:nn-1

 Yl(i)=xl(i+1);

 Ym(i)=xm(i+1);

 Yr(i)=xr(i+1);

end

for i=1:nn

 X1l(i)=xl(i)+toplaml;

 toplaml=X1l(i);

 X1m(i)=xm(i)+toplamm;

 toplamm=X1m(i);

 X1r(i)=xr(i)+toplamr;

 toplamr=X1r(i);

end

for i=2:nn

 Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);

 Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);

 Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);

end

Zl(1)=[];

Zm(1)=[];

Zr(1)=[];

for i=1:nn-1

Bl(i,1)=-Zl(i); Bl(i,2)=1; Bm(i,1)=-Zm(i); Bm(i,2)=1; Br(i,1)=-Zr(i); Br(i,2)=1;

```

end
Yl=Yl'; Ym=Ym'; Yr=Yr';
al=(Bl'*Bl)^-1*Bl'*Yl; am=(Bm'*Bm)^-1*Bm'*Ym; ar=(Br'*Br)^-1*Br'*Yr;
a=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1);
tahminroll=Tahmin_Xl(:,end);
tahminrolm=Tahmin_Xm(:,end);
tahminrolr=Tahmin_Xr(:,end);

fgrol_sbt_mape_test_tahmin.m
function[tahmin,apel,gercek,mapel,mapem,maper,hata_mape,Xvt]=fgrol_sbt_mape_t
est_tahmin(Xv,k,w,lambdal,lambdam,lambdar,alfa,beta,gama)
[nn,~]=size(Xv);
Xvt=Xv;
for i=1:nn-k
    [~,~,~,tahminroll,tahminrolm,tahminrolr]=fgrol_sbt_tahmin(Xvt(i:i+k-
1,:),lambdal,lambdam,lambdar,alfa,beta,gama);
    tahmin(i,1)=tahminroll;
    tahmin(i,2)=tahminrolm;
    tahmin(i,3)=tahminrolr;
    pel(i)=(abs(tahmin(i,1)-gercek(i,1))/gercek(i,1));
    pem(i)=(abs(tahmin(i,2)-gercek(i,2))/gercek(i,2));
    per(i)=(abs(tahmin(i,3)-gercek(i,3))/gercek(i,3));
end
mapel=mean(apel);
mapem=mean(apem);
maper=mean(aper);
end

```

EK E : Yuvarlanma mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

GA- Yuvarlanma mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

TFGM1rol_GA_test_tahmin.m dosyası

function o=TFGM1rol_GA_test_tahmin(x)

Xv_gercek=[29476.9300000000,32113.6937500000,36626.7700000000;

.....

29712.4100000000,32314.4512500000,36543.4600000000];

Xv=[29476.9300000000,32113.6937500000,36626.7700000000;

.....

29712.4100000000,32314.4512500000,36543.4600000000];

w=6; k=5;

lambdal=x(:,1);

lambdam=x(:,2);

lambdar=x(:,3);

alfa=x(:,4);

gama=x(:,5);

beta=x(:,6);

[nn,~]=size(Xv_gercek);

for j=1:nn-k

xl=Xvt(:,1);

xm=Xvt(:,2);

xr=Xvt(:,3);

toplaml=0;

toplamm=0;

toplamr=0;

for i=1:k-1

Yl(i)=xl(i+1);

Ym(i)=xm(i+1);

Yr(i)=xr(i+1);

end

for i=1:k

X1l(i)=xl(i)+toplaml;

toplaml=X1l(i);

```

    X1m(i)=xm(i)+toplamm;
    toplamm=X1m(i);
    X1r(i)=xr(i)+toplamr;
    toplamr=X1r(i);
end
for i=2:k
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
    Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);
    Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
end
Zl(1)=[];
Zm(1)=[];
Zr(1)=[];
for i=1:k-1
    Bl(i,1)=-Zl(i);
    Bl(i,2)=1;
    Bm(i,1)=-Zm(i);
    Bm(i,2)=1;
    Br(i,1)=-Zr(i);
    Br(i,2)=1;
end
Ylt=Yl';
Ymt=Ym';
Yrt=Yr';
al=(Bl'*Bl)^-1*Bl'*Ylt;
am=(Bm'*Bm)^-1*Bm'*Ymt;
ar=(Br'*Br)^-1*Br'*Yrt;
a=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1);
    Tahmin_Xl(2)=Tahmin_X1l(2)-(X1l(1));
    Tahmin_Xm(2)=Tahmin_X1m(2)-(X1m(1));
    Tahmin_Xr(2)=Tahmin_X1r(2)-(X1r(1));
tahminroll(j)=Tahmin_Xl(:,end);
tahminrolm(j)=Tahmin_Xm(:,end);
tahminrolr(j)=Tahmin_Xr(:,end);

```

```

tahmin(j,1)=tahminroll(j);
tahmin(j,2)=tahminrolm(j);
tahmin(j,3)=tahminrolr(j);
pel(j)=(abs(tahmin(j,1)-gercek(j,1))/gercek(j,1));
pem(j)=(abs(tahmin(j,2)-gercek(j,2))/gercek(j,2));
per(j)=(abs(tahmin(j,3)-gercek(j,3))/gercek(j,3));
end
mapel=mean(pel(nn-w+1-k:nn-k));
mapem=mean(pem(nn-w+1-k:nn-k));
maper=mean(per(nn-w+1-k:nn-k));
end

```

PSO- Yuvarlanma mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

```

function o=TFGM1rol_PSO_test_tahmin(x)
Xv_gercek=[29476.9300000000,32113.6937500000,36626.7700000000;
29901.9200000000,32394.8875000000,37034.6300000000;
.....
29712.4100000000,32314.4512500000,36543.4600000000];
w=9; k=5;
[nn,~]=size(Xv_gercek);
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
Xv=[29476.9300000000,32113.6937500000,36626.7700000000;
29901.9200000000,32394.8875000000,37034.6300000000;
.....
29712.4100000000,32314.4512500000,36543.4600000000];
[nn,~]=size(Xv_gercek);
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);

```

```

alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
xl=Xvt(:,1);
xm=Xvt(:,2);
xr=Xvt(:,3);
toplaml=0;
toplamm=0;
toplamr=0;
for i=1:k-1
    Yl(i)=xl(i+1);
    Ym(i)=xm(i+1);
    Yr(i)=xr(i+1);
end
for i=1:k
    X1l(i)=xl(i)+toplaml;
    toplaml=X1l(i);
    X1m(i)=xm(i)+toplamm;
    toplamm=X1m(i);
    X1r(i)=xr(i)+toplamr;
    toplamr=X1r(i);
end
for i=2:k
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
    Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);
    Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
end
Zl(1)=[]; Zm(1)=[]; Zr(1)=[];
for i=1:k-1
    Bl(i,1)=-Zl(i);
    Bl(i,2)=1;
    Bm(i,1)=-Zm(i);
    Bm(i,2)=1;
    Br(i,1)=-Zr(i);
    Br(i,2)=1;

```

```

end
Ylt=Yl'; Ymt=Ym'; Yrt=Yr';
al=inv(Bl'*Bl)*(Bl'*Ylt);
am=inv(Bm'*Bm)*(Bm'*Ymt);
ar=inv(Br'*Br)*(Br'*Yrt);
a=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1)
    Tahmin_Xl(2)=Tahmin_X1l(2)-(X1l(1));
    Tahmin_Xm(2)=Tahmin_X1m(2)-(X1m(1));
    Tahmin_Xr(2)=Tahmin_X1r(2)-(X1r(1));
tahminroll(j)=Tahmin_Xl(:,end);
tahminrolm(j)=Tahmin_Xm(:,end);
tahminrolr(j)=Tahmin_Xr(:,end);
tahmin(j,1)=tahminroll(j);
tahmin(j,2)=tahminrolm(j);
tahmin(j,3)=tahminrolr(j);
    pel(j)=(abs(tahmin(j,1)-gercek(j,1))/gercek(j,1));
    pem(j)=(abs(tahmin(j,2)-gercek(j,2))/gercek(j,2));
    per(j)=(abs(tahmin(j,3)-gercek(j,3))/gercek(j,3));
end
mapel=mean(pel(nn-w+1-k:nn-k));
mapem=mean(pem(nn-w+1-k:nn-k));
maper=mean(per(nn-w+1-k:nn-k));
        else
            o=1000;
        end
end
end

```

GIOA- Yuvarlanma mekanizmalı ÜBGM(1,1) Parametre Optimizasyonu MATLAB kodları

```

function [lb,ub,dim,fobj] = Get_Functions_details(F)
    lb=[0 0 0 0 0];
    ub=[1 1 1 0.5 0.5];
    dim=5;
    case"

```

```

        lb=[0 0 0 0 0];
        ub=[1 1 1 0.5 0.5];
        dim=5;
end
end

ana.m dosya
function o=TFGM1rol_test(x)
Xv=[29476.93000000000,32113.6937500000,36626.77000000000;
    ....
    29712.41000000000,32314.4512500000,36543.46000000000];
k=4; w=9;
[nn,~]=size(Xv);
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
[nn,~]=size(Xv);
k=4;
w=9;
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
xl=Xvt(:,1);
xm=Xvt(:,2);
xr=Xvt(:,3);
toplaml=0;
toplamm=0;
toplamr=0;
for i=1:k-1

```

```

        Yl(i)=xl(i+1);
        Ym(i)=xm(i+1);
        Yr(i)=xr(i+1);
    end
    for i=1:k
        X1l(i)=xl(i)+toplaml;
        toplaml=X1l(i);
        X1m(i)=xm(i)+toplamm;
        toplamm=X1m(i);
        X1r(i)=xr(i)+toplamr;
        toplamr=X1r(i);
    end
    for i=2:k
        Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
        Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);
        Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
    end
    Zl(1)=[];
    Zm(1)=[];
    Zr(1)=[];
    for i=1:k-1
        Bl(i,1)=-Zl(i);
        Bl(i,2)=1;
        Bm(i,1)=-Zm(i);
        Bm(i,2)=1;
        Br(i,1)=-Zr(i);
        Br(i,2)=1;
    end
    Ylt=Yl';
    Ymt=Ym';
    Yrt=Yr';
    al=(Bl'*Bl)^-1*Bl'*Ylt;
    am=(Bm'*Bm)^-1*Bm'*Ymt;
    ar=(Br'*Br)^-1*Br'*Yrt;
    a=alfa*al(1)+beta*am(1)+gama*ar(1);

```

```

e=exp(1);
    Tahmin_Xl(2)=Tahmin_Xl(2)-(Xl(1));
    Tahmin_Xm(2)=Tahmin_Xm(2)-(Xm(1));
    Tahmin_Xr(2)=Tahmin_Xr(2)-(Xr(1));
tahminroll(j)=Tahmin_Xl(:,end);
tahminrolm(j)=Tahmin_Xm(:,end);
tahminrolr(j)=Tahmin_Xr(:,end);
tahmin(j,1)=tahminroll(j);
tahmin(j,2)=tahminrolm(j);
tahmin(j,3)=tahminrolr(j);
end
    mapel=mean(pel(nn-w+1-k:nn-k));
    mapem=mean(pem(nn-w+1-k:nn-k));
    maper=mean(per(nn-w+1-k:nn-k));
        else
            o=1000;
        end
end

function o=TFGM1rol_test_tahmin(x)
Xv_gercek=[29476.9300000000,32113.6937500000,36626.7700000000;
....;
    29712.4100000000,32314.4512500000,36543.4600000000];
w=9; k=5;
[nn,~]=size(Xv_gercek);
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
Xv=[29476.9300000000,32113.6937500000,36626.7700000000;
    29901.9200000000,32394.8875000000,37034.6300000000;
    ....
    29712.4100000000,32314.4512500000,36543.4600000000];

```

```

[nn,~]=size(Xv_gercek);
lambdal=x(:,1);
lambdam=x(:,2);
lambdar=x(:,3);
alfa=x(:,4);
gama=x(:,5);
beta=1-alfa-gama;
xl=Xvt(:,1);
xm=Xvt(:,2);
xr=Xvt(:,3);
toplaml=0;
toplamm=0;
toplamr=0;
for i=1:k-1
    Yl(i)=xl(i+1);
    Ym(i)=xm(i+1);
    Yr(i)=xr(i+1);
end
for i=1:k
    X1l(i)=xl(i)+toplaml;
    toplaml=X1l(i);
    X1m(i)=xm(i)+toplamm;
    toplamm=X1m(i);
    X1r(i)=xr(i)+toplamr;
    toplamr=X1r(i);
end
for i=2:k
    Zl(i)=lambdal*X1l(i)+(1-lambdal)*X1l(i-1);
    Zm(i)=lambdam*X1m(i)+(1-lambdam)*X1m(i-1);
    Zr(i)=lambdar*X1r(i)+(1-lambdar)*X1r(i-1);
end
Zl(1)=[]; Zm(1)=[]; Zr(1)=[];
for i=1:k-1
    Bl(i,1)=-Zl(i);
    Bl(i,2)=1;

```

```

    Bm(i,1)=-Zm(i);
    Bm(i,2)=1;
    Br(i,1)=-Zr(i);
    Br(i,2)=1;
end
Ylt=Yl';
Ymt=Ym';
Yrt=Yr';
al=inv(Bl'*Bl)*(Bl'*Ylt);
am=inv(Bm'*Bm)*(Bm'*Ymt);
ar=inv(Br'*Br)*(Br'*Yrt);
a=alfa*al(1)+beta*am(1)+gama*ar(1);
e=exp(1);
Tahmin_Xl(2)=Tahmin_Xl(2)-(Xl(1));
Tahmin_Xm(2)=Tahmin_Xm(2)-(Xm(1));
Tahmin_Xr(2)=Tahmin_Xr(2)-(Xr(1));
tahminroll(j)=Tahmin_Xl(:,end);
tahminrolm(j)=Tahmin_Xm(:,end);
tahminrolr(j)=Tahmin_Xr(:,end);
tahmin(j,1)=tahminroll(j);
tahmin(j,2)=tahminrolm(j);
tahmin(j,3)=tahminrolr(j);
    pel(j)=(abs(tahmin(j,1)-gercek(j,1))/gercek(j,1));
    pem(j)=(abs(tahmin(j,2)-gercek(j,2))/gercek(j,2));
    per(j)=(abs(tahmin(j,3)-gercek(j,3))/gercek(j,3));
end
mapel=mean(pel(nn-w+1-k:nn-k));
mapem=mean(pem(nn-w+1-k:nn-k));
maper=mean(per(nn-w+1-k:nn-k));
        else
            o=1000;
        end
end
end

```

ÖZGEÇMİŞ

Ad-Soyad : Ceyda TANYOLAÇ BİLGİÇ

ÖĞRENİM DURUMU:

- **Lisans** : 2008, İstanbul Üniversitesi, İşletme Fakültesi, İşletme Bölümü
- **Yüksek lisans** : 2012, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Tanyolaç Bilgiç, C.**, Bilgiç, B. ve Çebi, F. (2022). Fuzzy Grey Forecasting Model optimized by Moth-Flame Optimization Algorithm for short time electricity consumption, *Journal of Intelligence and Fuzzy Systems*. 42 (1), 129-138. DOI: 10.3233/JIFS-219181.

