

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**HİBRİT ALGORİTMA KULLANARAK ELEKTRİK
ENERJİ TÜKETİM MODELİNİN OLUŞTURULMASI
VE KESTİRİMİ: UGANDA ÖRNEĞİ**

DOKTORA TEZİ

Abdal KASULE

**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**
Tez Danışmanı : Doç. Dr. Kürşat AYAN

Ekim 2018

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ


**HİBRİT ALGORİTMA KULLANARAK ELEKTRİK
ENERJİ TÜKETİM MODELİNİN OLUŞTURULMASI
VE KESTİRİMİ: UGANDA ÖRNEĞİ**

DOKTORA TEZİ

Abdal KASULE

Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ

Bu tez 19 / 10 /2018 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.


Prof. Dr.
Uğur ARİFOĞLU
Jüri Başkanı


Prof. Dr.
Ali ÖZTÜRK
Üye


Doç. Dr.
Kürşat AYAN
Üye


Doç. Dr.
Yılmaz UYAROĞLU
Üye


Dr. Öğr. Üyesi
Murat İSKEFİYELİ
Üye

BEYAN

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

Abdal KASULE

08/10/2018

TEŞEKKÜR

Doktora eğitimim boyunca değerli deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, çalışmaların planlanmasından yazılmasına kadar tüm aşamalarında değerli zamanını ayıran, ayrıca makalelerin yapılandırılma çalışmalarında ve yayınlama aşamasında yol göstericilik yapan, teşvik eden, değerli danışman hocam Doç. Dr. Kürşat AYAN'a teşekkürlerimi sunarım.

Tez izleme komitesinde bulunan değerli hocalarım Prof. Dr. Uğur ARİFOĞLU ve Dr. Öğr. Üyesi. Murat İSKEFİYELİ'ye tez çalışmam süresinde şahsıma karşı göstermiş oldukları yakın desteğin yanında bu süreçteki yapıcı ve yönlendirici katkılarından dolayı teşekkür ederim.

Doktora çalışmalarım sırasında tükenmez sabrı, desteği, motivasyonu ile maddi ve manevi her türlü desteğini esirgemeyen aileme ve arkadaşlarıma teşekkürü bir borç bilirim. Değerli Türk dili öğretmenlerim Öğr. Gör. Özlem Yahşi CEVHER ve Öğr. Gör. Dr. Engin ÖMEROĞLU'na teşekkürlerimi ifade etmeliyim. Ayrıca çok değerli arkadaşım Abdulkadir KARDEŞ'e doktora çalışmam süresince bana verdiği motivasyondan dolayı teşekkür ediyorum.

Son olarak, doktora çalışmam süresince verdikleri burs desteği nedeniyle Yurtdışı Türkler Başkanlığı'na teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	i
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	ix
TABLOLAR LİSTESİ.....	xi
ÖZET	xii
SUMMARY	xiii
BÖLÜM 1.	
GİRİŞ	1
1.1. Giriş	1
1.2. Tezin Amacı	4
1.3. Araştırma Soruları	6
1.4. Tezin Katkıları.....	7
1.5. Tez Organizasyonu	7
1.6. Yayın Listesi.....	8
BÖLÜM 2.	
ELEKTRİK ENERJİ TÜKETİMİ TAHMİNİ	9
2.1. Enerji Modelleme Kavramları	12
2.2. Enerji Talep Tahmin Yöntemleri.....	13
2.2.1. Parametrik ve istatistiksel yöntemler	15
2.2.1.1. Eğilim analizi	15
2.2.1.2. Nihai kullanım yöntemleri.....	15
2.2.1.3. Ekonometrik yaklaşım.....	16
2.2.1.4. Zaman serileri yaklaşımı	17
2.2.1.5. Regresyon yaklaşımı	18

2.2.2. Yapay ve hesaplamalı zekâ yaklaşımları.....	19
2.2.2.1. Makine öğrenmesi yöntemleri.....	20
2.2.2.2. Bilgi tabanlı yöntemler.....	22
2.2.2.3. Belirsizlik yöntemleri.....	23
2.2.2.4. Sezgisel yöntemler.....	24
2.2.3. Matematiksel programlama yöntemleri.....	26
2.2.4. Hibrit yöntemler.....	27
2.2.5. İstatistiksel ve hesaplamalı zeka tahmin yöntemlerinin karşılaştırılması.....	27
2.3. Veri Seti.....	28
2.3.1. Araştırmada kullanılan değişkenlerin ön analizi.....	34
2.3.2. Bağımsız değişkenlerin tahmini.....	37
2.4. Modellerin Tahmin Yeteneğini Değerlendirme Metrikleri.....	38
 BÖLÜM 3.	
PSO-YAK HİBRİT ALGORİTMASINI KULLANARAK TAHMİN.....	40
3.1. Kestirim Modelleri.....	40
3.2. Kaynak Araştırması.....	43
3.3. Optimizasyon Algoritmaları.....	44
3.3.1. Parçacık sürüşü optimizasyonu (PSO).....	45
3.3.2. Yapay arı kolonisi (YAK) algoritması.....	47
3.4. Hibrit PSO-YAK Algoritmaları.....	49
3.4.1. PSO ve YAK'ya dayalı hibrit algoritma.....	49
3.5. Önerilen Yaklaşımın Probleme Uygulanması.....	51
3.6. Sonuçlar.....	53
 BÖLÜM 4.	
HİBRİT PSO-ANFİS VE GA-ANFİS KULLANARAK TAHMİN.....	58
4.1. ANFİS'in Teorik Altyapısı.....	58
4.2. Kaynak Araştırması.....	67
4.3. Uzun Süreli Elektrik Tüketimi Tahmini İçin ANFİS Modeli.....	69
4.4. Genetik Algoritma.....	71

4.5. PSO ve GA ile ANFIS Eğitimi.....	72
4.6. Sonuçlar	74
BÖLÜM 5.	
TAHMİN MODELLERİNİN BİRLEŞTİRİLMESİ.....	80
5.1. Giriş	80
5.2. Modellerin Birleştirmesi.....	81
BÖLÜM 6.	
SONUÇLAR VE ÖNERİLER.....	85
6.1. Sonuçlar	85
6.2. Öneriler.....	88
KAYNAKLAR	90
ÖZGEÇMİŞ	101

SİMGELER VE KISALTMALAR LİSTESİ

ABA	: Ateş Böceği Algoritması
ABA-MA	: Memetik Algoritma Tabanlı Ateş Böceği Algoritması
ABD \$	: Amerika Bileşik Devletleri doları
AGO	: Accumulated Generating Operation (Birleşik Üretim İşlemi)
AIC	: Akaike Information Criteria (Akaike Bilgi Kriteri)
AIM	: Abductive Inference Modelling (Dışaçekimsel Çıkarım Modellemesi)
ALO	: Ant Lion Optimizer (Cesur Karınca Optimize Edici Algoritması)
AN	: Abductive Networks (Dışaçekimsel Ağları)
ANFIS	: Adaptive Neural Fuzzy Inference System (Adaptif sinirsel bulanık çıkarım sistemi)
ANOVA	: Analysis of Variance (Varyans Analizi)
API	: Application Programming Interface (Uygulama programlama arayüzü)
AR	: Autoregressive (Oto regresif)
ARCH	: Autoregressive Conditional Heteroscedasticity (Oto regresif Koşullu Heterosikliksellik)
ARDL	: Autoregressive Distributed Lag (Oto regresif Dağılımlı Gecikme)
ARIMA	: Autoregressive Integrated Moving Average (Oto regresif entegre hareketli ortalama)
ARMA	: Autoregressive Moving Average (Oto regresif Hareketli Ortalama)
ARMAX	: ARMA with eXogeneous variable (Eksojen Girişli Oto regresif Hareketli Ortalama)
BIC	: Bayes Information Criteria (Bayes Bilgilendirme Kriteri)
BT	: Benzetimli Tavlama
BVAR	: Bayes Vector Autoregression (Bayes vektör oto regresyon)
ÇDR	: Çoklu Doğrusal Regresyon

CLPSO-MA	: Comprehensive learning particle swarm optimization based memetic algorithm (Kapsamlı öğrenme parçacık sürüşü optimizasyon tabanlı memetik algoritma)
CV	: Cross Validation (Çapraz Doğrulama)
DE	: Diferansiyel Evrim
DFR	: Demand Forecast Report (Talep Tahmin Raporu)
DR	: Doğrusal Regresyon
EA	: Evrimsel Algoritma
ECM	: Error Correction Model (Hata Düzeltme Modeli)
EPM	: Enerji Planlama Modelleri
ERA	: Electricity Regulatory Authority (Elektrik Düzenleme Kurumu)
FCM	: Fuzzy C-means (bulanık c-yöntem)
FHCNN	: Fuzzy Hyper-rectangular Composite Neural Network (Bulanık hiper dikdörtgen sinir ağı kompozisyonu)
FIS	: Fuzzy Inference Sistem/Engine (Bulanık çıkarım motoru),
FNN	: Fuzzy Neural Network (Bulanık sinir ağı),
GA	: Genetik Algoritma
GARCH	: Generalized Autoregressive Conditional Heteroskedasticity (Genelleştirilmiş Otoregresif Koşullu Heteroskedastisite)
GKO	: Guguk Kuşu Optimizasyonu
GM	: Gri Modeleme (Grey Modelling)
GP	: Genetik Programlama
GSMG	: Gayri Safi Milli Gelir
GSMH	: Gayri Safi Milli Hasıla
GSYİH	: Gayri Safi Yurt İçi Hasıla
GT	: Gri Teori
GWh	: Giga Watt hour
GY	: Geri Yayılım algoritması
HS	: Harmony Search (Uyum araştırması)
HSA	: Harmony Search Algorithm (Harmoni Arama Algoritması)
HyFIS	: Hybrid Fuzzy Inference System (Hibrit Bulanık Çıkarım Sistemi)
IA	: Immune Algorithm (Bağışıklık Algoritması),

IAGO	: Inverse Accumulated Generating Operation (Ters Biriktirilmiş Üretim İşlemi)
KA	: Karar Ağaçları
KPSO	: Kaotik Parçacık Sürüsü Optimizasyonu
KKO	: Karınca Koloni Optimizasyonu
KKSO	: Kaotik Karınca Sürüsü Optimizasyonu
KP	: Karesel Programlama
kWh	: kilo Watt hour
LEAP	: Long-range Energy Alternatives Planning (Uzun Dönem Enerji Alternatifleri Planlama)
MA	: Moving Average (Hareketli Ortalama)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
MEMD	: Ministry of Energy and Mineral Development (Enerji ve Mineral Kalkınma Bakanlığı)
MF	: Membership Function (Üyelik Fonksiyonu)
MLP-LM	: Multi-layer Perceptron – Levenberg Marquardt (Çok katmanlı Algılayıcı - Levenberg Marquardt)
MP	: Matematiksel Programlama (Mathematical Programming)
MSE	: Mean Square Error (Ortalama karesel hata)
MSVR	: Multi-Output Support Vector Regression (Çok Çıkışlı Destek Vektör Regresyonu)
MW	: Mega Watt
MWh	: Mega Watt hour
NDP	: National Development Plan (Ulusal Kalkınma Planı)
NLP	: Non Linear Programming (Doğrusal Olmayan Programlama)
NLR	: Non Linear Regression (Doğrusal Olmayan Regresyon),
NPA	: National Planning Authority (Ulusal Planlama Müdürlüğü)
NPR	: Non Parametric Regression (Parametrik Olmayan Regresyon)
OLS	: Ordinary Least Squares (Basit En Küçük Kareler)
PAM	: Partial Adjustment Model (Kısmi Ayarlamalı Model)
PCM	: Polynomial Curve Model (Polinom Eğri Modeli)

PCMACP	: Polynomial Curve and Moving Average Combination Projection (Polinom Eğri ve Hareketli Ortalama Kombinasyon Projeksiyonu)
PLSR	: Partial Least Squares Regression (Kısmi en Küçük Kareler Regresyonu)
PSIP	: Power Sector Investment Plan (Enerji Sektörü Yatırım Planı)
PSO	: Parçacık Sürüşü Optimizasyonu
R^2	: Coefficient of determination (Belirleme Katsayısı)
RBFNN	: Radial Basis Function Neural Network (Radyal Temel Fonksiyon Sinir Ağı)
REA	: Rural Electrification Agency (Kırsal Elektrifikasyon Ajansı)
RESP	: Rural Electrification Strategy and Plan (Kırsal Elektrifikasyon Stratejisi ve Planı)
RMSE	: Root Mean Square Error (Ortalama karesel hatanın kökü)
SARIMA	: Seasonal Autoregressive Intergrated Moving Average (Mevsimsel Otoresif Entegre Hareketli Ortalama)
SR	: Stepwise Regression (Basamaklı Regresyon)
SSE	: Sum of Squared Errors (Karesel Hataların Toplamı)
STSM	: Structural Time Series Method (Yapısal Zaman Serileri Yöntemi)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
SVR	: Support Vector Regression (Destek Vektör Regresyon)
UBOS	: Uganda Bureau of Statistics (Uganda İstatistik Bürosu)
UEGCL	: Uganda Electricity Generation Company Limited (Uganda Elektrik Üretim Şirketi)
UGX	: Uganda Shilling (Uganda Şilini)
VAR	: Vector Autoregression (Vektör Otoresif)
VARIMA	: Vector ARIMA
YA	: Yerçekimi Arama algoritması
YAK	: Yapay Arı Kolonisi
YRM	: Yapısal Risk Minimizasyonu
YSA	: Yapay Sinir Ağı

ŞEKİLLER LİSTESİ

Şekil 2.1. Tahmin işlemine ilişkin genel işlemsel diyagram	10
Şekil 2.2. Enerji tüketiminin modellenmesi.....	12
Şekil 2.3. Elektrik tüketiminin nüfus ile değişimi	31
Şekil 2.4. Elektrik tüketiminin GSYİH ile değişimi	31
Şekil 2.5. Elektrik tüketiminin ihracat ile değişimi	32
Şekil 2.6. Elektrik tüketiminin ithalat ile değişimi	32
Şekil 2.7. Elektrik tüketiminin abone/tüketici sayısı ile değişimi.....	33
Şekil 2.8. Elektrik tüketiminin elektrik fiyatları ile değişimi	33
Şekil 2.9. Çok katmanlı algılayıcı sinir ağı.....	37
Şekil 3.1. PSO algoritmasının akış diyagramı.	46
Şekil 3.2. YAK algoritmasının akış diyagramı	48
Şekil 3.3. Hibrit PSO-YAK algoritmasının akış diyagramı.....	50
Şekil 3.4. Önerilen hibrit PSO-YAK yaklaşımının uygulaması	52
Şekil 3.5. Üstel model kullanarak gözlenen ve tahmin edilen değerlerin karşılaştırılması	54
Şekil 3.6. Karesel model kullanılarak Gözlenen ve tahmin edilen değerlerin karşılaştırılması	55
Şekil 3.7. Gerçek ve tahmin edilen elektrik tüketimi.....	57
Şekil 4.1. Üyelik fonksiyonları	60
Şekil 4.2. Bulanık çıkarım sistemi	61
Şekil 4.3. FCM algoritması	64
Şekil 4.4. Dört girişli ve bir çıkışlı ANFIS yapısı.....	65
Şekil 4.5. Elektrik tüketimi tahmini için ANFIS modeli	69
Şekil 4.6. ANFIS kuralları	70
Şekil 4.7. GA akış diyagramı	72

Şekil 4.8. Ana prosedürün sözde kodu.....	73
Şekil 4.9. Önerilen ANFIS yaklaşım uygulaması.....	73
Şekil 4.10. Eğitim veri setindeki PSO-ANFIS sonuç çıktıları.....	74
Şekil 4.11. Test veri setindeki PSO-ANFIS sonuç çıktıları.....	74
Şekil 4.12. Eğitim veri setindeki GA-ANFIS sonuç çıktıları	75
Şekil 4.13. Test veri setindeki GA-ANFIS sonuç çıktıları	75
Şekil 4.14. Eğitilmiş GA-ANFIS modeli	76
Şekil 4.15. Eğitilmiş PSO-ANFIS modeli	77
Şekil 4.16. Tahminlerin karşılaştırılması	79



TABLolar LİSTESİ

Tablo 1.1. MEMD tahminleri ile gerçek tüketimin karşılaştırılması.....	3
Tablo 2.1. Tüm veri seti	29
Tablo 2.2. Değişkenlerin yıllık ortalama artışı	30
Tablo 2.3. Değişkenlerin tanımlayıcı istatistik analizi.....	34
Tablo 2.4. Elektrik tüketimi ile bağımsız değişkenler arasındaki korelasyon katsayıları	36
Tablo 2.5. Elektrik tüketimi ile bağımsız değişkenler arasındaki regresyon analizi	36
Tablo 2.6. Bağımsız değişkenlerin tahmin değerleri	38
Tablo 2.7. Model değerlendirmesi için tipik MAPE değerleri	39
Tablo 3.1. Modeller için MAPE ve R^2 değerleri.....	54
Tablo 3.2. MEMD tahmin raporundan ve tahminlerimizden elektrik tüketim tahminleri.....	56
Tablo 3.3. Tahmin edilen değerlerin göreceli yüzde hataları	57
Tablo 4.1. ANFIS eğitiminden sonra RMSE ve MAPE değerleri.....	75
Tablo 4.2. GA-ANFIS giriş üyelik fonksiyon parametreleri	76
Tablo 4.3. GA-ANFIS çıkış üyelik fonksiyon parametreleri.....	76
Tablo 4.4. PSO-ANFIS giriş üyelik fonksiyon parametreleri.....	76
Tablo 4.5. PSO-ANFIS çıkış üyelik fonksiyon parametreleri	76
Tablo 4.6. Tahmin sonuçlarının ve MEMD tahmin raporunun karşılaştırılması.....	78
Tablo 4.7. Göreceli yüzde hataları	79
Tablo 5.1. ÇDR modelinin regresyon istatistikleri, katsayıları ve performans ölçüm değerleri.....	82
Tablo 5.2. MEMD, birleştirilmiş ve ÇDR tahminlerinin karşılaştırılması	83
Tablo 5.3. MEMD tahmini ve bu çalışma'nın tahmin modelleri arasındaki göreceli yüzde hatalarının karşılaştırılması	83

ÖZET

Anahtar Kelimeler: Elektrik tüketim tahmini, ANFIS, yapay arı kolonisi, parçacık sürüsü optimizasyonu, hibrit algoritma, genetik algoritma, tahmin aralıkları, Uganda.

Uzun vadeli elektrik tüketimi tahmini karar vericiler tarafından sistem genişletme planlaması konusunda karar vermek için kullanılır. Geçtiğimiz on yıl boyunca, elektrik tüketim tahminleri üzerine yapılan araştırmaların nokta tahminleri olarak sonuçları rapor edilmiştir. Özellikle uzun vadeli tahminler için nokta tahminleri çok fazla ilgi çekici değildir. Çünkü bunun sistem genişletme ile ilgili finansal riskinin, talep değişkenliğinin ve tahmin belirsizliğinin tahmin edilmesi için kullanılması güçtür.

Bu çalışmada ilk olarak, Uganda'nın net elektrik tüketimini modellemek için, tahmin modellerinde nüfusu, gayri safi yurtiçi hasılayı, abone sayısını ve ortalama elektrik fiyatını değişken olarak gözönüne almak suretiyle üstel, karesel ve Adaptif sinirsel bulanık çıkarım sistemi (ANFIS) formları kullanılmıştır. Parçacık Sürüsü Optimizasyonu (PSO) ve Yapay Arı Kolonisi (YAK) algoritmalarına dayalı bir hibrit algoritma kullanılarak üstel ve karesel tahmin modellerinin parametreleri optimize edilmiştir. ANFIS modelinin parametreleri ise, PSO ve Genetik Algoritma (GA) kullanılarak optimize edilmiştir.

İkinci olarak, %90 anlamlılık düzeyli alt ve üst hata sınırlarını elde etmek için basit doğrusal regresyonu kullanarak tahmin kalıntıları modellenmiştir. Uganda'nın 2040 yılına kadarki net elektrik tüketimine ilişkin tahmin aralıklarını oluşturmak için alt ve üst hata sınırları kullanılmıştır.

Son olarak, birleştirilmiş öngörme modeli elde etmek için bu dört yöntemle ilişkin dört model de birleştirilmiştir. Birleştirilmiş tahminlere göre, 2040 yılında Uganda'nın elektrik tüketiminin, yıllık ortalama %11,75 - %10,64'lük bir artışa işaretle [41,296 42,133] GWh arasında olacağı tahmin edilmiştir.

USING HYBRID ALGORITHM TO MODEL AND FORECAST ELECTRICITY CONSUMPTION: A CASE STUDY OF UGANDA

SUMMARY

Keywords: electricity consumption forecasting, ANFIS, artificial bee colony, particle swarm optimization, hybrid algorithm, genetic algorithm, prediction intervals, Uganda.

Long term electricity consumption forecasting is used by decision makers to make decisions regarding system expansion planning. Over the past decade, research on electricity consumption forecasting has reported results as point forecasts. Specifically for long-term forecasting, point forecasts are of little interest because it is hard to use them to assess the financial risk associated with system expansion versus demand variability and forecasting uncertainty. In this study, firstly we use power, quadratic and Adaptive Neuro Fuzzy Inference System (ANFIS) forms to model Uganda's net electricity consumption using population, gross domestic product, number of subscribers and average electricity price as variables in the forecasting models. We optimize the parameters of power and quadratic forecasting models using a hybrid algorithm based on particle swarm optimization (PSO) and artificial bee colony (ABC) algorithms. The parameters of ANFIS model are optimized using particle swarm optimization and genetic algorithm.

Secondly we model the forecast residuals using simple linear regression to obtain 90% significance level lower and upper error bounds. The lower and upper error bounds were used to construct prediction intervals for Uganda's net electricity consumption up to year 2040.

Finally we combine all the four models from the two methods to get a combined forecasting model. According to the combined forecast, in year 2040 Uganda's electricity consumption will be between [41,296 42,133] GWh indicating an annual average increase of 11.75%-10.64%.

BÖLÜM 1. GİRİŞ

1.1. Giriş

Uganda, Afrika'nın alt Sahra doğu kesiminde yer almaktadır. Doğuda Kenya, güneyde Tanzania ve Ruanda, batıda Demokratik Kongo Cumhuriyeti ve kuzeyde Güney Sudan tarafından sınırlanılmıştır. Uganda'da en çok kullanılan enerji kaynağı geleneksel biyokütle (odun ve odun kömürü) olup bu kaynak kullanılan toplam enerji kaynağının %88,8'ini oluşturur. Bu enerji kaynağı hem ısınma hem de beslenme amaçlı olarak kırsalda ve kentlerde kullanılmaktadır. Ağırlıklı olarak hidroelektrik (%77,6), termal (%15,2) ve küspe (%7,2) (Uganda Bureau of Statistics (Uganda İstatistik Bürosu (UBOS)), İstatistik Özeti 2016) kullanılarak üretilen elektrik enerjisi, tüketilen toplam enerjinin sadece %1,7'sini oluşturmaktadır. Uganda nüfusunun %40'ı kentlerde ve %7'si kırsalda olmak üzere toplamda sadece %20'si elektrik kullanma imkânına sahip olup kişi başına düşen elektrik tüketimi 80 kWh'dir (MEMD¹, 2015). Elektriğe olan bu sınırlı erişim imkânı, sosyal hizmetlerin sunulmasını ve küçük ölçekli sanayi ve ticari işletmelerin gelişimini kısıtlamakta olup aynı zamanda büyük ölçekli endüstriyel ve ticari yatırımların gerçekleştirilmesini de olumsuz yönde etkilemek gibi birçok açıdan sosyo-ekonomik gelişmeyi etkilemektedir. Uganda'daki düşük elektrik tüketiminin nedeni, yetersiz tedarik neticesinde gerekli talebi karşılamayan düşük üretim kapasitesine bağlanabilir. Ancak Uganda hükümeti, ülkede elektrik enerjisi tüketim problemini ele almak için yayınlamış olduğu dokümanlarda yeni enerji politika ve stratejilerini ortaya koymuştur. Bunları şu şekilde sıralayabiliriz:

1. Uganda Vizyon 2040² kapsamında 2040 yılında elektrik tüketim hedeflerini %80 olarak belirlemiştir.

¹ Uganda Enerji ve Mineral Kalkınma Bakanlığı (Uganda Ministry of Energy and Mineral Development)

² <http://npa.ug/wp-content/themes/npatheme/documents/vision2040.pdf> erişim tarihi: 3-Eylül-2016

2. Ulusal Kalkınma Planı (National Development Plan (NDP)) 2015/16–2019/20, 2020 yılında %30’a ulaşmak için elektrik tüketim hedefleri belirlemiştir.
3. 2013-2022 Kırsal Elektrifikasyon Stratejisi ve Planı (Rural Electrification Strategy and Plan (RESP), 2022 yılında kırsal alanlarda elektrik tüketimini %7’den %26’ya çıkarmak için bir hedef belirlemiştir.

Yukarıda belirtilen stratejilerin hedeflerine ulaşmak için, stratejilerin uygulanmasına rehberlik etmek amacıyla elektrik tüketim tahmin çalışmaları yapılmıştır. Uganda’da elektrik tüketim tahmini için yapılan ilk çalışma, Enerji Sektörü Yatırım Planı (Power Sector Investment Plan (PSIP)) idi. Bu planda elektrik talebi tahmini 2009-2030 dönemi için yapılmıştır. PSIP’nin amacı “Uganda’nın ekonomik gelişimini teşvik etme talebine dayanan yeterli ve güvenilir bir enerji sağlamaktır”. Uganda Vizyon 2040’da Uganda’nın 2040 yılında 41.738 MW’lık bir elektrik enerjisine ihtiyacı olacağı, böylece kişi başına elektrik tüketiminin 3.668 kWh’ye çıkacağı ve toplam nüfusun %80’lik kısmının elektrik enerjisi kullanacağı tahmin edilmektedir (NPA³, 2010). Hâlihazırda ulusal şebeke sadece ülkenin kentsel ve yarı kentsel bölgelerini kapsamakla birlikte nüfusun %80’i kırsal alanlarda yaşamaktadır. Kırsal elektrifikasyonun iyileştirilmesi amacıyla, 2001 yılında kırsal elektrik erişiminin sağlanması amacıyla, 2001 yılında %1’den 2012’de %10’a ve 2022’de de %22’ye (RESP 2001-2010) ulaşılması amacıyla Kırsal Elektrifikasyon Ajansı (Rural Electrification Agency (REA)) oluşturulmuştur. 2012 yılı tahmini %10’luk kırsal alan elektrifikasyon hedefinin ancak %7’sine ulaşılabilmiştir. Tahmin edilen hedeflere ulaşamadığından dolayı, Enerji Sektörü Yatırım Planı revize edilmiş ve 2015 Talep Tahmin Raporu (Demand Forecast Report (DFR)) yapılmıştır. DFR’nin amacı, karar vericilere Uganda’nın elektrik sektöründe planlama ve yatırım konusunda bilinçli kararlar vermek için alternatifler sunmaktır. DFR’da, 2015’ten itibaren 2040’a kadar Uganda’nın elektrik tüketiminin tahmini yapılmıştır [1]. Kurulu kapasite şu anda 895,5 MW seviyesindedir. Uganda hükümeti, elektrik üretimini iyileştirmek amacıyla, 2013 yılında iki büyük hidroelektrik santrali inşa etmeye başlamıştır. Bu santraller Uganda’nın batısındaki Karuma’da (600 MW) ve Uganda’nın doğusundaki Isimba’dadır (183 MW). Bu projelerin 2018 Aralık ayında devreye alınması

³ National Planning Authority

beklenmektedir. Ayrıca Muzizi’de (44 MW) ve Nyagak’ta (5,5 MW), (Uganda Elektrik Üretim Şirketi (Uganda Electricity Generation Company Ltd (UEGCL), Faaliyet Raporu 2015) mini hidroelektrik santralleri bulunmaktadır. Bu projelerin devreye alınması ile birlikte toplam kurulu kapasite 1728 MW’a çıkaracaktır. Bu kurulu kapasite ile kırsal alanlara ulaşmak için ulusal şebekenin şu anda mevcut olan 1.300 km’den 2.750 km’ye çıkarılması hedeflenmektedir. (Elektrik Düzenleme Kurumu (Electricity Regulatory Authority (ERA)), 2014/15-2023/24 Stratejik Plan). Ayago, Oriang ve mini hidroelektrik santralleri gibi hidroelektrik santralleri için gelecekteki yerler belirlenmiştir. Hükümetin elektrik üretimini ve elektrik enerjisine erişimi iyileştirme çabalarına rağmen, DFR’da tahmin edilen hedefler hala karşılanmamaktadır. DFR’da kullanılan çeşitli (Base case (temel durum), Low case (düşük durum), high case (yüksek durum) ve Vizyon 2040 durum) tahmin senaryolarına göre, 2015, 2016 ve 2017 yıllarına ait tahmini elektrik enerjisi tüketim değerleri Tablo 1.1.’de verilmiştir. Tablodan bu değerlerin gerçek tüketimden çok fazla sapma gösterdiği gözlemlenmektedir.

Tablo 1.1. MEMD tahminleri ile gerçek tüketimin karşılaştırılması

Yıl	Gerçek (GWh)	Tahminlen (GWh)				% Göreceli hatalar			
		Low case	Base case	High case	Vizyon 2040	Low case	Base case	High case	Vizyon 2040
2015	3.219	4.407	4.645	5.082	25.506	36,9	44,3	57,9	692,4
2016	3.489	5.451	6.665	8.193	31.090	56,2	91,0	134,8	791,1
2017	3.715	5.853	7.114	8.815	37.035	57,6	91,5	137,3	898,9

Kaynak: ERA, DFR 2015.

Yukarıdaki Tablo 1.1.’den tahminlerin gerçekçi olmadığını görüyoruz. Diğer bir deyişle, tahminler Uganda’daki elektrik tüketiminin gerçek resmini yansıtmamaktadır. Planlama amaçları için bu tahminler güvenilir değildir ve yanıltıcıdır. Şayet elektrik enerjisine erişim, Uganda için ülkenin hızlı büyüyen nüfusunun sosyo-ekonomik dönüşümü ve büyüme eğilimini sürdürmede itici güç olmaya devam edecekse, Uganda Vizyon 2040 ekonomik gelişme hedeflerine ulaşılması noktasında, karar vericilerin uygun planlama ve elektrik ücretlendirme politikalarına ve sübvansiyonlar gibi uygun politikalar geliştirmesine yardım edebilmesi için, elektrik tüketim tahminleri daha az hata ile gerçekleştirilmelidir. [2] Uganda’nın elektrik tüketimi ile ekonomik büyümesi

arasındaki ilişkiyi incelemiştir. Onların çalışmaları, elektrik tüketimi ve ekonomik büyümenin pozitif bir korelasyon gösterdiğini ortaya koymuş ve Uganda'daki yüksek seviyede bir ekonomik büyümenin, ancak yüksek seviyede bir elektrik tüketimine ve düşük seviyede bir ekonomik büyümenin ise, yine düşük seviyede bir elektrik tüketimine yol açacağı sonucuna varmışlardır. [3] [4] [5] gibi diğer çalışmalar da elektrik tüketiminin ekonomik büyümeyi ve gelişmeyi olumlu yönde etkilediğini göstermektedir. [1]'de ekonomik kalkınma ve elektrik tüketimi arasındaki ilişkiyi incelemek için ekonomik gelişmenin bir göstergesi olarak gayri safi yurtiçi hasılası (GSYİH) kullanmışlardır. Onlar, gerçekten de, elektrik tüketiminden GSYİH'ye uzanan uzun vadeli tek yönlü nedensel bir ilişki olduğunu onaylamışlardır. Sonuç olarak, bir ülkenin ekonomik kalkınma hedeflerini karşılayabilmesi için yeterli derecede elektrik enerjisine sahip olmasının esas olduğunu söyleyebiliriz. Bu hedefe ulaşma stratejileri arasında, elektrik tüketim tahminlerinde mümkün olduğunca düşük hatalara sahip olması yer almaktadır. Aksi durumda, fazla tüketim tahmini, kullanılmayan kapasiteden dolayı finansal kaynakların israfına yol açabilecek iken, az tüketim tahmini durumunda ise muhtemel sonuçlara yol açabilecektir [6]. Birçok gelişmekte olan ülke ki; Uganda bunlardan biridir, enerji sistemlerindeki uygun olmayan yatırım kararlarına yol açan yetersiz planlamaları da içine alan yapısal eksiklikler göstermektedir [7]. Bu ülkelerde elektrik enerjisine erişim oranları düşük olmakla birlikte, elektrik enerjisi kaynaklarının çeşitliliği de hala yetersizdir. Bu durum yük atmasına neden olan elektrik enerjisi teminindeki eksiklikler yani elektrik kesintileri ile karakterize edilir [8]. Güç sistem planlaması ve çalışması, gücün kullanımı için en temel faaliyettir. Etkin bir güç sistemi planlaması ve operasyon stratejisi için ilk adım gerçekçi ve doğru tahminler yapmaktır. Elektrik enerjisi tüketim tahmini, bir ülkenin artan elektrik ihtiyacı ve tüketimi ile başa çıkabilecek yatırıma öncelik vermesine ve buna uygun politikalar geliştirmesine yardımcı olur.

1.2. Tezin Amacı

Bu çalışmanın amacı iki yönlüdür; Birincisi, Uganda'nın elektrik tüketimini farklı hesaplamalı zekâ yaklaşımlarını kullanarak düşük tahmin hatalarıyla modellemek ve tahmin etmektir. Bununla birlikte, talep değişkenliği ve tahmin belirsizliğine karşı

sistem genişlemesi ile ortaya çıkan finansal riski değerlendirmek için bu yaklaşımları kullanmak zor olduğundan, uzun dönem tahminler için nokta tahminleri çok fazla ilgi çekmemektedir [9]. Bu nedenle ikinci amacımız, sonuçları, gelecekteki gerçek tüketimin önemli ölçüde düşeceği aralığı gösteren sıklık tahminleri olarak sunmaktır.

Bu tezde ilk olarak Uganda'daki elektrik tüketimini etkileyen en etkili sosyo-ekonomik değişkenler belirlenmiştir. Farklı tahmin modelleri geliştirebilmek için girdi olarak belirlenen sosyo-ekonomik değişkenler ve çıktı olarak da elektrik tüketimi kullanılmıştır. Veri setimiz, 27 yıldır (1990-2016) değişkenlere ait tarihsel verilerden oluşmaktadır. Veri setimiz biri eğitim veri seti ve diğeri de test veri seti olmak üzere ikiye bölünmüştür. Tahmin hatalarını en aza indirerek tahmin modellerini optimize etmek için eğitim veri setinde farklı hesaplamalı zekâ teknikleri kullanılmıştır. Modellerimizi doğrulamak için test veri seti kullanılmıştır. Bağımsız değişkenlerin gelecekteki değerlerini elde etmek için basit çok katmanlı algılayıcı sinir ağını kullanılmıştır. Tahmin edilen değişkenler, Uganda'nın elektrik tüketimini tahmin etmek için doğrulanmış modellere girdiler olarak kullanılmış olup, elde edilen sonuçlar MEMD tarafından yapılan ulusal tahminlerle karşılaştırılmıştır. Elde edilen nihai sonuçlara dayanarak da Uganda'nın elektrik sektörü için politika önerileri sunulmuştur.

En sonunda farklı yaklaşımlardan elde edilen tahminleri nihayetinde bir final tahmininde birleştireceğiz. Bu çalışmada, bağımlı değişken olarak elektrik tüketimini ve bağımsız değişkenler olarak da sosyo-ekonomik göstergeleri kullanmak suretiyle üstel, karesel ve ANFIS (adaptif nöro bulanık çıkarım sistemi) olmak üzere üç farklı model geliştirilmiştir. Üstel ve karesel modellerin parametrelerini optimize etmek için parçacık sürüsü optimizasyon (PSO) ve yapay arı kolonisi (YAK) algoritmalarına dayalı hibrit bir algoritma kullanılmıştır. ANFIS modelinin parametrelerini optimize etmek için ise PSO algoritması ile genetik algoritma (GA) birlikte kullanılmıştır. Birçok ülkedeki elektrik tüketimini tahmin etmek için hesaplamalı zekâ yaklaşımı kullanılmış olup [6] [10] [11] [12] [13], elde edilen tahmin sonuçlarının, geleneksel istatistiksel ve ekonometrik tekniklere kıyasla daha iyi olduğu gözlemlenmiştir.

Uganda'nın elektrik tüketimini daha doğru tahmin etmek için de aynı tekniklerin ve yaklaşımların kullanılabileceğini umuyoruz.

1.3. Araştırma Soruları

Bu tez, Uganda'nın elektrik tüketimini tahmin etmek için iki yaklaşım sunmaktadır. Bu iki yaklaşım, aşağıdaki ana araştırma sorusuna cevap vermeye odaklanmaktadır:

Uganda'nın elektrik tüketimini düşük tahmin hatalarıyla modellemek ve kestirmek için hesaplamalı zekâ yaklaşımlarını nasıl uygulanır?

Bu ana araştırma sorusuna ek olarak, aşağıdaki detaylı araştırma soruları incelenmiştir:

1. Uganda'da elektrik tüketiminin büyümesini etkileyen değişkenler neler olabilir?
 - a. Her bir değişken elektrik tüketimi ile ne ölçüde ilişkilidir?
 - b. Uganda'nın üstel, karesel ve ANFIS modellerinde elektrik tüketimi modelinde kullanılabilecek en etkili değişkenler nelerdir?
2. Uganda'nın elektrik tüketimini tahmin etmek için hibrit PSO-YAK algoritmasını kullanmak.
 - a. Üstel ve karesel modeller olarak model elektrik tüketimi.
 - b. Üstel ve karesel tahmin modellerinin parametrelerini optimize etmek için hibrit PSO-YAK algoritması nasıl uygulanır? Hangi model düşük tahmin hataları verir?
3. Uganda'nın elektrik tüketimini tahmin etmek için hibrit PSO-ANFIS ve GA-ANFIS kullanmak.
 - a. Elektrik tüketimi tahmini için ANFIS modeli geliştirmesi.
 - b. ANFIS tahmin modelinin parametrelerini optimize etmek için PSO algoritması ve GA nasıl uygulanır?
4. Bu çalışmada elde edilen sonuçlar gerçek elektrik tüketimi ve MEMD tarafından yapılan ulusal elektrik tüketim tahminlerinden ne kadar farklıdır?
5. Bir nihai kestirim modeli elde etmek için iki yaklaşımı ve dört model nasıl birleştirilebilir?

1.4. Tezin Katkıları

Bu çalışmanın katkılarının aşağıdaki şekillerde olacağı düşünülmektedir:

- a. Uganda'nın elektrik tüketimini en fazla etkileyen değişkenler tespit edilecektir.
- b. Uganda'nın net elektrik tüketimi, yukarıdaki (a) tespit edilmiş değişkenlere bağlı olarak tahmin edilecektir.
- c. Elektrik sektöründeki karar alıcılar ve karar vericiler, elektrik üretimi ile tüketim sektörü arasında, tüketicinin kullanmadığı çok fazla miktardaki elektriği üretmenin aksine, bir denge oluşturmak için doğru politikalar ve kararlar vermelerine yardımcı olur. Böylece yatırımlar uygun bir şekilde yapılmış olacaktır.
- d. Gelişmekte olan ülkelerde ve özellikle Sahra-altı Afrika'da elektrik tüketimi tahmini ile ilgili literatüre katkıda bulunacaktır.

1.5. Tez Organizasyonu

Tez şu şekilde organize edilmiştir;

İkinci bölümünde, elektrik tüketim tahmini kavramı açıklanmış ve buna ilişkin tahmin metotları ve yöntemleri ile elektrik tüketim tahmin modellerine ilişkin yaklaşımlar verilmiştir. Ayrıca regresyon analizi ile veri seti de tarif edilmiştir.

Üçüncü bölümünde, üstel ve karesel tahmin modelleri tanıtılmıştır. Hibrit PSO ve YAK algoritmaları kullanılarak tahmin modellerine ilişkin parameterlerin nasıl optimize edildiği açıklanmış ve bunun neticesinde elde edilen tahmin sonuçları verilmiştir.

Dördüncü bölümünde, ANFIS elektrik tüketim tahmin modeli sunulmuştur. Burada ANFIS modelinin parameterleri PSO algoritması ve GA kullanılarak optimize edilmiştir. Bunun neticesinde ANFIS modeli kullanılarak elde edilen tahmin sonuçları verilmiştir.

Beşinci bölümünde, üçüncü ve dördüncü bölümlerde verilen tahmin modellerinin birleştirilmesi sunulmuştur. Yine aynı bölümde hesaplamalı zeka yöntemlerine dayalı olarak birleştirilen tahmin model sonuçları Çoklu Doğrusal Regresyon (ÇDR) modelinin sonuçları ile karşılaştırılmış ve elde edilen neticeler sunulmuştur.

Altıncı bölümünde ise sonuçlar ve öneriler sunulmuştur.

1.6. Yayın Listesi


1. Kasule A.; Ayan, K.: Forecasting Uganda's Net Electricity Consumption Using a Hybrid PSO-ABC Algorithm. Arab. J. Sci. Eng. (2018) <https://doi.org/10.1007/s13369-018-3383-z>
2. Kasule A.; Ayan, K.: Using PSO and Genetic algorithms to optimize ANFIS model for forecasting Uganda's net electricity consumption. (Yayına alınması düşünülen "Electrical Engineering" dergisine gönderildi. Değerlendirme aşamasında).

BÖLÜM 2. ELEKTRİK ENERJİ TÜKETİMİ TAHMİNİ

Elektrik piyasalarının serbestleşmesinden sonra, elektrik tüketiminin modellenmesi, enerji üretimi ve tüketimi alanında faaliyet gösteren enerji planlayıcıları, uygulayıcıları, politika yapıcıları, akademisyenler ve araştırmacılar arasında artan bir ilgi görmüştür. Modelleme, tüketicilere gereken enerjiyi sağlarken, elektrik tedarikcisi kurumların kayıplarını minimum düzeyde tutabilmesini sağlamakta yardımcı olur. Elektrik yükü, talep ya da tüketim tahmini, kısa vadeli, orta vadeli veya uzun vadeli olacak şekilde sınıflandırılabilir [14]. Kısa vadeli tahmini esasen bir saatten bir haftaya veya bir aya kadar olan bir dönem için iken, orta vadeli tahmini normal olarak bir aydan bir yıla kadarlık bir dönem için ve uzun vadeli tahmini ise beş yıldan yirmi yıl veya daha fazla sürelik bir dönem içindir. Elektrik tahmini, daha çok elektrik üretimi ve iletimini planlamak için kısa vadeli tahmin kullanılır, yani elektrik tedarikcisi kuruluşların işleyişi hakkında bilgi vermek. Yakıt alımlarını planlamak için orta vadeli tahmin kullanılır. Güç tedarikini ve dağıtım sistemini planlamak, yani üretim, iletim ve dağıtım geliştirmek ve genişletilmek için ise uzun vadeli tahmin kullanılır [15].

Elektrik tüketiminin modellenmesi, elektrik sektöründeki arz-talep analizi, tahmin, yenilenebilir enerji entegrasyonu, emisyon azaltma ve optimizasyon gibi bir dizi planlama sorunu ele almak için kullanılır. Modelleme, sistemlerin, tüketicilerin elektrik ihtiyaçlarını karşılayan önceden tanımlanmış kapasite ile tasarlanmasına ve üretilmesine yardımcı olur. Modellemenin amacı her ne olursa olsun, elektriksel modeller, elektrik/enerji sisteminin performansını olabildiğince doğru bir şekilde tanımlayan matematiksel fonksiyonlar ile modellenmişlerdir. Modeller, elektrik sisteminin/kurumunun performans parametrelerinin sayısal değerlerini üretmek için simüle edilmiştir. Bu çalışmada elektrik tüketimini doğru bir şekilde veya en az hata ile tahmin etmeye çalışıyoruz. Amacımız, öngörülen ve gözlenen elektrik tüketimi değerleri arasındaki hata terimlerini en aza indirmektir.

Tahmini, şimdiki ve geçmiş verilerin eğilimlerinin analizine dayanarak geleceğin tahminlerini içeren bir süreç olarak tanımlamaktadır [16]. Buna göre tahmin kavramı, girdi değişkenleri (geçmiş ve şimdiki veriler), tahmin yöntemleri ve çıktı değişkenleri (gelecekteki tahminler) olmak üzere üç temel bileşeni içermektedir. Buna ilişkin genel işlemsel diyagram şekil 2.1.'de gösterilmiştir.



Şekil 2.1. Tahmin işlemine ilişkin genel işlemsel diyagram

Herhangi bir elektrik güç tedarik kurumunun nihai hedefi, son kullanıcılara güvenli ve kararlı bir şekilde elektrik enerjisi sağlamaktır. Bu nedenle elektrik planlaması ve tahmini, elektrik güç sistemlerinin işleyişinde önemlidir. Doğru tahminler, gelecekteki gelişmeler için doğru kararlar alınmasının yanı sıra, güç tedarik ve dağıtım sisteminin güvenilirliğinin artması noktasında ve işletme ve bakım maliyetlerinde önemli tasarruflar sağlar. Bir elektrik tedarik sisteminin elektrik talep tahmini, sisteme bağlı belirli bir tüketici grubundan yük (MW) veya enerji (MWh) talebinin olabilmesidir.

Bu durumda talep tahmini şu şekilde tarif edilebilir: “belirli bir zaman periyodunda belirli sayıdaki tüketicinin elektrik kurumundan bekleyebileceği elektrik talebidir” [17]. Bu nedenle, elektrik talep tahmininin önemi üç aşamalıdır: Üretimi artırma

planlaması, iletim ağını genişleme planlaması ve finansal planlama (yatırım ve fiyatlandırma politikaları).

Elektrik talep tahmini, özellikle enerji sektörlerinde karar vericiler tarafından kullanılan bir politika aracıdır. Bu nedenle, elektrik talep tahmini, enerji sektörünün ekonomik işleyişi için kritik faktörlerden biri olarak değerlendirilir. Elektrik tahmininin amacı, elektrik talebinin durumu ve gerçek kaynak kapasitesi hakkında kolay anlaşılır bilgi sağlamaktır. Bu nedenle, elektrik tüketimini tahmin etmek, planlamacıların ve politika yapıcıların altyapı planlaması için gelecekteki yük taleplerini tahmin etmelerine, elektrik sektöründe yatırım için uygun kararlar almasına, ülkenin etraflı bir şekilde gelişim eğilimlerini ve endeksini incelemesine yardımcı olur.

Tahmin yaklaşımları ve metodolojileri genel olarak gözlemlenen/gerçekleşen ve tahmin edilen değerler arasındaki hatayı en aza indirmeyi amaçlamaktadır. Bu nedenle, tüm tahmin yöntemleri, amaç fonksiyonu olarak birtakım hata fonksiyonlarını kullanır. Yaygın olarak kullanılan hata fonksiyonları, karesel hataların toplamı (Sum of Squared Errors (SSE)), ortalama karesel hata (Mean Square Error (MSE)), ortalama karesel hatanın kökü (Root Mean Square Error (RMSE)) ve ortalama mutlak yüzde hatasını (Mean Absolute Percentage Error (MAPE)) içerir. Bu çalışmada eğitim algoritması için amaç fonksiyonu olarak (2.1) denklemi ile verilen SSE kullanılmıştır.


$$\min f = \sum (Y_i^{actual} - Y_i^{predicted})^2 \quad (2.1)$$

Burada Y_i^{actual} gözlenen tüketim ve $Y_i^{predicted}$ gözlemlenen dönem için belirli bir tahmin modelini kullanarak hesaplanan tüketimdir.

[18]'na göre, elektrik talep tahmini, sıcaklık, bağıl nem, rüzgâr hızı, yağış, kar yağışı, vb. gibi çevresel veya hava koşulları, ülkenin GSYİH'sı, toplam abone sayısı, yeni altyapı projelerinin sayısı, ithalat ve ihracat rakamları, vb. gibilerini içine alan sosyo-ekonomik faktörler, ülkenin franchise alanının nüfusu, hane halkının büyüklüğü, hane halkının yaşadığı yerler vb. gibilerini içine alan demografik değişkenlerden etkilenir.

2.1. Enerji Modelleme Kavramları

Enerji planlaması, enerji arz-talep analizi, tahmin, yenilenebilir enerji entegrasyonu, emisyon azaltma ve optimizasyon gibi enerji sektöründeki pek çok konuyu ele almak ve incelemek için enerji modelleri kullanılmıştır. Enerji modelleri, bir ülkeyi veya bölgeyi besleyen çeşitli enerji santralleri ve şebekeleri olan sistemleri modellemek için kullanılmaktadırlar. Enerji modelleri, verimlilik, gelir ve sosyal faydalar gibi olumlu etkileri maksimize edecek şekilde tüketicilerin enerji ihtiyacını karşılayan, aynı zamanda yakıt tüketimi, maliyetler ve çevresel bozulma gibi olumsuz etkileri minimize edecek şekilde bir sistem tasarlamak ve inşa etmeye odaklanmaktadırlar. Enerji tüketiminin modellenmesi şekil 2.2.'deki gibi gösterilebilir.



Şekil 2.2. Enerji tüketiminin modellenmesi

Enerji tüketiminin düşük tahmini muhtemel sera gazlarının ortaya çıkmasına yol açar; oysa enerji tüketiminin aşırı tahmini gereksiz atıl kapasiteye yolaçar (bakınız şekil 2.2.). Bu nedenle, hatalarla ilgili maliyetlerinden kaçınmak için enerji tüketimini iyi bir doğrulukla modellemek gerekmektedir [17].

[18] çeşitli enerji modellerini ve bunların elektrik yük tahmini ve tüketiminde ne ölçüde kullanıldığını ortaya koymuşlardır. Aşağıdaki bölümlerde onların bazılarını kısaca açıklayacağız. Nonlineerlik bir gerçeklik olduğundan dolayı, değişkenler arasındaki nonlineerlik kullanılarak enerji sistemlerinin modellenmesi gerektiği

şiddetle tavsiye edilmiştir [20]. Örneğin; [21] tarafından tanımlanan destek vektör analizi, Türkiye'de elektrik tüketimini modellemek ve tahmin etmek için de kullanılmıştır. Bu modelde, gayri safi milli hâsıla (GSMH), ithalat, ihracat, ithalat-ihracat oranı ve zaman değişkeni olarak kullanılmıştır. Bu yöntem, modelin doğruluğundan endişe etmeye gerek olmadığını, bununla birlikte modelin hatalarını, eksik veriler, karışıklıklar ve kısa süreli etkiler gibi verilerdeki kusurları ele alma becerisi noktasında endişeli olduğunu ifade etmektedir. Esas konu yerel bir minimuma takılmaksızın maliyet fonksiyonunun minimize edilmesidir. Bu nedenle, iyi modellerin, maliyet fonksiyonu için genel bir minimuma ulaşmayı veya genel bir minimuma sahip olmayı garanti etmesi gerekir. Bu şekildeki modeller tam manasıyla iyi bir optimizasyon ve gürbüzlük özellikleri sergilemelidir. Destek vektör regresyon (Support Vector Regression (SVR)) metodolojisi doğrusallığı, çoklu girişleri, veri kusurlarını, veri aralıklarını ele almaya izin verir ve tam manasıyla mükemmel optimizasyon özelliklerine sahiptir. Sonunda, enerji modelleri, enerji sisteminin performansını olabildiğince doğru tarif eden bir matematiksel fonksiyon oluşturmaya odaklanır. Bu fonksiyona dayanarak, sistemin performans parametrelerinin sayısal değerlerini üretmek için genellikle bir bilgisayar algoritmasında gerçekleştirilen bir benzetim prosedürü geliştiririz. Bu sayısal değerler enerji sisteminin termodinamik, ekonomik veya çevresel performansını ortaya çıkarabilir.

2.2. Enerji Talep Tahmin Yöntemleri

Enerji talep tahmini, özellikle yükselen enerji piyasalarında karar vericiler tarafından kullanılan bir politika aracıdır. Sonuç olarak, çeşitli tahmin yöntemleri kullanılarak çok sayıda enerji talep tahmin çalışmaları yapılmıştır. Bu tahmin yöntemlerini, ekonometrik yaklaşım, yapay zekâ yaklaşımı, hibrit model, Gri teori tahmin modeli ve LEAP (Long-range Energy Alternatives Planning (Uzun vadeli Enerji Alternatifleri Planlama)) modeli olmak üzere beş geniş kategoride sınıflandırmıştır. Enerji talep tahmin yöntemleri genellikle, parametrik/istatistik ve sayısal/yapay zekâ yöntemleri olmak üzere kabaca iki kategoriye sınıflandırılabilir [20].

483 Enerji Planlama Modelinde (EPM) kullanılan tahmin yöntemlerinin sistematik ve eleştirel bir incelemesini sunmaktadır [16]. Bir tahmin yönteminin seçiminin çoğunlukla veri kullanılabilirliği ve aracın hedeflerine ve planlamanın uygulanmasına bağlı olduğunu ifade etmektedirler. Yöntemler, tahmin doğruluğu, zamansal ve mekânsal tahminler için uygulanabilirlik, planlama ve politika hedefleriyle olan ilgi için analiz edilmiştir. Bu çalışmada, incelenen EPM'lerin %40'ında uygulanan Yapay Sinir Ağının (YSA) en yaygın kullanılan yöntem olduğunu saptadılar. Diğer popüler yöntemler, azalan sırayla, şunlardır: destek vektör makinesi (Support Vector Machine (SVM)), otoregresif entegre hareketli ortalama (Autoregressive Integrated Moving Average (ARIMA)), bulanık mantık (Fuzzy Logic), doğrusal regresyon (DR), GA, PSO, Gri Modelleme (Grey Modelling (GM)) ve otoregresif hareketli ortalama (Autoregressive Moving Average (ARMA)). Hesaplamalı zeka yöntemleri, tahmin doğruluğu ile ilgili olarak, özellikle kaynak verilerindeki daha büyük değişkenliğe sahip parametreler için istatistiksel olanlardan daha iyi performans göstermiştir. Bundan başka, hibrit yöntemler, özerk (hibrit olmayan) yöntemlerden daha iyi doğruluk sağlamışlardır. Hesaplamalı zeka yöntemleri tüm zamansal tahmin aralıkları (kısa, orta ve uzun) için tercih edilirken, istatistiksel yöntemler büyük ölçüde sadece kısa ve orta aralık için kullanılmıştır. Hedefe istinaden, EPM'lerin çoğu, enerji talebi ve yük tahmini üzerine odaklanmıştır.

Sınıflandırmada, [16] genel olarak tahmin yöntemlerini özerk ve hibrit olmak üzere iki ana türe ayırmıştır. Özerk yöntemler, tahmin işlemi için tek bir teknik uygular; oysa hibrit yöntemler birden fazla özerk tekniği birleştirmektedir. Çoğu durumlarda hibridizasyonun amacı, tahmini güvenilir yapmak veya rasyonelize etmek ve daha yüksek projeksiyon doğruluğu sağlamaktır. Tekniklerin türüne istinaden, özerk yöntemler istatistiksel, hesaplamalı zeka ve Matematiksel Programlama (MP) olmak üzere üç kategoriye ayrılır. Hibrit yöntemler ise, istatistiksel-istatistiksel, istatistiksel-hesaplamalı zeka, hesaplamalı zeka-hesaplamalı zeka ve istatistiksel-MP yöntemleri olmak üzere dört bölüme ayrılmıştır.

Bütün tahmin yöntemleri arasından uygun olan birinin seçimi farklı faktörlere bağlıdır. Araştırma probleminin amacının yanı sıra karmaşıklığı ve doğası da yöntem

seiminin kritik belirleyicilerinden biridir. Tahmin yntemi seiminin diğr nemli faktrleri doėruluk ve eksik veri seti ile tahmin yeteneėi de olabilir.

Deėiřkenler arasındaki iliřki bilinmediėi veya karmařık olduėu zaman, makine ėrenme yntemleri istatistiksel olarak ele alınması zor olan verileri tahmin edebilir. Veri kullanılabilirliėi ayrıca tahmin ynteminin seimini de etkiler. YSA, veriye dayalı bir yntem olup daha yksek tahmin doėruluėu iin byk miktarda veri gerektirir. Eksik veri setleri durumunda, bulanık mantık daha iyid olmakla beraber doėruluk seviyesi her zaman tatmin edici deėildir. nemli sayıda yazar, tahmin yntemlerinin doėruluėunu artırmak iin birleřtirilmiř yntemlerinin kullanılmasını savunmuřtur [16].

2.2.1. Parametrik ve istatistiksel yntemler

İyi bilinen parametrik yntemlerinin  ise eėilim analizi, nihai kullanım modelleme ve ekonometrik modelleme olarak verilebilir.

2.2.1.1. Eėilim analizi

Eėilim analizi, elektrik talebinin gemiřteki deėiřimlerini geleceėe yayan bir yntemdir. Elle izilmiř dz izgilerden bilgisayar rn karmařık eėrilere kadar eřitli teknikleri kullanır. Yayılımlar tahminlerdir. Bu yntem, talebin niin gemiřte veya gelecekte olduėu gibi davrandıėını pek aıklamaz. Eėilim analizinin avantajı, uygulamanın basit, hızlı ve ucuz olmasıdır. Eėilim analizinin dezavantajı ise, elektrik talebinin, enerji fiyatları, sosyoekonomik deėiřken veya hkmet politikalarındaki deėiřikliklerle ilgili davranıř sergileme nedenini analiz etmeye yardımcı olmamasıdır [22].

2.2.1.2. Nihai kullanım yntemleri

Nihai kullanım yaklařımı elektrik tketimini doėrudan tahmin etmek iin konut, ticari ve endstriyel sektrlerdeki elektrik kullanımı hakkındaki kapsamlı bilgileri kullanır.

Tahminin esası, değişim dinamikleri ile birlikte müşteriler hakkında istatistiksel bilgilerdir. Bu yöntemler, tüketim miktarını, tüketicilerin ısıtma, klima, aydınlatma, soğutma vb. talebinden elde eder. Bu nedenle, nihai kullanım yöntemleri, elektrik talebini piyasadaki uygulama sayısının bir fonksiyonu olarak ifade ederler. İdeal olarak, bu yaklaşım çok doğru olmakla birlikte, nihai kullanım verilerinin miktarına ve kalitesine çok duyarlıdır. Bu yaklaşım için daha az tarihsel veriye ihtiyaç olmakla birlikte, müşteriler ve kullandıkları cihazlar hakkında daha fazla bilgiye ihtiyaç vardır. Nihai kullanım analizinin dezavantajı, elektrik ile nihai kullanım (cihaz başına elektrik) arasında sabit bir ilişkinin olduğuna dair varsayımdır. Kısa dönem için bu varsayım doğru olmakla birlikte, uzun dönem için enerji tasarrufu teknolojisindeki veya enerji fiyatlarındaki değişiklikler nedeniyle bu ilişki de değişecektir [22].

2.2.1.3. Ekonometrik yaklaşım

Ekonometrik yaklaşım, elektrik talebini tahmin etmek için ekonomi teorisi ile istatistiksel teknikleri birleştirir. Temel olarak ekonometrik yaklaşım, GSYİH, ihracat, ithalat, kişi başına düşen milli gelir, nüfus, elektrik fiyatları, kentleşme oranları vb. gibi diğer sosyo-ekonomik değişkenler ile elektrik tüketimini, talep denklemlerinin elde edilmesi amacıyla ilişkilendirir. Genel olarak kabul edilen bir ekonometrik talep modeli (2.2) denklemi ile gösterilen biçime sahiptir.

$$\ln(Y) = a + b\ln(x_1) + c\ln(x_2) + d\ln(x_3) + e\ln(x_4) \quad (2.2)$$

Burada Y bağımlı değişken, x_1, x_2, x_3 ve x_4 bağımsız değişkenler ve a, b, c, d ve e , tahmin edilecek katsayılar/esnekliklerdir [23]. Elektrik tüketimi ile ilişkili olan her bir sosyo-ekonomik değişkenin talep denklemlerindeki katsayıları/esneklikleri, basit bir şekilde en küçük kareler yöntemiyle tahmin edilir. Bu çerçevede yer alan seçeneklerden biri, farklı sektörlerdeki (konut, ticari, endüstriyel, vb. gibi) tüketim, hava, ekonomik ve diğer değişkenlerin bir fonksiyonu olarak hesaplandıktan sonra yakın zaman tarihi veriyi kullanarak tahminler ile birleştirildiğinde, ekonometrik yaklaşımı bir araya getirmektir. Literatürde ekonometrik yaklaşımların çeşitli uygulamaları bulunmaktadır. Örneğin [24] Sri Lanka için elektrik talebini

ekonometrik teknikleri kullanarak tahmin etmiştir. Bu çalışmayı yapanlar, farklı teknikler arasında enerji talebi eğilimi değişirken, farklı yöntemlerden elde edilen tahminlerin 2025 yılına kadar önemli ölçüde değişmediğini tespit etmişlerdir. Çin enerji ekonomisine göre, 2020 yılına kadar Çin'in tüketeceği ve ithal edeceği enerjiyi tahmin etmek için ekonometrik bir yöntem oluşturmuştur [25]. [26], enerji tüketimini etkileyen çeşitli değişkenleri incelemiş ve ardından en etkili değişkenlere dayalı çeşitli ekonometrik yöntemler önermiştir. Önerilen yöntemler tahmin yapmak için 2012 yılına kadar kullanılmıştır. Geçmiş tüketim eğilimlerinin ve kalıplarının gelecekte de devam edeceğini varsayımına dayanan zaman serileri yaklaşımlarının aksine, ekonometrik tahmin yaklaşımları, sosyo-ekonomik değişkenlerin tahmin süresinin başından sonuna kadar sabit değişimlere sahip olacağını varsaymaktadır. Bu nedenle, tahmin edilen ekonomik ve demografik parametrelerin çoğunlukla gerçekleştirmelerden sapma gösterdiğinden dolayı, ekonometrik tahmin yaklaşımlarının daha iyi sonuçlar vermediğini bulmuşlardır. Tahminleri geliştirmek için, ekonometrik yaklaşımlar normalde birden fazla senaryo altında tahminler yapmış, çoğunlukla esas durum, daha az durum ve daha çok durum senaryoları kullanılmıştır.

İstatistiksel yöntemler, verilerin toplanması, incelenmesi, açıklanması, sunulması ve ilişkilendirilmesini araştırır. Tahmin için farklı istatistiksel yöntemler arasında zaman serileri, DR, Olağan en Küçük Kareler (Ordinary Least Squares (OLS)), Doğrusal Olmayan Regresyon (Non Linear Regression (NLR)), Lojistik Regresyon, Parametrik Olmayan Regresyon (Non Parametric Regression (NPR)), Kısmi en Küçük Kareler Regresyonu (Partial Least Squares Regression (PLSR)) ve Basamaklı Regresyon (Stepwise Regression (SR)) yer almaktadır [16].

2.2.1.4. Zaman serileri yaklaşımı

Zaman serileri yaklaşımı, yaklaşımların en basitidir ve gelecekteki tüketimi tahmin etmek için zaman serileri eğilim analizini kullanır. Zaman serileri tek değişkenli ve çok değişkenli zaman serileri olarak ikiye bölünebilir. Tek değişkenli zaman serileri yöntemleri, Hareketli Ortalama (Moving Average (MA)), ARIMA, Mevsimsel Otoregresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving

Average (SARIMA)), Eksojen Girişli Otoregresif Hareketli Ortalama (ARMA with eXogeneous variable (ARMAX)) ve ARMA) olarak verilebilir. Çok değişkenli zaman serileri yöntemleri ise, Vektör Otoregresyon (Vector Autoregression (VAR)), Bayes Vektör Otoregresyon (Bayes Vector Autoregression (BVAR)), Çok Değişkenli VARIMA (Vector ARIMA) ve Yapısal Zaman Serileri Yöntemi (Structural Time Series Method (STSM)) olarak verilebilir. ARIMA tahmin modeli, zaman serileri tahmin analizi için en popüler modellerden biri olup zaman serileri durağan olduğunda ve zaman serilerinde eksik veri bulunmadığında kullanılabilir.

Zaman serileri, farklı zaman dilimlerine sahip elektrik yükü tahminlerinde yaygın olarak kullanılmaktadır. Örneğin, [27], zaman serilerinin eğilime ve etrafındaki dalgalanmaya ayrılarak aylık elektrik enerjisi talebi için zaman serileri tahminine yeni bir yaklaşım önermiştir. Bu yaklaşımda genel bir tahmin elde etmek için iki tahmin toplanmıştır. Ürdün'de elektrik tüketimini tahmin etmek için eğilim, aylık, mevsimsellik ve döngü dinamiklerini açıklayan tahmin yöntemleri önermektedir [28].

2.2.1.5. Regresyon yaklaşımı

Regresyon, elektrik tüketiminin tahmini için en yaygın kullanılan istatistiksel tekniklerden biridir. Elektrik tüketimi tahmininde regresyon yöntemleri, genellikle elektrik tüketimi ile hava durumu, demografik ve sosyo-ekonomik değişkenler gibi faktörlerin ilişkisini modellemek için kullanılmaktadır. Gözlemlenen verileri doğrusal bir denkleme yerleştirerek iki veya daha fazla değişken arasındaki ilişkiyi modellemek için DR uygulanır. Regresyon yöntemlerinde elektrik tüketimi, bir veya daha fazla bağımsız değişkenin bir fonksiyonu olarak modellenmekte ve her değişkene ait esneklikleri bulmak için en küçük kareler yöntemi kullanılmaktadır. [29] gelecekteki yük talebini tahmin etmek için yıllık yük büyümesi ile artırılmış önceki yıllık verilerin günlük ve haftalık basit DR modellerini art arda içeren uzun dönem/orta dönem elektrik yükü tahmini için yeni bir yaklaşım sunmuştur. Kısa ve uzun dönem elektrik tüketimini tahmin etmek için basit DR ve çoklu doğrusal regresyon (ÇDR) biçiminde regresyon modelleri de kullanılmıştır. [30] elektrik tüketimi ile müşteri sayısı, elektrik fiyatı ve turist sayısı arasındaki ilişkiyi araştırmak için çoklu regresyon analizini

kullanmış olup yöntemlerinin yüksek tahmin gücüne sahip olduğunu belirlemişlerdir. [31] 1980–2050 arası dönem için nüfus artışı ve kişi başı enerji tüketimi artış oranlarına göre Türkiye'nin enerji kullanımını tahmin etmişlerdir. [32], Ürdün sanayi sektörünün elektrik tüketimi için çok değişkenli bir DR tahmin yöntemi geliştirmişlerdir.

Diğer istatistiksel yöntemler arasında; Otoregresif Koşullu Değişken Varyans (Autoregressive Conditional Heteroscedasticity (ARCH)) yöntemleri, Otoregresif Dağıtık Gecikme (Autoregressive Distributed Lag (ARDL)), Log-linear analiz, Log-linear ekonometrik yöntemler, Geometrik Progresyon, Transandantal Logaritmik (Translog), Polinom Eğri Modeli (Polynomial Curve Model (PCM)), Kısmi Ayarlama Modeli (Partial Adjustment Model (PAM)), Varyans Analizi (Analysis of Variance (ANOVA)), Eş-bütünleşme ve Ayırıştırma [16] sayılabilir.

2.2.2. Yapay ve hesaplamalı zekâ yaklaşımları

Hesaplamalı yöntemler, girdiler ve çıktılar arasındaki ilişkiye dair önceki veriler ile matematiksel formülasyonun bilinmediği tahmin problemleri için kullanılmıştır. Bunlar, makine öğrenme yöntemleri, bilgi tabanlı yöntemler, belirsizlik yöntemleri ve sezgisel yöntemler olmak üzere dört kategoride sınıflandırılabilir. Makine öğrenmesi yöntemleri arasında YSA, SVM, Dışaçekimsel Ağlar (Abductive Networks (AN)) ve Karar Ağaçları (KA) bulunmaktadır. Bilgi tabanlı yöntemler, uzman sistemleri içermekte olup ağırlıklı olarak kısa dönem yük tahmini için kullanılırlar. Belirsizlik yöntemleri, bulanık mantık ve GM'yi içerir. Bulanık mantık, eksik veya sınırlı veri seti ile etkilidir. Sezgisel yöntemler arasında ise GA ve Evrimsel Algoritma (EA), Memetik Algoritma, PSO algoritması, YAK optimizasyon algoritması, Karınca Koloni Optimizasyon (KKO) algoritması, Kaotik Karınca Sürüsü Optimizasyonu (KKSO), Diferansiyel Evrim (DE) gibi evrimsel yöntemler, Yerçekimi Arama (YA), algoritması Uyum Araştırması (Harmony Search (HS)), Bağışıklık Algoritması (Immune Algorithm (IA)), Benzetimli Tavlama (BT) Algoritmaları, Ateş Böceği Algoritması (ABA)) ve Guguk Kuşu Arama Algoritması (GKA) [16] vardır. Sezgisel yaklaşımlar, geleneksel gradyan temelli arama yöntemlerinin tam manasıyla optimal

çözümlere ulaşmakta başarısız olduğu durumlara dayanmaktadır. Her yöntemin kısa bir açıklamasını ve bu yöntemlerin enerji veya elektrik tüketimini tahmin etmek için kullanıldığı çalışmaları gözden geçireceğiz.

2.2.2.1. Makine öğrenmesi yöntemleri

YSA, bağımlı ve bağımsız değişkenler arasında daha yüksek dereceli nonlinearlik gösteren regresyon teknikleri olarak değerlendirilirler [33]. YSA, bir eğitim veri setine ait bilgileri öğrenme, saklama ve geri çağırma kabiliyetine sahip biyolojik sinir sisteminden ilham alır. Bunlar, giriş ve çıkış uzayları arasındaki ilişkinin dinamiğinin bilgisine sahip olmaksızın, çok boyutlu bir giriş uzayını, çok boyutlu diğer bir çıkış uzayı üzerinde doğrusal olmayan bir şekilde eşleştirebilmeyi sağlayan "karakutu" modelleme tekniğidir. YSA, [34] [35] [36] [37] [38] [39] tarafından elektrik tüketimi tahmininde başarılı bir şekilde kullanılmıştır.

SVM, girdilerin daha yüksek boyutlu bir özellik uzayına eşlenmesini tanımlayan denetimli öğrenme yöntemleridir. Yüksek boyutlu özellik uzayında, giriş ve çıkış verileri arasındaki doğrusal olmayan ilişkiyi formüle etmek için doğrusal bir fonksiyon kullanılır [40]. Tecrübi riski minimize etme prensibini (eğitim hatasını minimize etme) uygulayan sinir ağ modelinin aksine, SVM'ler Yapısal Risk Minimizasyonu (YRM) prensibini uygularlar. YRM'nin temel kavramı, genelleme hatasının üst sınırını minimize etmektir [41]. SVM'ler, yük tahmini problemlerinde başarıyla kullanılmıştır. Örneğin [41], bir SVM modelinin parametrelerini seçmek için BT algoritmalarını kullanmış ve Tayvan için elektrik yükünü tahmin etmiştir. Bu yöntem ile elde edilen sonuçların, ARIMA ve genel regresyon sinir ağları modelleri kullanılarak elde edilenlerden daha iyi olduğu ortaya konmuştur. [40] Tayvan için elektrik yüklerini tahmin etmek üzere bir SVM modeline ilişkin uygun parametre kombinasyonunu seçmek için Kaotik Parçacık Sürüsü Optimizasyon (KPSO) algoritmasını uygulamıştır. [42] ise yük tahmini için KKO'na dayalı SVM'leri kullandı. Geri yayımlı (GY) sinir ağı ve tek SVM ile karşılaştırıldığında, daha iyi tahmin doğruluğu elde edildiği görülmüştür. [21], Türkiye'nin elektrik tüketimini modellemek ve tahmin

etmek için SVM yöntemini uygulamıştır. Elektrik tüketimi, nüfus, brüt gayri safi milli hasıla, ithalat ve ihracatın bir fonksiyonu olarak modellenmiştir.

Hepten gidimsel (dışaçekimsel) çıkarım, genel prensiplerden ve ilk gerçeklerden, belirsizlik altındaki yeni olgulara akıl yürütmedir [43]. AN, hepten gidimsel çıkarıma dayalı bir sayısal bilgi modelleme ağıdır. Bu anlamda, karmaşık sistemlerin çıktılarını tahmin etmek için AN etkin bir biçimde tahmin edici olarak kullanılabilirler. Bir AN'da, karmaşık bir sistem, polinom işlevsel düğümlerinin kullanımı ile birkaç katman halinde gruplandırılan daha küçük ve daha basit alt sistemlere ayrılır. Girişler ayrıca gruplara ayrılır ve bireysel işlevsel düğümlere iletilir. Polinom fonksiyonları, bir çıkış üreten sınırlı sayıdaki giriş düğümünü değerlendirmek için kullanılır. Üretilen çıkış, sonraki katmanın düğümlerinin girişi olarak işlev görür [44]. Bunlar, işlevsel bir elemanın çıkışının girdi değişkenlerinin bir polinom fonksiyonu olması bakımından, sinir ağlarından farklılık gösterirler. Yani, dışaçekimsel bir ağı düğümleri, üç giriş değişkenine kadar üçüncü derece polinom fonksiyonlarını içerir iken, sinir ağlarının düğümleri, giriş değişkenlerinin doğrusal ağırlıklı toplamlarından meydana gelir. Polinom terimlerinin katsayıları, sentez sırasında belirlenen "ağırlıklandırma" faktörleridir [45]. Sinir ağları gibi, AN da kısa dönem elektrik tüketimi için kullanılmıştır. Örneğin, [46], kısa dönem saatlik yükleri AN kullanarak tahmin etmiştir. İlgili bir araştırmada [47], beş yıllık tepe yükü ve aşırı sıcaklığı kullanarak altıncı yıl için günlük elektrik tepe yüklerini tahmin etmek için dışaçekimsel bir ağ geliştirdi. AN modeli, aynı veri seti için sinir ağları modeli ile karşılaştırıldığında daha iyi performans göstermiştir. [48], Suudi Arabistan'ın doğu vilayetinde aylık evsel elektrik tüketimini modellemek için dışaçekimsel çıkarım modellemesi (Abductive Inference Modelling (AIM)) kullanmıştır. Burada hava durumu parametreleri, demografik ve ekonomik göstergeler için beş yıllık veri kullanılmıştır. AIM modelinin geliştirilmesi daha kolay ve daha hızlı olup daha önce aynı veriler için geliştirilen regresyon modellerinden daha az girdi parametresine ihtiyaç duymaktadır. AIM modelinin tahmin sonuçları daha doğru olarak gerçekleşmiştir.

KA, "IF-THEN" kurallarını çıkarmaya ve giriş ile çıkış değişkenleri arasındaki ilişkiyi kolay bir şekilde açıklığa kavuşturmaya müsaade eden bir veri madenciliği yöntemidir

[49]. Burada, yük ile GSYİH, toplam ihracat ve ikincil sanayi GSMH artış hızı olarak tanımlanan etkili değişkenler arasındaki ilişkiyi kurmak için karar ağacı tabanlı bir yöntem geliştirilmiştir. Geliştirilen sistemin faydasını göstermek için, tahmin sonuçları gerçek sistem üzerinden geleneksel bir yaklaşım ile karşılaştırılmıştır. Yükü tahmin edebilmek için bir dizi karar kuralları elde edilmiş ve bilgi tabanında depolanmıştır. [50], elektrik enerjisi tüketimini tahmin etmek için regresyonlu KA'ını sinir ağları ile karşılaştırmıştır. Bu araştırmacılar, KA'nın diğer yöntemlere göre avantajlı olduklarına dikkat çekmektedirler. Çünkü bunlar, kolaylıkla yorumlanabilen kuralları gösteren ve aynı zamanda tahmin için önemli faktörlerin önemi hakkında net bilgi sağlayan bir model üretmektedirler. Bununla birlikte KA genellikle doğrusal olmayan veriler için sinir ağları gibi iyi performans göstermezler ve verilerdeki gürültüden büyük ölçüde etkilenirler. Bu araştırmacılar, KA modeli ve sinir ağı modelinin, elektrik enerjisi tüketimini tahmin etmek için kullanılan tahmin doğruluğu açısından, regresyon modelinden biraz daha iyi performans gösterdiklerini bulmuşlardır.

2.2.2.2. Bilgi tabanlı yöntemler

Uzman bir sistem, alan uzmanlarından gelen bilgileri bir bilgisayar programı içerisinde kurallar olarak modeller. Bu kural tabanlı algoritma, yük ile onun etkili değişkenleri ya da faktörleri, yük ve etkili faktörlerdeki değişimler ve çıkarımların (tahminlerin) yapılabildiği IF-THEN kurallarından oluşan bir kural tabanı arasındaki mantıksal ve sözdizimsel ilişkilerden oluşur [51]. Örneğin [51] bir Mumbai ajansı için haftanın her gününü ve o günün ortalama sıcaklığını etkili değişkenler olarak kullanmak suretiyle kısa dönem elektrik tahmini için uzman bir sistem geliştirmiştir. Bu sistemde, sistem davranışı ile ilgili kurallar kamuda çalışan mühendislerinden elde edilmiştir. İstatistiksel analiz kullanarak kurallar berraklaştırılmış ve haftanın her günü için doğrusal bir tahmin modeli geliştirilmiştir. Doğrusal modelin parametreleri önceki verilerde Karesel Programlama (KP) kullanılarak optimize edilmiştir. Optimize edilmiş doğrusal model, ertesi günün tahminlerini yapmak için kullanılır. Ayrıca [52], elektrik yükünün zaman serileri tahmini için bulanık bir uzman sistemi modellemek için hibrid bir sinir ağı geliştirmiştir. Bu hibrit sinir ağı, bulanık "IF-THEN" kurallarını

geliştirmek ve yük ve hava durumu parametrelerinin giriş/çıkış üyelik değerlerini optimize etmek için eğitilmiştir.

2.2.2.3. Belirsizlik yöntemleri

YSA'ından farklı olarak, bulanık mantık yaklaşımı, belirsiz ve kesin olmayan koşullar altında karar veren insan zekâsının muhakeme yeteneğini modellemeyi amaçlamaktadır. Sayısal verilerden elde edilen nesnellik ve dilbilimine ait bilgilerinden elde edilen öznellik, bulanık mantıkta biraraya getirilebilir. Bulanık yöntemlerin esas avantajı, bunların, tamamen belirsizlik altında yüksek doğruluk elde edebilmeleri ve girdi ve çıktı değişkenlerini haritalayabilecek matematiksel olmayan modeli ön plana çıkarmaya da yardımcı olmasıdır. Bulanık mantık elektrik tüketim tahmininde de kullanılmıştır. [53] girdi değişkenleri olarak GSYİH'yi ve popülasyonu gözönüne almak suretiyle, Brezilya'da uzun dönem elektrik tüketimini tahmin etmek için bulanık yöntemini kullanmışlardır. Giriş değişkeni olarak sadece GSYİH'yi gözönüne alan [54], Türkiye'nin kısa süreli brüt yıllık elektrik talebini bulanık bir yaklaşımla tahmin etmişlerdir. Hem sinir ağlarını hem de bulanık mantık prensiplerini bütünleştiren ANFIS gibi diğer yöntemler ile bulanık mantığı birleştiren hibrit yöntemler de önerilmiştir.

GM, küçük örneklerle ve eksik bilgilerle sorunlara çözümler bulan Gri Teoriye (GT) dayanmaktadır. GT'nin temel amacı, sınırlı veri ile rastgele veya bulanık yöntemler ile tespit edilemeyen sistemlerin davranışını tahmin etmektir. Birçok farklı GM arasından en çok kullanılanı GM (1,1) modelidir [55]. GM (1,1) üç temel aşamaya sahiptir. İlk adımda, orijinal veri dizisinden biriktirilmiş bir üretim işlemi (Accumulated Generating Operation(AGO)) kullanılarak yeni bir veri dizisi üretmeyi ihtiva eder. Üretilen yeni veri dizilerinde daha az gürültü ve rastsallık vardır. İkinci aşamada GM (1,1) modellenir. Yani bağımlı ve bağımsız değişken arasındaki ilişki bir diferansiyel denklem olarak formüle edilmiştir. Modelin parametreleri en küçük kareler metodu kullanarak optimize edilir ve gelecekteki noktalar tahmin edilir. Son adımda, tahmin edilen AGO değerlerini orijinal diziye geri dönüştürmek için ters biriktirilmiş üretim işlemi (Inverse Accumulated Generating Operation(IAGO)) uygulanır [56]. [55],

Türkiye'nin yıllık elektrik tüketimini tahmin etmek için optimize edilmiş bir GM kullanmıştır. Bu çalışmada 1945'ten 2010'a kadar Türkiye'nin tarihsel elektrik tüketim verileri kullanılmıştır. Başka bir araştırmada [57], Çin'in yıllık elektrik tüketimini ve Shanghai şehrinin yıllık elektrik tüketimi tahmin etmek için Cesur Karınca Optimize Edici Algoritması (Ant Lion Optimizer (ALO)) kullanılarak GM (1,1) parametreleri optimize edilmiştir. ALO tarafından optimize edilen GM (1,1)'nin, en küçük kareler yöntemi ve PSO tarafından optimize edilen GM (1,1) modelinden daha iyi sonuçlar verdiği gözlemlenmiştir.

2.2.2.4. Sezgisel yöntemler

Evrimsel hesaplama algoritmaları, seçim, mutasyon ve tekrardan birleştirme süreçleri aracılığıyla bireysel yapıların evrimini simüle eden ortak bir kavramsal temeli paylaşır. Süreçler, bir ortam tarafından tarif edilen bireysel yapıların algılanan performansına bağlıdır [58]. Evrimsel hesaplama, evrimsel programlama, evrim stratejileri, GA'lar ve genetik programlamadan meydana gelir. Evrimsel hesaplamanın gerisindeki temel prensip, belirli bir nüfusun ortam baskısı neticesinde gerçekleşen doğal seçim (en uygun olanın hayatta kalması) neticesinde yeni bir kuşağa dönüşmesidir. Yeni bir nesile evrilme, bir amaç fonksiyon kullanılmak suretiyle bir optimizasyon süreci olarak modellenebilir. Amaç fonksiyonun uygunluk değerine dayanarak, tekrardan birleştirme ve mutasyon gibi operatörleri uygulamak suretiyle yeni bir nesil oluşturmak üzere daha iyi adaylar seçilir. Yeni bir aday üretmek için bir adaya mutasyon uygulanır iken, iki yeni aday (çocuk) üretmek için iki adaya (ebeveynlere) tekrardan birleştirme uygulanır. Yeni adaylar bir sonraki neslin içerisinde yer alabilmek için eski adaylarla fitness değerlerine göre rekabet ederler [59].

GA'lar, evrim ve doğal genetik prensipler tarafından yönlendirilen rasgele arama ve optimizasyon teknikleridir. GA'lar, optimal çözümlere yakın sonuçlar üreten ve büyük miktarda tam paralellik gösteren, etkili, uyarlanabilir ve gürbüz arama süreçleridir. GA'lar, enerji modellemesine uygulandığında, ekonomik göstergelere dayalı mevcut verileri kullanarak, doğrusal, karesel veya üstel olabilen farklı denklemlerin ağırlıklarını optimize ederler.

Genetik Programlama (GP), atanmış görevlerde iyi performans gösteren fonksiyonları geliştiren bir stratejidir. GA'ları kullanmak için, olası bilgisayar programları içerisinde belirli bir görevi gerçekleştirmek için en uygun yeteneğe sahip bir program araştırılır. Bağımlı ve bağımsız değişkenler arasında fonksiyonel bir ilişki olması gerekli değildir. [60], bağımsız değişken olarak popülasyon ve GSYİH'yi kullanarak, bağlantı ve fonksiyonel kümelerin farklı kombinasyonlarına sahip birkaç durumu araştırdılar. Kore'nin yıllık elektrik enerjisi talebi, GP modeli kullanılarak tahmin edilmiş olup, sonuçlar regresyon modeli ile karşılaştırılmıştır.

Sürü zekası, biyolojik açıdan esinlenmiş sezgisel optimizasyon algoritmalarının bir sınıfıdır. En bilinen sürü zekâsı algoritmaları, PSO, KKO ve YAK optimizasyon algoritmalarıdır. GA'lar gibi, yük tahmininde kullanılan sürü zekâsı teknikleri, ekonomik göstergelere dayalı verileri kullanarak farklı talep denklemlerinin ağırlıklarını optimize ederler.

Diğer sezgisel algoritmalar ise elektrik tüketimini modellemek ve tahmin etmek için kullanılmışlardır.

Örneğin, HS algoritması, müzisyenlerin doğaçlama sürecinden esinlenilen ve [61] tarafından önerilen sezgisel bir algoritmadır. HS algoritmasında her karar değişkeni (müzik aleti), küresel optimum çözümü (en iyi uyumu) bulmak için bir değer (ton) üretir. Yöntem, bir gradyan arama yerine, uyum hafıza önem oranına ve perde ayar oranına dayalı stokastik rastgele bir arama kullanır.

Çin'de Beijing şehrinin yıllık elektrik yükü tahmini için DE algoritmasını ve SVR'nin birleşimi hibrit bir yük tahmin modeli uygulanmıştır. SVR yük tahmini modeli için uygun parametreleri seçmek için DE algoritması kullanılmıştır [62]. Benzer bir araştırmada [63] ise, elektrik yükünü tahmin etmek için SVR kullanılmış ve SVR'nin parametreleri de bağıklık algoritmasını kullanarak optimize edilmiştir. [64], kısa dönem elektrik yüklerini tahmin etmek için kullanılan bir bulanık hiper dikdörtgen sinir ağı kompozisyonunun (Fuzzy Hyper-rectangular Composite Neural Network

(FHCNN)) parametrelerini optimize etmek için BT algoritmasını kullanmıştır. Veitnam'daki Hanoi şehrinin aylık elektrik talep tahminleri için tasarlanan YSA modellerini eğitmek için Yerçekimi Arama (YA) ve Guguk Kuşu Optimizasyonu (GKO) algoritmaları kullanılmıştır [65]. Elde edilen bulgular, GKO algoritması kullanılarak eğitilen YSA modelinin, YA algoritması kullanılarak eğitilen YSA modelinden daha iyi performans gösterdiğini göstermiştir. [66], SVR elektrik yükü tahmin modelinin parametrelerini optimize etmek için memetik algoritma tabanlı bir ABA; yani bir (ABA-MA) algoritmasını önermiştir. ABA, GA, PSO ve BT tabanlı SVR tahmin modelleri ile iyi bilinen modellerden Radyal Temel Fonksiyon Sinir Ağı (Radial Basis Function Neural Network (RBFNN)), Çok katmanlı algılayıcı - Levenberg Marquardt (Multi-layer Perceptron – Levenberg Marquardt (MLP-LM)) ve ARIMA'nın karşılaştırmalı analizi, önerilen ABA-MA'nın SVR'nin tahmin doğruluğunu etkin bir şekilde geliştirebileceğini göstermiştir. [67], bir aya kadarki orta dönem yükleri tahmin etmek üzere çok çıkışlı bir destek vektör regresyon (Multi-Output Support Vector Regression (MSVR)) modelinde, zaman gecikmeli yükler ve sıcaklıklar gibi uygun giriş özelliklerini seçmek için ABA-MA kullanmıştır. Tahmin sonuçları, hem tepe hem de çukur noktalarını gösteren ara değerli seriler olarak sunulmuştur. [68], SVR kısa dönem yük tahmin modelinin özellik seçimi ve parametre optimizasyonunu, kapsamlı öğrenme PSO tabanlı memetik algoritma (Comprehensive Learning Particle Swarm Optimization based Memetic Algorithm (CLPSO-MA)) kullanarak eş zamanlı olarak geliştirmektedir. SVR'nin elektrik yük tahmin modelinin daha iyi bir tahmin performansına sahip olabilmesi için, [69], uygun parametreler için arama yapmak üzere KKSÖ'ünü kullanmıştır.

2.2.3. Matematiksel programlama yöntemleri

Matematiksel programlama ya da matematiksel optimizasyon, bazı durumlarda bir dizi mevcut alternatiften daha iyi çözüm sunar. Bu yöntemler doğrusal olmayan programlama (Non Linear Programming (NLP)) içerir [16]. Örneğin [70], İran'daki konut ve ticari sektörlerin doğal gaz tüketimini tahmin etmek için lojistik temelli bir yaklaşım kullanmıştır. Lojistik parametreleri optimize etmek için NLP ve GA önerilmiştir.

2.2.4. Hibrit yöntemler

Analiz edilen modellerde bulunan hibrit yöntemler aşağıdaki gibi dört kategoriye ayrılabilir; örneğin; istatistiksel-istatistiksel (PCMACP (Polynomial Curve and Moving Average Combination Projection (Polinom Eğri ve Hareketli Ortalama Kombinasyon Projeksiyonu)), Dalgacık (Wavelet)- Genelleştirilmiş Otoregresif Koşullu Heteroskedastisite (Generalized Autoregressive Conditional Hetroskedasticity (GARCH)) – ARIMA, ARMAX – GARCH), istatistiksel-hesaplamalı zeka (ARIMA-YSA, YSA-ÇDR, ARIMA-SVM, SARIMA-SVM, GM (1,1) ARMA ile birlikte), hesaplamalı zeka-hesaplamalı zeka (bulanık sinir ağı (Fuzzy Neural Network (FNN)), ANFIS, PSO-GA, PSO-KKO, GA- KKO) [16].

2.2.5. İstatistiksel ve hesaplamalı zeka tahmin yöntemlerinin karşılaştırılması

Literatürden yapay zekâ yöntemlerinin geleneksel yöntemler ile kıyaslaması yapıldığında, yapay zekâ yöntemlerinin daha iyi sonuçlar verdiklerini gözlemledik. Örneğin, GSYİH, enerji ihracatı, enerji ithalatı ve nüfus tarihi verilerinin elektrik tüketim tahminine etkisini incelemek için, [71] parametrik ve yapay zeka optimizasyon yöntemlerini incelemişlerdir. Gelişmiş ve gelişmekte olan ülkeler için uzun vadeli elektrik enerjisi tüketimini tahmin etmek için regresyon ve YSA modelleri geliştirmişlerdir. Geçmiş verileri kullanarak doğru tahminler elde edebilir. Yapay zeka optimizasyon teknikleri parametrik optimizasyon teknikleriyle karşılaştırıldığında daha düşük tahmin hatası değerleri verdiği sonucuna varmışlardır.. Model parametrelerini aramak için sıradan en küçük kareler tahmini gibi geleneksel yöntemler, PSO [72], GA [73] ve hibrid PSO-GA [74] gibi hesaplama yöntemleri ile karşılaştırılmıştır. Bu çalışmaların tamamında, hata analizi, yapay zekâ yöntemlerini kullanarak parametreleri optimize edilmiş modellerin, geleneksel yöntemlerle optimize edilmiş modelden daha iyi çalıştığını gösterir. Ayrıca, [75]'de, yazarlar amaç fonksiyonunu optimize etmek için PSO aramasını YAK teknikleriyle birleştirirler. Geleneksel yöntemlerle karşılaştırıldığında, hibrit PSO-YAK yöntemi daha iyi sonuçlar verir. [74]'de yazarlar, hibrit PSO-GA algoritmasını sıradan en küçük kareler tahminiyle karşılaştırmışlar ve parametreleri hibrid PSO-GA ile optimize edilmiş

modelin, parametreleri sıradan en küçük kareler tahminiyle tahmin edilen modellere göre daha iyi tahmin sonuçları verdiğini bulmuşlardır. [16]'de hibrit istatistiksel yöntemlerin özerk istatistiksel yöntemlerden daha iyi performans gösterdiğini ve çoğu durumda, hesaplama zeka yöntemlerinin istatistiksel yöntemlerden daha iyi performans gösterdiğini ileri sürmüşlerdir. Ayrıca, hibrit yöntemler, hesaplama zekâ yöntemlerine doğrulukta üstünlük sağlamıştır.

Sonraki bölümlerde, modellerin doğruluk performansını ve tahmin yeteneğini değerlendirmek için kullanılan veri setini ve metrikleri tarif edeceğiz.

2.3. Veri Seti

Elektrik tüketimi hava, sosyo-ekonomik ve demografik faktörler gibi birçok faktörden etkilenmektedir. Hava faktörleri normalde kısa dönem elektrik tüketimini etkilerken, sosyo-ekonomik ve demografik faktörler uzun dönem elektrik tüketimini etkilemektedir. Bu çalışmada sosyo-ekonomik faktörleri bağımsız değişkenler olarak kullanıyoruz. Bu çalışmada kullanılan bağımsız değişkenlerin seçimi, verilerin kullanılabilirliğine bağlıdır. Örneğin, elektrik tüketimi, ihracat ve ithalata kıyasla kentleşme oranı ve enerji tüketimi yapısından daha fazla etkilendiğinden, Uganda için kentleşme ve enerji tüketim yapısı verileri mevcut veri kaynaklarından kolayca elde edilememektedir. Veri kaynaklarından elde edebildiğimiz veriler, nüfus, GSYİH, Uganda'nın toplam ihracat ve ithalatı, abone sayısı ve elektrik fiyatları idi. Dolayısıyla bu çalışmada, 1990 dan 2016'ya kadarki veri seti, bağımlı değişken olarak elektrik tüketimine ait tarihsel veri ve bağımsız değişkenler olarak ise ortalama elektrik fiyatı, elektrik abonelerinin/müşterilerinin (konut, ticari ve endüstriyel müşteriler) toplam sayısı, ithalat, ihracat, nüfus ve GSYİH gibi sosyo-ekonomik faktörlerden oluşmuştur. Nüfus⁴ ve GSYİH⁵ verileri dünya bankası nüfusu ve GSYİH veri API'larından (Application Programming Interfaces (API)) elde edildi. Elektrik tüketimi, ihracat, ithalat, abone sayısı ve elektrik fiyatlarına ilişkin veriler ise, Planlama ve Ekonomik Kalkınma Bakanlığı'nın 1997 istatistik özetinden, 2002'den 2016'ya kadar UBOS⁶

⁴ <http://api.worldbank.org/v2/en/indicator/SP.POP.TOTL?downloadformat=excel> erişim tarihi 12-Eylül-2017

⁵ <http://api.worldbank.org/v2/en/indicator/NY.GDP.MKTP.CD?downloadformat=excel> erişim tarihi 12-Eylül-2017

⁶ <http://www.ubos.org/publications/statistical-abstract> erişim tarihi 10-Eylül-2017

istatistik raporlarından ve Uganda'nın ERA'dan⁷ alınmıştır. Tüm veri seti aşağıdaki Tablo 2.1.'de gösterilmiştir.

Tablo 2.1. Tüm veri seti

Yıl	Nüfus (10 ⁶)	GSYİH (ABD \$ 10 ⁹)	İhracatlar (ABD \$ 10 ⁹)	İthalatlar (ABD \$ 10 ⁹)	Abone sayısı (10 ⁶)	Elektrik fiyatlar (UGX 10 ²)	Elektrik Tüketim (GWh 10 ²)
1990	17,3844	4,3044	0,1901	0,5511	0,09896	0,1077	5,153
1991	17,9734	3,3217	0,1960	0,5227	0,10472	0,1757	5,962
1992	18,5715	2,8575	0,1714	0,5244	0,11068	0,3453	7,620
1993	19,1777	3,2204	0,2226	0,4035	0,11675	0,4873	7,400
1994	19,7913	3,9904	0,4635	0,6842	0,10742	0,8577	7,400
1995	20,4130	5,7558	0,5766	1,0476	0,10843	0,8530	7,170
1996	21,0415	6,0446	0,7108	0,8632	0,12109	0,8433	7,150
1997	21,6795	6,2693	0,5946	0,8944	0,14075	0,9270	8,740
1998	22,3368	6,5848	0,5367	1,0933	0,15904	0,9040	8,650
1999	23,0264	5,9986	0,4888	0,9942	0,16340	0,9533	7,530
2000	23,7576	6,1932	0,4016	0,9582	0,17996	1,0723	13,240
2001	24,5347	5,8405	0,4518	1,0064	0,19993	1,5527	10,580
2002	25,3558	6,1786	0,4676	1,0738	0,22454	1,3797	13,760
2003	26,2178	6,3367	0,5341	1,3751	0,24392	1,3813	12,760
2004	27,1147	7,9404	0,6651	1,7262	0,26179	1,3220	10,230
2005	28,0424	9,0138	1,0132	2,1200	0,26910	1,5533	10,690
2006	29,0009	9,9426	1,1939	2,6379	0,29771	2,6747	10,427
2007	29,9920	12,2928	1,8673	3,5526	0,30311	3,2627	11,983
2008	31,0144	14,2390	2,5320	4,6040	0,29776	3,5920	13,924
2009	32,0671	17,8782	2,3662	4,3396	0,31719	3,6647	14,850
2010	33,1494	20,1818	2,1469	4,7304	0,37776	3,6013	17,065
2011	34,2603	20,2629	2,5149	5,6847	0,47022	3,5973	18,205
2012	35,4006	23,2369	2,8112	6,0950	0,50139	4,0317	20,380
2013	36,5734	24,6630	2,8290	5,8710	0,59616	4,2237	29,299
2014	37,7830	26,9985	2,6766	6,1389	0,70429	4,4790	30,982
2015	39,0324	26,3692	2,6661	5,5892	0,87253	4,7187	32,190
2016	40,3053	29,7066	2,9015	4,8931	0,9957	4,9308	34,890

Net elektrik tüketimi, 1990'da 515.3GWh iken 2016'da 3.489 GWh'ya yükseldi. Nüfus, 1990'da 17,4 milyondan 2016'da 40,3 milyona ulaşmıştır. GSYİH, 1990'da 4,3 milyar ABD dolarından 2016'da 29,7 milyar ABD dolarına yükselmiştir. İhracat, 1990'da 0,1901 seviyesinden 2016'da 2,9015 milyar ABD dolarına, ithalat ise 2016'da 0,5511'den 2016'da 4,8931 milyar ABD dolarına yükselmiştir. Toplam abone sayısı

⁷ <http://www.era.or.ug/index.php/statistics-tariffs/tariffs>, erişim tarihi 10-Eylül-2017


(konut, ticari ve endüstriyel) 1990'da sadece 99.000'den 2016'da 995.700'e yükselmiş olup, bu rakam toplam nüfusa kıyasla hala çok düşüktür. Ortalama elektrik fiyatı da 1990'da 11 Uganda şilininin 2016'da 493 Uganda şilinine yükselmiştir. Bu fiyat, Sahra-altı Afrika'daki en yüksek fiyatlardan biridir.

2002 ve 2006 yılları arasında abone sayısı artmasına rağmen, aynı dönemde elektrik tüketimindeki düşüşe dikkat çekmek istiyoruz. 2002 ve 2006 yılları arasındaki dönemsel peryotta elektrik tüketimindeki düşüş temel olarak üretim kapasitesindeki 1.895,6GWh'den 1.628,9GWh'ye azalmaya bağlanabilir. O dönemde ana kaynak sadece hidroelektrik olup, uzun süren kuraklık Nil nehrinin su seviyelerindeki düşüşe ve dolayısıyla üretimde düşüşe neden olmuştur. Bunu düzeltmek için, Uganda'da 2006'da ilk kez termal üretim uygulamaya sokulmuştur. Termal üretimin başlatılması, elektrik fiyatlarında keskin bir artışa neden oldu. Değişkenlerdeki yıllık ortalama artış aşağıdaki Tablo 2.2. 'de verilmiştir.


Tablo 2.2. Değişkenlerin yıllık ortalama artışı

Değişken	1990'da rakam	2016'da rakam	% yıllık ortalama artışı
Elektrik Tüketimi (GWh)	432	3.489	9,21
Nüfus (Milyon)	17,4	40,3	3,29
GSYİH (ABD \$ Milyar)	4,3	29,6	8,57
İhracat (ABD \$ Milyar)	0,1901	2,9015	13,74
İthalat (ABD \$ Milyar)	0,5511	4,8931	10,67
Abone sayısı	99.000	995.700	9,55
Ortalama Fiyatlar (UGX)	11	493	18,64


Şekil 2.3. - 2.8. 'lerde, elektrik tüketiminin çeşitli bağımsız değişkenler ile değişimi gösterilmektedir. Şekil 2.3. – 2.8.'lerden tüm değişkenlerin pozitif bir eğilim sergilediğini görebiliriz. Bu eğilim tahmin sonuçlarında da beklenmektedir.




Şekil 2.3. Elektrik tüketiminin nüfus ile değişimi




Şekil 2.4. Elektrik tüketiminin GSYİH ile değişimi




Şekil 2.5. Elektrik tüketiminin ihracat ile değişimi



Şekil 2.6. Elektrik tüketiminin ithalat ile değişimi



Şekil 2.7. Elektrik tüketiminin abone/tüketici sayısı ile değişimi



Şekil 2.8. Elektrik tüketiminin elektrik fiyatları ile değişimi

Veriler farklı kaynaklardan ve farklı zamanlarda toplanmış ve aynı yıl için farklı rakamların (özellikle UBOS raporları) kaydedildiği anlaşılmıştır. Örneğin, 2011 yılı için, 2014 istatistik raporu toplam tüketimi 4217,5GWh olarak kaydetmiş olmakla birlikte, aynı yıl için 2015 ve 2016 istatistik raporları 2482,9GWh olarak kaydetmiştir. Bu nedenle 2015 ve 2016 raporlarındaki kayıtlı değer gerçek değer olduğu

anlaşılmaktadır. Kullanmış olduğumuz veri setlerinde aynı döneme ait farklı değerlerin kaydedilmiş olduğunu ve bunun sonucunda bu durumu da, çalışmamızın sonuçlarını öyle ya da böyle bir şekilde etkileyebilecek bir sınırlama olarak gördüğümüzü kabul ediyoruz. Bununla birlikte bu tutarsızlıklar nerede karşımıza çıkarsa çıksın, veri kaynaklarının en son sürümünde kaydedilen değerler kullanılmıştır.

2.3.1. Araştırmada kullanılan değişkenlerin ön analizi

Bu çalışmada kullanılan bağımsız değişkenler; nüfus, GSYİH, ihracat, ithalat, bundan böyle aboneler olarak adlandırılacak olan toplam abone sayısı (konut, ticari ve endüstriyel) ve bundan böyle fiyat olarak adlandırılacak olan ortalama elektrik fiyatıdır. Bağımlı değişken net elektrik tüketimidir. Tablo 2.3., değişkenlerin tanımlayıcı istatistik analizini göstermektedir.

Tablo 2.3. Değişkenlerin tanımlayıcı istatistik analizi

İstatistik	Elektrik tüketimi (x100GWh)	Nüfus (Milyon)	GSYİH (ABD \$) 10 ⁹	İhracat (ABD \$) 10 ⁹	İthalat (ABD \$) 10 ⁹	Abone sayısı (Milyon)	Fiyat (x100 UGX)
Ortalama	14,0085	27,2212	11,6897	1,2663	2,5917	0,3090	2,1283
Standart hata	1,6350	1,3437	1,6465	0,1982	0,4068	0,0461	0,3040
Ortalayan	10,6900	26,2178	6,5848	0,6651	1,3751	0,2439	1,3813
Standart sapma	8,4956	6,9821	8,5554	1,0300	2,1140	0,2394	1,5798
Standard varyans	72,1745	48,7502	73,1955	1,0609	4,4690	0,0573	2,4959
Dağılım	29,7375	22,8974	26,8491	2,7302	5,7355	0,8968	4,7955
Minimum	5,1525	17,3844	2,8575	0,1714	0,4035	0,0990	0,1077
Maximum	34,8900	40,2818	29,7066	2,9015	6,1389	0,9957	4,9032
Sayı	27	27	27	27	27	27	27

Önemli girdi değişkenlerinin seçilmesi, zaman serileri tahmin modellerinin geliştirilmesinde önemli bir adım olup s adet önemli giriş değişkeninin bir S alt kümesini, c adet aday giriş değişkeninin bir C havuz kümesinden 'uygun şekilde' seçme görevi olarak tarif edilir [76]. Seçimin uygunluğuna genel olarak model performansına göre karar verilir. Bir yandan, S az bilindiğinde, seçilen değişkenler modellenen sistemin davranışını tam olarak tarif edemediği için model performansı zayıf olur. Öte yandan, S aşırı-bilindiğinde, ilgisiz veya gereksiz girdi değişkenlere sebep olursa,

modelin doğruluğunu azaltan fazladan gürültü ekleyen ilgisiz veya gereksiz değişkenler nedeniyle model performansı yine zayıf olur. Araştırmalar, girdi değişkenleri arasında korelasyon olduğunda, tahmin sonuçlarının bozulduğunu açıkça göstermektedir. Buna ilave olarak, ilgisiz değişkenler, önemli değişkenleri arasında varolan gerçek ilişkilerin üstünü örtebilir. İlgisiz veya gereksiz değişkenler modelin parametre sayısını ve karmaşıklığını da artırır. Dahası, gereksiz girdi değişkenlerinin dahil edilmesi, veri toplamada zaman ve maliyeti artırabilir. Giriş seçimi esas olarak model içermeyen ve model tabanlı olmak üzere iki yaklaşıma ayrılabilir. İki yaklaşım arasındaki temel fark, model içermeyen yaklaşımın model tabanlı yaklaşımda olduğu gibi model yapısına ve model kalibrasyonuna bağlı olmamasıdır. Tam tersine, model içermeyen yaklaşım, model girdileri ve çıktıları arasındaki doğrusal veya doğrusal olmayan korelasyon biçimindeki istatistiksel ilişkiyi gözönüne alır. Pearson korelasyonu, en basit doğrusal korelasyonu algılayabilen model içermeyen bir tekniktir [77]. [76]'de hem doğrusal hem de doğrusal olmayan korelasyonu saptayabilen model içermeyen bir teknik olarak, kısmi ortak bilgi geliştirmiştir. Her iki teknik (yani, Pearson korelasyonu ve kısmi ortak bilgi), tesadüfi seçimden kaçınmak için bir veya daha fazla istatistiksel teste dayanan önemli girdi değişkenlerini seçmektedir. Model çıktısı ile istatistiksel olarak anlamlı korelasyona sahip girdi değişkenleri, model geliştirmek için önemli girdi değişkenleri olarak seçilebilir. Diğer taraftan model tabanlı yaklaşım, bir veya daha fazla modelleme performans göstergesine, diğer girdi değişkenlerinden nispeten daha fazla katkıda bulunmaları halinde, önemli girdi değişkenleri olarak aday girdi değişkenlerini gözönüne almaktadır. Yaygın olarak kullanılan iki gösterge, gözlenen ve tahmin edilen çıktılar arasındaki MSE ve belirleme katsayısı (R^2)'dır. Bununla birlikte, model tabanlı yaklaşım, girdi değişkenlerinin, bir anlamda, MSE ve R^2 gibi öngörülen modelleme performanslarına dayalı olarak seçildiği yargısına sahiptir [77]. Bu araştırmada tahmin modelimiz için basitlik olsun diye, en önemli değişkenleri seçmek için Pearson'un korelasyon katsayılarını kullanıyoruz.

Değişkenler arasındaki ilişkiyi değerlendirmek için korelasyon katsayıları ve regresyon analizi kullanılmıştır. Tablo 2.4.'de korelasyon katsayıları verilmiştir. Sonuçlar bağımlı ve bağımsız değişkenler arasında anlamlı korelasyon göstermektedir.

Tablo 2.4. Elektrik tüketimi ile bağımsız değişkenler arasındaki korelasyon katsayıları

Değişken	GSYİH	Nüfus	İhracat	İthalat	Abone Sayısı	Fiyatlar
Korelasyon katsayıları	0,9098	0,9368	0,8399	0,8396	0,9723	0,8821

Yukarıdaki Tablo 2.4.'ten, bağımsız değişkenlerin tamamının bağımlı değişken ile pozitif ilişki içerisinde olduğu görülmektedir. Abone sayısı en yüksek korelasyonu gösterir iken ithalat en düşük korelasyonu gösterir. Tüm değişkenler dikkate değer olmakla birlikte, tahmin modellerinde, ithalat ve ihracatı ihmal ederek, gözönüne alınması gereken sadece dört adet değişken seçilmiştir. Örneğin, Tablo 2.4.'te görülen altı değişkeni de gözönüne aldığımızda, karesel modelde yirmi sekiz katsayıya sahip olmakla birlikte, veri setimiz sadece yirmi yedi veri noktasından oluşmaktadır. Veri setinin boyutu küçük olduğundan, optimize edilecek katsayıların sayısını sınırlamak için bu işlem yapılmıştır. Bu bağlamda nüfus, GSYİH, abone sayısı ve fiyatları gözönüne alıyoruz. Bu değişken seçiminden sonra, elektrik tüketimi ile seçilen bağımsız değişkenler arasındaki ilişkiyi göstermek için bir regresyon analizi yapıyoruz. Regresyon analizinin sonuçları ise Tablo 2.5.'te gösterilmiştir.


Tablo 2.5. Elektrik tüketimi ile bağımsız değişkenler arasındaki regresyon analizi

Regresyon istatistiği	Regresyon katsayıları		
R karesi	0,9511	Kesişme	1,4050
Ayarlanmış R karesi	0,9422	GSYİH	0,3229
Standart hata (22 df)	2,042	Nüfus	0,0959
F-istatistiği (4 ve 22 df)	107	Aboneler sayısı	26,7241
p-değeri	4,368e-14	Fiyat	-0,9598

Regresyon analizi, regresyon katsayılarının kayıta kabul edilebilir olduğunu göstermektedir; yani nüfus, GSYİH ve abone sayısındaki bir artış, elektrik tüketiminde artışa ve dolayısıyla katsayıların işaretinin pozitif olmasına neden olur. Diğer taraftan, elektrik fiyatındaki artış, tüketimde bir azalmaya ve dolayısıyla katsayıların işaretinin negatif olmasına neden olur. Tüm belirleme katsayısı (R-kare (R^2)) olarak da bilinir), ayarlı R-kare ve p değerleri, bağımsız değişkenleri bağımlı değişken için öngörücüler olarak kullanmak açısından önemlidir.

2.3.2. Bağımsız değişkenlerin tahmini

2016-2040 döneminde elektrik tüketimini tahmin etmek için, bağımsız değişkenlerin tahmini değerlerine ihtiyaç duyulur. Diğer ülkelerde abone sayısı ve fiyatlar gibi değişkenler için yıllık tahmin değerleri zaten mevcut olmakla birlikte Uganda için bu değerler veri kaynaklarında bulunmadığından durum böyle değildir. İncelenen bazı çalışmalarda, her bir değişkenin yıllık yüzde artışı tahmin dönemi boyunca kullanılmıştır. Bununla ilgili problem, her yıl sürekli değişiminin olduğu varsayımdır ki; özellikle Uganda gibi gelişmekte olan bir ülke için bu her zaman geçerli değildir. Çünkü gerçek şudur ki; değişim ne sabittir ne de doğrusaldır. Bu nedenle bağımsız değişkenler zaman serileri olarak kabul edilmiş olup, 2016-2040 dönemindeki değerler çok katmanlı bir algılayıcı sinir ağı kullanılarak elde edilmiştir. Burada R-yazılımı *nnfor* ve *forecast* paketleri kullanılmıştır. Çok katmanlı algılayıcı sinir ağı, (x) adet değişen nörona sahip giriş katmanı, (y) adet değişen sinire sahip bir gizli katman ve bir sinire sahip çıkış katmanından oluşmaktadır. Minimum MAPE değeri elde edilene kadar gizli katmandaki sinirlerin sayısını değiştirmeye ve ağı birkaç sefer simüle etmeye devam edilir. Kullanılan çok katmanlı algılayıcı sinir ağının yapısı Şekil 2.9.'da gösterilmiştir.



Şekil 2.9. Çok katmanlı algılayıcı sinir ağı

Tablo 2.6., 2016'dan 2040'a kadarki döneme ait bağımsız değişkenlerin tahmin edilen değerlerini ve çok katmanlı algılayıcı sinir ağı için en düşük MAPE değerlerini, girdi katmanı sinirlerinin ve gizli katman sinirlerini göstermektedir.

Tablo 2.6. Bağımsız değişkenlerin tahmin değerleri

Yıl	Nüfus (10 ⁶)	GSYİH ABD \$ (10 ⁹)	Aboneler (10 ⁶)	Fiyatlar UGX (10 ²)
2016	40,3053	29,7066	0,9957	4,9308
2017	41,5982	30,0025	1,1794	5,0971
2018	42,9110	31,0555	1,4148	5,2449
2019	44,2467	31,7647	1,7477	5,3743
2020	45,5990	33,0425	2,0633	5,5494
2021	46,9801	34,1209	2,4247	5,7874
2022	48,3601	34,8310	2,8125	5,9799
2023	49,7470	35,7492	3,1839	6,1479
2024	51,1408	36,8597	3,5568	6,3435
2025	52,5412	38,2615	3,9329	6,5216
2026	53,9465	39,2265	4,3101	6,7098
2027	55,3546	41,0489	4,7024	6,9078
2028	56,7644	42,9654	5,1028	7,1714
2029	58,1755	43,8684	5,5110	7,3623
2030	59,5879	45,7975	5,9543	7,3832
2031	61,0016	46,3086	6,3999	7,5772
2032	62,4159	47,8564	6,8429	7,7682
2033	63,8307	48,8650	7,2885	7,9488
2034	65,2456	49,6763	7,7349	8,2113
2035	66,6608	51,5352	8,1817	8,3825
2036	68,0762	52,1177	8,6279	8,5570
2037	69,4918	53,3426	9,0747	8,6339
2038	70,9074	54,1011	9,5216	8,8179
2039	72,3232	56,1366	9,9687	9,0052
2040	73,7389	57,0769	10,4156	9,1905
En düşük MAPE (%)	0,0414	8,4303	6,7968	9,4931
Giriş katman sınırı	4	1	2	2
Gizli katman sınırı	10	16	13	5

2.4. Modellerin Tahmin Yeteneğini Değerlendirme Metrikleri

Tahmin doğruluğu, tahmin edilen değerin, gelecekteki gerçek veya gözlenen değere yakınlığının ölçüsüdür. Tahmin edilen değer ile gözlenen değer arasındaki fark olarak da tanımlanabilir. Fark en küçükse, yüksek tahmin doğruluğu elde etmiş oluruz. Ancak fark büyükse, tahmin doğruluğumuz düşük gerçekleşmiş olur. Tahmin doğruluğu, farklı performans değerlendirme ölçütleri kullanılarak belirlenir. En çok kullanılan

ölçütler, RMSE, ortalama mutlak hata (Mean Absolute Error (MAE)), MAPE ve R^2 dır. Modellerin tahmin yeteneğini değerlendirmek için, R^2 , MAPE ve RMSE kullanılır. R^2 , belirleme katsayısı olup modelin verilere ne kadar uygun olduğunu ölçer. MAPE, gözlemlenen ve tahmin edilen değerler arasındaki ortalama mutlak yüzde hatasını ölçer. RMSE, gözlemlenen ve tahmin edilen değerler arasındaki ortalama karesel hatanın ölçüsünü verir. Bire yakın olan bir R^2 değeri, iyi bir modeli gösterirken sıfıra yakın bir değer kötü bir modele işaret eder. MAPE ve RMSE'nin küçük değerleri iyi bir modeli gösterir, yani MAPE ve RMSE'nin değerleri ne kadar düşükse, tahmin etme yeteneği o kadar iyidir. Lewis'e göre, MAPE değeri % 10'un altında olan bir model yüksek doğruluğa sahiptir [78]. MAPE'ye göre model doğruluğunun ayrıntılı bir sınıflandırması Tablo 2.7.'de verilmiştir.

Tablo 2.7. Model değerlendirmesi için tipik MAPE değerleri

MAPE (%)	Değerlendirme
$MAPE \leq \%10$	Doğruluğu çok iyi tahmin
$\%10 < MAPE \leq \%20$	İyi tahmin
$\%20 < MAPE \leq \%50$	Kabul edilebilir
$MAPE \geq \%50$	Hatalı tahmin

R^2 , MAPE ve RMSE değerleri aşağıdaki formüller kullanılarak hesaplanır.

$$R^2 = 1 - \frac{\sum (Y^{actual} - Y^{predicted})^2}{\sum (Y^{actual} - \text{Mean}Y^{actual})^2} \quad (2.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum (Y_i^{actual} - Y_i^{predicted})^2} \quad (2.3)$$

$$MAPE = \frac{1}{N} \sum \left| \frac{Y_i^{actual} - Y_i^{predicted}}{Y_i^{observed}} \right| * 100 \quad (2.4)$$

(2.2), (2.3) ve (2.4) denklemlerindeki N gözlem sayısı, Y_i^{actual} gözlemlenen elektrik tüketimi ve $Y_i^{predicted}$ tahmini elektrik tüketimidir.

BÖLÜM 3. PSO-YAK HİBRİT ALGORİTMASINI KULLANARAK TAHMİN

3.1. Kestirim Modelleri

Elektrik tüketim tahmin modellemesi, beklenen gerçek tüketime mümkün olan en doğru tahminleri gerçekleştirmeyi amaçlamaktadır. Arzu edilen bu doğruluk düzeyine ulaşmak için, bu çalışmada elektrik tüketimini, gözlenen ve tahmin edilen değerler arasındaki karesel hata terimlerinin toplamını minimize eden bir minimizasyon problemi olarak modelliyoruz. Bu çalışmada, y elektrik tüketimi ve x_i 'ler, elektrik tüketimini etkileyen bağımsız değişkenler kümesi olmak üzere, $y(x_i, \omega_i)$ tahmin fonksiyonunu sağlayan bir $\omega = [\omega_0, \omega_1, \omega_2, \dots, \omega_n]^T$ katsayılar vektörünü bulmaya çalışacak şekilde, elektrik tüketimini kısıtsız bir optimizasyon problemi olarak modelliyoruz. Buna göre amaç fonksiyonu (3.1) denklemi ile aşağıdaki gibi tanımlanabilir.

$$\min f(y) = \sum_{r=1}^R (y_r^o - y(x_i, \omega_i)_r^p)^2, \quad \omega = [\omega_0, \omega_1, \omega_2, \dots, \omega_n]^T \quad (3.1)$$

Burada y_r^o ve $y(x_i, \omega_i)_r^p$ sırasıyla, gözlenen ve tahmin edilen değerler olup R ise toplam gözlem sayısıdır. $y(x_i, \omega_i)$ tahmin fonksiyonu katsayılarının optimal bir $\omega = [\omega_0, \omega_1, \omega_2, \dots, \omega_n]^T$ çözüm vektörünü bulmak için, PSO ve YAK sezgisel algoritmalarını hibrit bir biçimde kullanıyoruz. $y(x_i, \omega_i)$ tahmin fonksiyonu, sırasıyla (3.2) ve (3.3) denklemlerinde gösterildiği gibi üstel ve karesel olmak üzere iki şekilde tasarlanmıştır.

$$Y = \omega_0 + \omega_1 x_1^{\omega_2} + \omega_3 x_2^{\omega_4} + \omega_5 x_3^{\omega_6} + \omega_7 x_4^{\omega_8} \quad (3.2)$$

$$Y = \omega_0 + \omega_1 x_1 + \omega_2 x_2 + \omega_3 x_3 + \omega_4 x_4 + \omega_5 x_1 x_2 + \omega_6 x_1 x_3 + \omega_7 x_1 x_4 + \omega_8 x_2 x_3 + \omega_9 x_2 x_4 + \omega_{10} x_3 x_4 + \omega_{11} x_1^2 + \omega_{12} x_2^2 + \omega_{13} x_3^2 + \omega_{14} x_4^2 \quad (3.3)$$

Elektrik tüketim tahminlerini elde etmek için (3.2) ve (3.3) denklemleri kullanılmıştır. Tahmin hatalarını hesaba katmak için, gerçek elektrik tüketimi Y_{actual} , denklem (3.4)'te gösterildiği gibi modellenenir.

$$Y_{actual} = Y \pm E \quad (3.4)$$

Burada E tahmin hatasıdır, yani gerçek tüketimin aşağıda verilen denklem (3.5)'te gösterildiği gibi daha az veya daha fazla olması beklenir.

$$Y - E_{lower} \leq Y_{actual} \leq Y + E_{upper} \quad (3.5)$$

Burada Y , tahmini elektrik tüketimi olup E_{lower} ve E_{upper} tahmin hatasının alt ve üst değerleridir. Tahmin aralıkları üretmek için literatürde önerilen birçok yöntem vardır. Örneğin [79] tahmin artıklarını simüle etmek ve ardından elektrik talebi için tahmin aralıkları üretmek için değiştirilmiş bir önyüklemeye yöntemi önermişlerdir. Tahmin dağılımları, gerçek taleplerin tamamı bölge içerisinde tahmin edilen dağılımdan düşerek değerlendirilmiştir. [80]'de aynı zamanda olasılıksal yük tahminleri üretmenin üç yolunu ortaya koymuştur; yani, giriş senaryosu, simüle edilmiş tahmin ediciler ile üretme; model bağımlı aralık oluşturma ve olasılıksal tahmin modelleri; ve arta kalan simülasyon ile işlem sonrası veya tahmin kombinasyonu. Her senaryo girişine, her bir nokta tahminine karşılık gelen bir olasılık atanmıştır. Olasılıksal yük tahminleri üretmeye yönelik modelleme teknikleri, noktasal veya olasılıksal tahmin yapma gibi asıl amaçları baz alınarak sınıflandırılırlar. Bazı teknikler başlangıçta nokta tahmini için tasarlanmış olmakla birlikte daha sonra araştırmacılar, tekniklerin nokta tahminleri etrafındaki gelecekte ortaya çıkabilecek belirsizliklerin niceliğini belirlemede kullanılabilmesi için tahmin aralıklarının oluşturulmasına imkân sağlayacak şekilde yöntemleri genişletmişlerdir. Örneğin, üstel düzeltme, uzun zamandır endüstride popüler bir nokta tahmin tekniği olarak yer almaktadır. [81] tahmin aralıklarını kapsama dahil edebilmek için modelleme çerçevesini daha sonra

geliştirilmişlerdir. Diğer taraftan, parametrik olmayan olasılık yoğunluk tahmini, Bayesyen modeller, seyrek heterosedastik modeller ve çeyrek regresyon gibi olasılıksal tahmin özelliği olan pek çok teknik geliştirilmiştir. Arta kalanı işleme yöntemi, literatürdeki mevcut nokta yük tahmininin avantajlarından istifade eder. Arta kalanı işleme, artıkların olasılıksal yoğunluk fonksiyonunun, nokta tahminine veya birkaç nokta tahmininin birleşimine uygulanması neticesinde bir yoğunluk tahmini üreterek yapılabilir. Bunu yapmanın en anlaşılır yolu, tahmin hatalarını modellemek için normal bir dağılım kullanmak ve simüle edilmiş artıkları, başlangıç nokta tahminlerine ilave etmektir [80]. Bu çalışmada, denklem (3.5)'te gösterildiği gibi tahmin aralığını elde etmek için modellenmiş artıkları E_{lower} ve E_{upper} olarak nokta tahminlerine ilave ediyoruz. Denklem (3.6)'da gösterildiği gibi, tahmin edilen artıkları (gözlenen dönem için, gözlenen ve tahmin edilen tüketim arasındaki hatalar) modellemek için basit DR kullanıyoruz.

$$\hat{e} = az + b \quad (3.6)$$

Burada a eğim, b kesişme noktası ve z de yıldır. Denklem (3.6)'yı kullanarak herhangi bir yıl için tahmin hatasını bulabiliriz. E tahmin hatasının alt (E_{lower}) ve üst (E_{upper}) sınırları denklem (3.7) kullanılarak elde edilebilir.

$$E = \hat{e} \pm t_{\frac{\alpha}{2}, n-2} * s * \sqrt{1 + \frac{1}{n} + \frac{(z^* - \bar{z})^2}{(n-1)s_e^2}} \quad (3.7)$$

Burada $\hat{e}$, z yılı için artık tahmini, $t_{\frac{\alpha}{2}, n-2}$ $n-2$ serbestlik derecesine sahip bir t skoru, α 0 ile 1 arasında bir değer ve önem derecesidir; yani $\%(1-\alpha)$ 'da denklem (3.5)'in sağlanacağından emin olduğumuzu söyleyebiliriz. Yine burada s artıkların standart hatası, n gözlem sayısı, z^* hatayı bulduğumuz yıl, $\bar{z}$ gözlenen yılların ortalaması, s_e tahmin edilen artıkların standart sapmasıdır.

3.2. Kaynak Araştırması

Enerji talebi genellikle hava durumu, demografik ve sosyo-ekonomik değişkenlerden etkilenmektedir. Enerji modelleri, tarihsel veriyi kullanarak elektrik tüketimi ile etkili değişkenler arasındaki ilişkiyi matematiksel olarak ifade eder [82]. Bu matematiksel gösterimde, modelde etkin olabilecek her bir değişkene, tahmin dönemi için elektrik tüketimi üzerindeki etkisini gösteren bir ağırlık faktörü verilmiştir. Ağırlık faktörlerinin belirlenmesi, verilere en uygun değerleri veren en iyi değerler kümesini bulmayı amaçlayan bir parametre optimizasyon problemidir. Bu sorunu çözmek için, arasında geleneksel gradyan temelli ve istatistiksel gibi yöntemlerin yanında, yapay zekâ yöntemlerinin de bulunduğu çeşitli yaklaşımlar, teknikler ve yöntemler kullanılmıştır. Yapay zekâ yaklaşımları ve yöntemleri GA'lar, sinir ağları ve sürü zekâsı tekniklerini ihtiva eder. Örneğin, [6] ve [21] Türkiye'nin elektrik tüketimini tahmin etmek için, sırasıyla YSA ve SVR yöntemlerini kullanılmışlardır. YSA kullanarak, ağ topolojisi, tanjant sigmoid ve saf doğrusal transfer fonksiyonları için GY eğitim algoritması ile çok katmanlı algılayıcı algoritması [6], 2027'ye kadarlık bir dönem için Türkiye'nin elektrik tüketimini, ekonomik göstergelerin (nüfus, GSMH, ihracatlar ve ithalatlar) bir fonksiyonu olarak modellemeyi ve tahmin etmeyi başarmıştır. [21]'de aynı ekonomik göstergeleri SVR analizi ile de kullanmıştır. MSE'ye bağlı olarak her değişken için ε -SVR modelini bulacak şekilde model parametreleri için şebeke tipi arama gerçekleştirilmiştir. Türkiye'nin enerji talepleri modellemek için kullanılan diğer yöntemler ise KKO yaklaşımı [83], YSA, DR ve NLR [84] ve regresyon analizi ve YSA [39] bulunmaktadır. [85]'te, Türkiye için enerji talebini analiz etmek için eş-bütünleşme ve ARIMA modellemesi kullanılmış iken, [86]'te Türkiye'nin elektrik tüketimini tahmin etmek için YSA ve SVR kullanmıştır. [11]'de ise, Türkiye'nin enerji talebini tahmin etmek için YAK ve PSO yöntemleri kullanılmıştır. Daha önceki diğer yöntemler gibi, Türkiye'nin GSYİH'yi, nüfusu, ithalat ve ihracat rakamları, model (ABCEE (Artificial Bee Colony Energy Estimation) ve PSOEE (PSO Energy Estimation)) geliştirmek için, YAK ve PSO'lu elektrik enerjisi tahminlerinde girdi olarak kullanılmıştır. Her iki model de doğrusal ve karesel formları ele alır. Sonuçlar KKO kullanıldığında elde edilen sonuçlar ile karşılaştırılmıştır [83]. Karşılaştırma sonuçları, önerilen modellerin göreceli tahmin hatalarının KKO'dan daha düşük olduğunu ve sosyo-ekonomik göstergelerin

dalgalanmalarından dolayı karesel formun doğrusal forma göre daha uygun çözümler sağladığını göstermektedir. Sosyo-ekonomik göstergeleri kullanarak, İran'da konut ve ticari sektörler için enerji talebini tahmin etmek için PSO kullanılmıştır [87]. Aralarında zaman serileri yaklaşımı, YSA, HS algoritması, GA'lar ve GM de olduğu [88]'da tarif edilen çeşitli yöntemler kullanılarak enerji talebini tahmin etmek için oldukça fazla sayıda çalışma yapılmıştır. 1980-2009 dönemine ait zaman serileri verileri için, Kenya'nın elektrik tüketimi, gerçek harcanabilir gelir ve konut elektriği fiyatları arasındaki ilişki Hata Düzeltme Modeli (Error Correction Model (ECM)) kullanılarak incelenmiştir [89]. Türkiye'nin net elektrik üretimini tahmin etmek için, 2025 yılına kadar hem üretim hem de talep için doğrusal ve karesel model kullanarak, nüfus, GSYİH, ithalat ve ihracat değerlerini gözönüne alan bir Karınca Kolonisi Optimizasyon Elektrik Enerjisi Tahmin (KKO Electricity Energy Estimation (KKOEEE)) modeli geliştirilmiştir [90]. Hem üretim hem de talep için geliştirilen karesel modeller, ekonomik göstergelerin dalgalanmalarından dolayı daha uygun bir çözüm sağlamıştır. [91]'da, modelde brüt elektrik enerjisi talebini, nüfusu, ortalama yıllık sıcaklığı ve enerji tüketimini bağımsız değişkenler olarak kullanmak suretiyle, Türkiye'nin yıllık hidroelektrik üretimini tahmin etmek için, YAK-YSA modelini uygulamıştır. Sonuçlar, YSA-YAK yönteminin hidroelektrik üretimini, GY algoritması ile eğitilen klasik YSA'den daha iyi tahmin ettiğini göstermektedir. Doğrusal ve karesel formları kullanan PSO ve karınca kolonisi algoritmasından oluşan hibrid bir yöntem, [11] tarafından Türkiye'deki enerji talebini tahmin etmek için kullanılmıştır. Onların çalışmasında GSYİH, nüfus, ithalat ve ihracat değişken olarak kullanılmıştır.

Bu çalışmada, tahmin modellerinin parametrelerini optimize etmek için kullanacağımız PSO algoritması, YAK algoritması ve hibrit PSO-YAK algoritmalarının detayları daha sonraki bölümlerde açıklanacaktır.

3.3. Optimizasyon Algoritmaları

Literatürde gösterildiği gibi, tahmin denkleminin parametrelerini optimize etmek için sezgisel optimizasyon algoritmaları kullanılmıştır. Bu algoritmalar ya özgün ya da

hibrit olarak kullanılmıştır. Bu çalışmada PSO ile YAK'a dayanan hibrit bir algoritma seçilmiştir. Literatürde PSO ve YAK algoritmaları ile bunların varyantları ve uygulamaları üzerine çeşitli çalışmalar çok iyi tartışılmıştır [92][93][94][95][96][97][98][99]. Sonraki bölümlerde PSO, YAK ve hibrid PSO-YAK algoritmalarının genel detayları açıklanacaktır.


3.3.1. Parçacık sürüsü optimizasyonu (PSO)

1995 yılında Eberhart ve Kennedy tarafından geliştirilen PSO, kuş akınının veya balık yetiştiriciliğinin sosyal davranışından ilham alan bir hesaplamalı zekâ tekniğidir. PSO'nun yapay yaşam ve sosyal psikolojinin yanı sıra bilgisayar ve mühendislik bilimlerinde de kökeni vardır. PSO'da kullanılan sürü zekası kavramı, uyumlu olan küresel fonksiyonel kalıplar oluşturmak için çevreleriyle yerel olarak etkileşime giren temsilcilerin kolektif davranışını içerir [100].

Temel bir PSO algoritması, parçacık adı verilen aday çözümlerin sürü adı verilen bir popülasyonunu kullanır. Her parçacık potansiyel bir çözümdür ve bir konum ve onunla ilişkili hız ile karakterize edilir. Parçacık pozisyonları, yüksek uygunluğa sahip boş yerleri bulacak şekilde güncellenir. Parçacıklar, bir uygunluk fonksiyonuna göre arama uzayı etrafında hareket ederler. Ayar kriterini sağlayan düzeltilmiş konumlar bulununcaya kadar işlem tekrarlanır. Her parçacığın bir hafıza fonksiyonu vardır ve o ana kadar ziyaret ettiği en iyi konuma ve tüm sürü tarafından elde edilen küresel en iyi konumuna göre hareketini ayarlar. Hem parçacığın bulunduğu en iyi konum hem de küresel anlamda en iyi konum, kullanıcı tanımlı bir uygunluk fonksiyonuna göre türetilir. Her parçacığın hareketi doğal olarak optimal ya da optimele yakın bir çözüme dönüşür. Parçacıkların hareketi, arama uzayındaki en iyi bilinen konumu (parçacığın en iyisi) ile tüm sürünün en iyi bilinen konumu (küresel en iyi) tarafından yönlendirilir. Parçacığın en iyisi onun gösterdiği mevcut çözümdür. Parçacığın hızı, bir sonraki iterasyonda daha verimli bir konuma gitmesine katkı sağlayacak olan arama uzayındaki bir yer değiştirme vektörüdür. PSO, rastgele bir çözüm popülasyonu ile başlatılır ve (3.8) denklemi kullanılmak suretiyle bir sonraki iterasyonda parçacıkların konumunu güncelleyerek optimal çözümü arar.

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (3.8)$$

Burada x_i^{k+1} yeni konum, x_i^k bir önceki konum ve v_i^{k+1} güncellenmiş hızdır. Hız, (3.9) denklemi kullanılarak güncellenir.



Şekil 3.1. PSO algoritmasının akış diyagramı.

$$v_i^{k+1} = v_i^k + c_1 rand_1(pbest_i^k - x_i^k) + c_2 rand_2(gbest^k - x_i^k) \quad (3.9)$$

Burada c_1 ve c_2 sosyal ve bilişsel yardımcılar, $rand_1$ ve $rand_2$ $[0,1]$ aralığında eşit olarak dağılmış rasgele sayılardır. $pbest_i^k$ her bir parçacık için bireysel en iyi konum ve $gbest^k$ de tüm sürü için küresel en iyi konumdur. Bu tanımlamalara göre PSO'nun adımları Şekil 3.1.'de verilmektedir.

PSO'nun en büyük avantajı, doğrusal olmama durumundan ve problemin büyüklüğünden büyük ölçüde etkilenmemesidir. Çoğu analitik yöntemin yakınsamadığı birçok problem için PSO optimal çözüme yaklaşabilir. Bu nedenle PSO'nun, tahmin problemlerini de içeren farklı optimizasyon problemlerine uygulanmasının etkin olduğu düşünülmektedir.


3.3.2. Yapay arı kolonisi (YAK) algoritması

Yapay arı kolonisi (YAK) algoritması, bal arısı sürülerinin besin arama davranışından esinlenen sürü zekâsı tabanlı bir algoritma olup, 2005 yılında Derviş Karaboğa tarafından tanıtılmıştır. Balözü miktarı amaç fonksiyonun uygunluk değerine eşit olduğunda, YAK'daki bir besin kaynağı, optimizasyon problemi için potansiyel bir çözüm olmuş olur. Bu algoritmada arı kolonisi, işçi ve gözcü arılar olmak üzere iki eşit parçaya bölünmüştür [101]. İşçi arıların görevi, bir besin kaynağı için araştırma yapmak ve gözcü arıların üye yapmak (iyileştirmek) için bulunan besin kaynağının bilgilerini paylaşmaktır. Gözcü arılar, daha fazla besin kaynağı araştırmaktan sorumludurlar. Algoritma, rastgele üretilmiş bir $X_i = \{x_{i,1}, x_{i,2}, \dots, x_{i,D}\}$ çözümü ile başlar ki; burada D , araştırma uzayında problemin boyutsallığıdır. Üretilen çözümler, (3.10) denklemi kullanılarak, $c = 1, 2, 3, \dots, MCN$ gibi bir dizi döngüyle düzeltilir.

$$v_i = x_{i,j} + \varphi_{i,j} * (x_{i,j} - x_{k,j}) \quad (3.10)$$

Burada, x_k , ($i \neq k$) rasgele seçilen bir aday çözüm, j , $\{1, 2, \dots, D\}$, kümesinden rasgele seçilen bir boyut indeksi ve $\varphi_{i,j}$ $[-1, 1]$ aralığında rasgele bir sayıdır.

Çözüm, her döngü sonunda uygunluk fonksiyonuna göre düzeltilir ve test edilir. Eğer yeni çözüm daha iyi ise muhafaza edilir, aksi takdirde bir sonraki döngüye eski çözüm alınır. İşçi arılar çözümleri değerlendirdikten sonra, gözcü arılar ilerde daha iyi çözümler belirleyecek bir olasılık fonksiyonuna göre “roulette selection” mekanizmasını kullanarak çözümleri değerlendirirler.



Şekil 3.2. YAK algoritmasının akış diyagramı

Belirli bir denemeden sonra (sınır belirtilir) besin kaynağı iyileştirilmezse, işçi bir arı kâşif arıya dönüşür. Aşağıda verilen (3.11) denklemi, yeni bir besin kaynağını bulmak için bir kâşif arıyı rasgele ayarlamak için kullanılır.

$$x_i = lb_j + rand(0,1) * (ub_j - lb_j) \quad (3.11)$$

Burada lb_j ve ub_j , j inci boyutun alt ve üst sınırlarıdır. Daha iyi çözümler bir sonraki döngüde göznüne alınır. Bu tanımlamalara göre YAK algoritmasının adımları Şekil 3.2.'de verilmektedir.


3.4. Hibrit PSO-YAK Algoritmaları

Literatürde iki hibridizasyon mekanizmasına dayanan bir kaç hibrit PSO ve YAK algoritması önerilmiştir. Birincisi her iki algoritmanın paralel olarak çalıştığı ve bazı noktalarda belirli koşulların karşılanıp karşılanmadığına bağlı olarak bilgi alışverişinde bulunduğu ortak bir yaklaşımdır. Hibritleşmeye ilişkin ikinci yaklaşım, bir algoritmanın bileşenlerini veya aşamalarını diğeriyle karıştırmaktır. Örneğin [102] ve [103]'de tarif edilen PSO-YAK hibrid algoritmaları doğaları gereği ortaktır. [104] ve [105]'da tarif edilen algoritmalar ise PSO'nun bileşenleri ile karıştırılan YAK algoritmasının bileşenlerine sahiptir. Hibritleşmenin gerekçesi, her bir algoritmanın dezavantajlarını ortadan kaldırırken avantajlarını güçlendirmektir. Örneğin, PSO'nun faydalanma konusunda iyi ancak araştırmada yetersiz olduğu bilinir. Buna mukabil YAK için bunun tersi doğrudur. Bu çalışmada, (3.2) ve (3.3) tahmin denklemlerinin parametrelerini optimize etmek için [105] tarafından önerilen hibrit algoritmayı kullanacağız. Bir sonraki bölümde bu algoritmanın detayları açıklanacaktır.

3.4.1. PSO ve YAK'ya dayalı hibrit algoritma

Bu algoritmada hem PSO hem de YAK'ın bileşenleri karıştırılarak hibritleşme işlemi gerçekleştirilir. PSO, başlangıç çözümünü oluşturmak için kullanılır ve daha sonra PSO tarafından üretilen çözümlerin saflaştırılması için YAK algoritmasının gözcü arı ve düzeltilmiş kâşif arı fazları kullanılır. Algoritma tüm PSO parametrelerini ve

$pbest_{Measure}$ olarak adlandırılan YAK algoritmasının ölçüm parametresi kullanır. Algoritmanın hangi fazının icra edildiğini belirlemek için de Limit1 ve Limit2 gibi iki kontrol parametresi ilave edilir. Her iterasyonda her birey $pbest$ 'in güncel halini kaydederek $pbest_{Measure}$ tarafından yönetilir. Eğer $pbest$ güncellenirse, $pbest_{Measure}$, 0'a çekilir, aksi takdirde $pbest_{Measure}$ 1 arttırılır. $pbest_{Measure}$, Limit1'den küçükse, geleneksel PSO fazı uygulanır, aksi takdirde araştırma tipini seçmek için (gözcü fazı veya düzeltilmiş kâşif fazı) $pbest_{Measure}$ Limit2 ile mukayese edilir. $pbest_{Measure}$, Limit2'den küçükse, YAK'ın gözcü arı fazını kullanır, aksi takdirde düzeltilmiş kâşif arı fazını çalıştırır. Durdurma kriterine ulaşıldıktan sonra, en iyi $gbest$ çözümünü elde etmek için son aşama icra edilir. Buna ait algoritma adımları Şekil 3.3.'te özetlenmiştir.



Şekil 3.3. Hibrit PSO-YAK algoritmasının akış diyagramı

Gözcü arı fazında, PSO'nun pbest'i güncelleme sürecinde kullanılır. Tüm pbest'lerden en iyi "fitness" değerlerine sahip olan arıların ilk yarısı, "roulette selection" mekanizmasına dayalı olarak işçi arılar olarak seçilir. Gözcü arılar aşağıdaki ifadeyi kullanarak işçi arıların besin kaynağını değerlendirir.

$$x_i^{t+1} = x_i^t + \psi \cdot (x_i^t - pbest_j^t) \quad (3.12)$$

Burada ψ $[-1, 1]$ aralığında rasgele bir sayıdır. Hafızada tutulacak olanı seçmek için uygunluk değerlerine bağlı olarak x_i^t ve x_i^{t+1} arasında bir "greedy selection" mekanizması kullanılır.

Düzeltilmiş kaşif arı fazında, yeni bir besin kaynağı oluşturmak için tüm pbest'lerden rastgele iki pbest aşağıdaki ifadeyi kullanarak seçilir.

$$x_i^{t+1} = x_i^t + \psi \cdot (pbest_{k1}^t - pbest_{k2}^t). \quad (3.13)$$


x_i^{t+1} 'nin uygunluğu x_i^t 'ninkiyle karşılaştırılır. İkisinin daha iyisi, popülasyonun yeni bir üyesi olur.

3.5. Önerilen Yaklaşımın Probleme Uygulanması

Tahmin modellerinin parametrelerinin optimizasyonu, her iterasyonda parametreleri ayarlamak için algoritma tarafından kullanılan ve (3.1) denklemi ile verilen bir amaç fonksiyonuna dayanmaktadır. Girdiler tahmin modelleri, eğitim veri seti ve doğrulama veri setidir. Çıktılar ise optimize edilmiş model ve model performans ölçümleri, yani MAPE ve R^2 dir. İşlemin ayrıntılı açıklaması Şekil 3.4.'de gösterilmiştir.

Problemin boyutu optimize edilecek katsayıların sayısıdır. Üstel model için problem boyutu dokuz iken karesel model için problem boyutu on beştir. Bu algoritma popülasyona dayalı bir algoritmadır, yani her bir parçacık, PSO bileşeni için onun konumu ve hızı ile, YAK bileşeni için ise besin kaynaklarının sayısı ve balözü miktarı

ile tanımlanır. Bu nedenle, her bir parçacığın konumu n -boyutlu bir uzayda tanımlanmış olup, bu uzayda n optimize edilecek katsayıların sayısıdır.



Şekil 3.4. Önerilen hibrit PSO-YAK yaklaşımının uygulaması

Algoritma, MATLAB 2017a kullanılarak kodlanmış ve uygulanmıştır. Algoritma 40 parçacıktan oluşan popülasyon ile başlatılmış, maksimum iterasyon sayısı 2000'e ayarlanmış, $c_1 = 1,495$, $c_2 = 2,105$, $L_1 = 0,01$, $L_2 = 0,05$, $W_{max} = 0,9$ ve $W_{min} = 0,4$, alt ve üst sınırlar sırasıyla -0,1 ve 0,1 değerlerine ayarlanmıştır. Bu parametrelerle, her model en az on defa çalıştırılmıştır. Veri seti iki kısma ayrılmış olup, ilk kısım (1990-2010) eğitim veri seti olup katsayıları optimize etmek için kullanılmıştır. Her iterasyonda, eğitim veri setindeki her parçacığın konumu değerlendirilir ve en iyi konuma sahip olan parçacık en iyi çözüm olarak, yani o iterasyonda optimize edilmiş katsayılar olarak gözönüne alınır. Bu katsayılar daha sonra o iterasyonda tahmin edilen değeri hesaplamak için kullanılır. Her iterasyonda tahmin edilen değer daha sonra amaç fonksiyonunu değerlendirmek için kullanılır. Bu işlem durdurma kriterlerine

ulaşılan kadar tekrarlanır. Algoritma, maksimum iterasyon sayısına ulaşıldığında duracak şekilde ayarlanmıştır.

İkinci kısım (2011-2016) test veri seti olup, her modelin tahmin yeteneğini değerlendirmek için kullanılmıştır. Test veri seti, bilinen çıktılara sahip olan ve modelin geliştirilip birleştirilemeyeceğini kontrol etmek için kullanılan örnek veri setinin dışındadır. Modelin geliştirilmesinin en iyi ölçüsü, tahmin edilen ve gözlenen tüketim arasındaki hata terimini bulmaktır, yani modelin çıktılarını, doğrulama veri seti üzerinde gözlenen tüketim ile mukayese etmektir. Optimize edilmiş parametrelere sahip tahmin modelleri, 2011-2016 dönemindeki (test veri seti) tüketimi tahmin etmek için kullanılır. Bu çalışmada kullanılan performans kriterlerine göre, geliştirilecek olan tahmin modellerimiz için, tahmini ve gözlenen tüketim arasındaki hata ölçümü (MAPE) küçük ve aynı zamanda belirleme katsayısı (R^2) bire yakın olmalıdır. Ayrıca, kullanılan performans metriklerinin üç veri setinde (eğitim veri seti, test veri seti ve tüm veri seti) önemli ölçüde farklılık gösterip göstermediğini kontrol etmek için model, eğitim veri seti ve tüm veri setinde test edilmektedir. Modellerin tahmin yeteneğini test etmek için kullanılan performans metrikleri, eğitim, test ve tüm veri setinde önemli ölçüde farklılık gösteriyorsa, modeller test testini geçemezler ve böylece tüm veri seti üzerinde geliştirilemezler.

Önerilen yaklaşım rastgele bir arama algoritması kullandığı için, her model iyi bir çözüme ulaşmak için birkaç kez çalıştırılmıştır. Her çalıştırmada, MAPE bir doğruluk ölçütü olarak kullanılmış olup, en düşük MAPE değerini veren model çalışması, en iyi çözüm olarak alınmıştır.

3.6. Sonuçlar

Eğitim ve test setleri üzerinde üstel ve karesel modeller için elde edilen en iyi MAPE ve R^2 değerleri Tablo 3.1.'de gösterilmiştir. Hem MAPE hem de R^2 değerleri, karesel modelin üstel modelden daha iyi olduğunu göstermektedir.


Tablo 3.1. Modeller için MAPE ve R^2 değerleri

Performans metrikleri	Üstel tahmin modeli	Karesel tahmin modeli
MAPE Eğitim veri seti (%)	0,4106	0,1751
MAPE Test veri seti (%)	1,4387	1,1741
MAPE Tüm veri seti (%)	0,3197	0,2609
R^2 Eğitim veri seti	0,9906	0,9969
R^2 Test veri seti	0,9893	0,9925
R^2 Tüm veri seti	0,9920	0,9948


Şekil 3.5. ve 3.6.'daki grafikler, sırasıyla, üstel ve karesel tahmin modelleri için 1990 ile 2016 yılları arasındaki gözlenen ve tahmin edilen tüketimin mukayyesini göstermektedir.

Her model için optimize edilmiş katsayıların çıkarılmasının ardından, (3.2) ve (3.3) denklemleri aşağıdaki denklemler (3.14) ve (3.15) elde edilmiştir.

$$Y = -0,0827 + 1,1794x_1^{0,5459} + 0,5621x_2^{-0,4175} + 23,1529x_3^{1,1518} - 0,3441x_4^{-0,8801} \quad (3.14)$$



Şekil 3.5. Üstel model kullanarak gözlenen ve tahmin edilen değerlerin karşılaştırılması



Şekil 3.6. Karesel model kullanılarak Gözlenen ve tahmin edilen değerlerin karşılaştırılması

$$Y = 1,5154 + 0,0986x_1 + 0,0362x_2 + 0,0797x_3 + 0,2146x_4 - 0,0061x_1x_2 - 0,3042x_1x_3 + 0,0816x_1x_4 + 1,105x_2x_3 - 0,2173x_2x_4 - 0,0577x_3x_4 + 0,009x_1^2 + 0,018x_2^2 + 0,3084x_3^2 - 0,1408x_4^2 \quad (3.15)$$

Denklem (3.14)'te ve (3.15)'te Y , net elektrik tüketimi, x_1 nüfus, x_2 gayri safi yurtiçi hasıla, x_3 toplam elektrik abone sayısı ve x_4 ortalama elektrik fiyatıdır.

Uganda'nın 2040'a kadar net elektrik tüketimini tahmin etmek için (3.14) ve (3.15) tahmin denklemleri kullanılmaktadır. Tahmin hatasının alt ve üst sınırlarını bulmak için $\alpha = 0,1$ (veya % 90 oranında (3.5) denkleminin sağlandığından emin oluruz) seçilmiştir. Gözlenen yıllar için, yani 1990'dan 2016'ya kadar, karesel ve üstel hatalar için (3.6) denklemi, sırasıyla (3.16a) ve (3.16b) denklemleri olur.

$$\widehat{e}_Q = -0,1489z + 297,456 \quad (3.16a)$$

$$\widehat{e}_E = -0,1594z + 318,457 \quad (3.16b)$$

Tablo 3.2. MEMD tahmin raporundan ve tahminlerimizden elektrik tüketim tahminleri

Yıl	Gerçek (GWh)	MEMD Tahmini (GWh)		Üstel Tahmin (GWh)			Karesel Tahmin (GWh)		
		Basecase	Vizyon 2040	Alt	Tahmin	Üst	Alt	Tahmin	Üst
2015	3.219	4.645	25.506	2.686,2	2.847,8	3.465,6	2.563,8	2.726,7	3.349,8
2016	3.489	6.665	31.090	3.026,1	3.188,0	3.806,9	3.073,6	3.236,8	3.860,9
2017	3.715	7.114	37.035	3.537,3	3.699,4	4.319,5	3.508,9	3.672,4	4.297,6
2018		7.591	43.358	4.205,5	4.367,9	4.989,4	4.164,4	4.328,2	4.954,5
2019		8.099	50.077	5.172,2	5.335,0	5.957,8	5.035,1	5.199,2	5.826,8
2020		8.638	57.214	6.115,0	6.278,3	6.902,5	5.992,7	6.157,1	6.786,0
2021		9.211	64.790	7.219,7	7.383,3	8.009,1	7.054,2	7.219,0	7.849,3
2022		9.819	72.825	8.431,5	8.595,5	9.223,0	8.165,5	8.330,7	8.962,5
2023		10.370	81.344	9.616,3	9.780,9	10.410,1	9.352,4	9.518,0	10.151,4
2024		10.992	90.370	10.826,7	10.991,7	11.622,7	10.650,3	10.816,4	11.451,4
2025		11.648	99.927	12.066,6	12.232,1	12.865,0	12.152,1	12.318,6	12.955,3
2026		12.338	110.033	13.328,3	13.494,3	14.129,1	13.550,6	13.717,5	14.356,0
2027		13.064	120.723	14.656,9	14.823,5	15.460,4	15.461,4	15.628,8	16.269,2
2028		13.828	132.026	16.030,0	16.197,1	16.836,2	17.537,6	17.705,5	18.347,8
2029		14.632	143.973	17.446,2	17.613,9	18.255,2	19.248,2	19.416,6	20.060,9
2030		15.453	156.320	19.000,5	19.168,8	19.812,4	21.901,9	22.070,9	22.717,2
2031		16.289	169.042	20.580,7	20.749,6	21.395,6	23.645,3	23.814,9	24.463,3
2032		17.138	182.087	22.168,0	22.337,5	22.986,0	26.157,3	26.327,4	26.978,1
2033		17.994	195.410	23.780,3	23.950,5	24.601,4	28.395,0	28.565,8	29.218,7
2034		18.857	208.961	25.409,8	25.580,7	26.234,2	30.481,0	30.652,4	31.307,7
2035		19.721	222.688	27.054,9	27.226,5	27.882,7	33.605,2	33.777,2	34.434,9
2036		20.584	236.534	28.711,7	28.884,0	29.543,0	35.709,3	35.882,0	36.542,2
2037		21.441	250.440	30.383,2	30.556,2	31.218,0	38.553,2	38.726,5	39.389,3
2038		22.289	264.345	32.067,5	32.241,3	32.906,1	40.927,3	41.101,3	41.766,6
2039		23.124	278.183	33.764,0	33.938,6	34.606,2	44.708,5	44.883,2	45.551,2
2040		23.941	291.889	35.471,5	35.646,9	36.317,6	47.443,1	47.618,5	48.289,4


Karesel ($\widehat{e}_Q$) ve üstel ($\widehat{e}_E$) hataları, (3.16a) ve (3.16b) denklemlerini kullanarak 2016'dan 2040'a kadar tahmin edebilmiştir. Ardından 2016'dan 2040'a kadarki tahmin hatalar ve $\alpha = 0,1$ ile, her yılın beklenen tahmin hatası için % 90'lık tahmin aralığı elde edebilmiştir. Yani her bir yıllık tahminin alt sınırı olan E_{lower} ve üst sınır E_{upper} elde edebilmiştir. Son olarak, E_{lower} , Y ve E_{upper} ve (3.5) denkleminin elde edilen değerlerini kullanılarak, elektrik tüketiminin gerçek değerinin %90'lık anlamlılık düzeyinde, Tablo 3.2.'de gösterildiği gibi tahmin aralığı içerisinde kalmasını bekliyoruz. Tahminler, aynı tabloda MEMD tarafından yapılan tahminlerle de karşılaştırılmıştır. Uganda'nın 2040 yılında net elektrik tüketiminin, üstel tahmin modelimizi kullandığımızda 35.471,5 GWh ve 36.317,6 GWh aralığında olduğu ve

karesel tahmin modelimizi kullandığımızda ise 47.443,1 GWh ve 48.289,4 GWh aralığında olduğu tahmin edilmektedir.

Tablo 3.3. Tahmin edilen değerlerin göreceli yüzde hataları

Yıl	Göreceli yüzde hataları (%)							
	MEMD Tahmini		Üstel tahmin modeli			Karesel tahmin modeli		
	Basecase	Vizyon 2040	Alt	Tahminler	Üst	Alt	Tahminler	Üst
2015	44,30	692,36	-16,55	-11,53	7,66	-20,35	-15,29	4,06
2016	91,03	791,09	-13,27	-8,63	9,11	-11,91	-7,23	10,66
2017	91,45	896,90	-4,78	-0,42	16,27	-5,55	-1,15	15,68

Tablo 3.3.'te 2015, 2016 ve 2017 yılları tahminlerin göreceli yüzde hatalarını göstermektedir. Bu tablodan, göreceli tahmin hatalarımızın MEMD tahminlerinden çok daha düşük olduğu görülebilir.



Şekil 3.7. Gerçek ve tahmin edilen elektrik tüketimi

Şekil 3.7.'de gerçek ve tahmin edilen elektrik tüketimi, MEMD tarafından yapılan tahminlerle de karşılaştırılmıştır.

BÖLÜM 4. HİBRİT PSO-ANFİS VE GA-ANFİS KULLANARAK TAHMİN

4.1. ANFİS'in Teorik Altyapısı

Adaptive Neuro Fuzzy Inference System (ANFİS), sinir ağları ile bulanık sistemlerin birleşimidir. Bulanık sistem bileşeni üyelik fonksiyonlarını tanımlarken sinir ağı bileşeni, bulanık kuralları sayısal verilerden otomatik olarak çıkarmak ve üyelik fonksiyonunun parametrelerini bir öğrenme süreciyle uyumlu bir şekilde ayarlamak için kullanılır. Bu bölüme, ANFİS modelinin temeli olan bulanık mantık ve bulanık sistem kavramlarını gözden geçirerek başlıyoruz.

Bulanık mantık, belirli olgulardan makul sonuç elde etmede belirsizlik içeren yazılımsal bir hesaplama yöntemidir. Bulanık mantığın temel kavramı, bir girdi setini, öyleyse-böyle bulanık kuralları kullanarak bir çıktıya dönüştürmesidir. Bir bulanık "IF-THEN" kuralının aşağıdaki biçimde olduğunu düşünüyoruz.

“IF x is A THEN y is B ”

Burada A ve B , sırasıyla x ve y 'deki bulanık kümelerle tanımlanan dilsel değerlerdir. “ x is A ”, önerme/önceki olarak adlandırılır ve “ y is B ”, netice/karar olarak adlandırılır. A ve B , x ve y 'deki sıralı çiftler kümesi olarak aşağıdaki gibi tanımlanır.

$$A = \{(x, \mu_A(x)) | x \in X\} \text{ ve } B = \{(y, \mu_B(y)) | y \in Y\}$$

Burada $\mu_A(x)$ ve $\mu_B(y)$ üyelik fonksiyonu olarak adlandırılırlar. Bir üyelik fonksiyonu (Membership Function (MF)), giriş ve çıkış uzayındaki her bir elemana,

ona karşılık gelen bir üyelik değeri veya $[0, 1]$ kapalı birim aralık içerisinde üyelik derecesi atanarak bulanık kümenin özelliğini tanımlayan bir eşleştirmedir. Genel olarak, Üçgen (Triangular)MF, Testere Dişi (Trapezoidal) MF, Gauss (Gaussian) MF, Genelleştirilmiş Çan (Generalized Bell) MF ve Sigmoid (Sigmoidal) MF olarak tarif edilen beş adet alışılmış MF vardır. Üçgen MF, belli başlı üçgen üyelik fonksiyonunun üç köşesinin x koordinatlarını (burada $a < b < c$) gösteren üç parametre $\{a, b, c\}$ ile tanımlanır. Eğrinin ayakları a ve c ve eğrinin ucu da b dir.

$$triangular(x; a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \quad (4.1)$$

Testere Dişi MF, belli başlı Testere Dişi MF'nin dört köşesinin x koordinatlarını ($a < b < c < d$) gösteren dört parametre $\{a, b, c, d\}$ ile belirtilir.

$$trapezoid(x; a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right) \quad (4.2)$$

Gauss MF, MF'nin merkezini gösteren c ve MF'nin genişliğini gösteren σ olmak üzere iki parametre $\{c, \sigma\}$ ile tanımlanır.

$$gaussian(x; c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2} \quad (4.3)$$


Genelleştirilmiş Çan MF, çan eğrisinin genişliğini belirten a , pozitif bir tamsayı b , söylem evreninde eğrinin merkezini belirleyen c olmak üzere, üç parametre $\{a, b, c\}$ ile belirlenir.

$$bell(x; a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}} \quad (4.4)$$

Sigmoid MF, iki parametre $\{a, c\}$ ile tanımlanmıştır ki; burada a çapraz geçiş noktası olan $x = c$ noktasında eğimi kontrol eder.

$$sig(x; a, c) = \frac{1}{1 + \exp[-a(x-c)]} \quad (4.5)$$

Şekil 4.1., trapmf, yamuk MF, gbellmf, genelleştirilmiş çan MF, trimf, üçgen MF, gaussmf, Gaussian MF ve sigmf, sigmoid MF olmak üzere üyelik fonksiyonlarının şekillerini göstermektedir.




Şekil 4.1. Üyelik fonksiyonları

Şekile bakılmaksızın, tek bir MF sadece bir bulanık kümeyi tanımlayabilir. Genellikle, tek bir giriş değişkenini tanımlamak için birden fazla MF kullanılabilir.

Çoklu girdiler arasında IF-THEN kuralları oluşturmak için kullanılan en temel mantıksal işlemler AND, OR ve NOT dır. Mantıksal AND, *min* fonksiyonu ile ifade edilir ve böylece $A \text{ AND } B$ ifadesi $\min(A, B)$ 'ye eşit olur. Mantıksal OR, *max* fonksiyonu ile tanımlanır ve böylece $A \text{ OR } B$, $\max(A, B)$ değerine eşdeğer olur ve nihayet mantıksal NOT, NOT A ile tanımlanır ve böylece NOT A ifadesi $(1 - A)$ 'ya eşdeğer olur.

Bulanık çıkarım, verilen giriş değişkenlerinin, “IF-THEN” kuralları, üyelik fonksiyonları ve bulanık mantıksal işlemlerden oluşan bulanık mantık tabanlı çıkarım mekanizması yardımıyla bir çıktı uzayına eşlenmesi sürecidir. Bir bulanık çıkarım sistemi (Fuzzy Inference System (FIS)), Şekil 4.2.'de gösterildiği gibi,

“bulanıklaştırıcı”, “çıkarım motoru”, “kural tabanı” ve “durulaştırıcı” olmak üzere dört bileşenden oluşmaktadır.



Şekil 4.2. Bulanık çıkarım sistemi

Bulanıklaştırıcı, normalde değeri kesin olan girdileri okur ve giriş MF'lerindeki her bir MF için üyelik derecelerini değerlendirir. Bulanıklaştırıcı daha sonra, kural çıkarmak için bulanıklaşmış sonuçları çıkarım motoruna aktarır. Çıkarım motoru, kural kümelerine dayanarak kural tabanından sonuçlar çıkarır. Çıkarım motoru, saklı anlamı ve birleştirmeyi gerçekleştirir. Saklı anlam, bulanık bir girdiyi kuralın sonucu olarak bilinen bir çıktıya dönüştürken, birleştirme, başka bir bulanık set oluşturmak için tüm çıktıları biraraya getirir. Ardından, tüm çıktıların toplamının duru bir çıktıya dönüştürülmesi için durulaştırma safhasına geçilir [106].

Genellikle Mamdani ve Sugeno bulanık çıkarım yöntemleri kapsamlı bir şekilde incelenmiş ve uygulanmıştır. Onlar aynı bulanıklaştırma sürecini takip etmekte olup, iki FIS arasındaki temel fark, Sugeno'nun çıkış MF'leri doğrusal veya sabit iken, Mamdani'nin çıkış MF'lerinin ise bulanık kümeler olmasıdır. Mamdani çıkarım

motorunda (inference engine), “IF-THEN” kurallarının sonucu, bulanık bir küme olarak tanımlanır. Her kuralın çıkış bulanık kümesi, bir eşleşme sayısı ile yeniden şekillendirilir ve bu yeniden şekillendirilmiş bulanık kümelerin tümü bir araya toplandıktan sonra durulaştırma gerekir. Diğer taraftan, Sugeno çıkarımında, “IF-THEN” kuralının sonucu, giriş değişkenlerine göre bir polinom ile açıklanır, böylece her bir kuralın çıkışı tek bir sayı olur. Daha sonra nihai kesin çıktıyı ortaya çıkarmak için bir ağırlıklandırma mekanizması uygulanır. Örneğin Mamdani FIS'de, x 'in A ve y 'nin B olması durumunda, z C olur (as *if x is A , and y is B , then z is C*) şeklindeki bir kural, Sugeno FIS'te, x 'in A ve y 'nin B olduğu durumda z , $pA + qB + r$ olur (*if x is A , and y is B , then z is $pA + qB + r$*) şeklinde uygulanabilir.

ANFIS, Jang tarafından 1993 yılında, uygun üyelik fonksiyonları aracılığıyla girdi ile çıktı uzayını eşleştirmek maksadıyla, “IF-THEN” kuralları oluşturacak bir temel olarak sunulmuştur [107]. Jang'ın çalışması, Takagi ve Sugeno tarafından 1985'te [108], sistemlerin bulanık tanımlanması ve modellenmesi üzerine yapılan bir çalışmanın genişletilmesidir. ANFIS, bulanık “IF-THEN” kurallarını kullanarak, giriş uzayından (bağımsız değişkenler), çıktı alanına (net elektrik tüketimi) doğrusal olmayan bir eşleştirmeyi gösterir. Her kural, eşleştirmenin yerel davranışını tarif eder. Sugeno bulanık modelinde temel bir bulanık kural aşağıdaki gibi gösterilir.

$$\text{IF } X_1 \text{ is } a_1 \text{ and } X_2 \text{ is } a_2 \text{ and } X_3 \text{ is } a_3 \text{ and } X_4 \text{ is } a_4 \text{ THEN } Y = f(X_1, X_2, X_3, X_4),$$

Burada X_1, X_2, X_3 ve X_4 , önceki girişlerde (etkili değişkenler) bulanık kümeler olup Y , çıkışı (elektrik tüketimi) temsil eden kesin bir fonksiyondur. ANFIS'teki girişler ve çıkışlar üyelik fonksiyonları ile gösterilir. Üyelik fonksiyonlarının türü ve sayısı, giriş ve çıkışların sayısı ve kuralların sayısı, bir öğrenme süreci ile optimize edilecek parametrelerin sayısını belirler. ANFIS kural tabanındaki kuralların sayısına, her giriş için giriş uzayını bölecek şekilde üyelik fonksiyonlarının sayısı karar verir. Ayrıca, her üyelik fonksiyonundaki parametre sayısı da bu parametrelerin öğrenme maliyetini belirler. Bulanık kurallar giriş uzayından bölümlleme işlemi yardımıyla oluşturulur. Yaygın olarak kullanılan bölümlleme işlemleri, ağ bölümlleme (grid partition), eksiltmeli kümeleme (subtractive clustering) ve bulanık c-yöntem (fuzzy c-means

(FCM)) kümelemesidir. Bu bölümlene işlemlerinin her birinin, kuralların karmaşıklığı ve diğerleri arasındaki hesaplama süresi gibi avantaj ve dezavantajları vardır. Kümelenmenin amacı, Z veri setini, c adet kümeye (gruplar veya sınıflar) bölmektir. Kümeleme teknikleri, verileri, tek tek veri öğelerinin arasındaki benzerliklerine göre gruplara ayırmak için kullanılan denetimsiz yöntemlerdir. Benzerlik genellikle bir veri noktasının bir kümenin merkezinden Euclidean mesafesi olarak tanımlanır. Mesafe ne kadar kısaysa, kümedeki bir noktanın üyelik derecesi o kadar yüksek olur ve yenilenme doğrudur. Kümeleme yöntemlerinin olası bir sınıflandırması, alt kümelerin bulanık veya keskin (sert) olup olmamasına göre olabilir. Bulanık kümeleme, veri noktalarını kümelere atamak için üyelik derecelerini kullanır. Üyelik derecesine bağlı olarak, bir veri noktası birden fazla kümeye ait olabilir, yani veri noktaları, farklı üyelik dereceleriyle eşzamanlı olarak (aynı anda) birkaç kümeye aittir. Diğer taraftan keskin kümelenme ayırt edici (farklı) olup, veri noktalarını eksiksiz olarak bağlantısız kümelere atar, yani bir veri noktası bir kümeye ait olabilir veya olmayabilir [109]. Bu çalışmada, karmaşıklığı ve optimize edilecek olan kural ve parametrelerin sayısını azaltmak için FCM kümelemesini bir bölümlene işlemi olarak kullanıyoruz. FCM kümeleme, veri noktalarının çoklu kümelere ait olmasına izin verir ve her veri noktası herbir kümedeki bir üyelik değeri ile tanımlanır. Küme içindeki her veri noktasının üyelik değeri, küme merkezi ile veri noktası arasındaki mesafeye bağlı olan bir üyelik fonksiyonu ile belirtilir. Sonraki bölümde, FCM algoritması detaylı bir biçimde açıklanacaktır.

FCM algoritmasının standart versiyonu (Peizhuang, 1983) – Algoritma 1)

$$\mu_{ij} \in [0,1]; \sum_{j=1}^K \mu_{ij} = 1 \forall i; 0 < \sum_{i=1}^n \mu_{ij} < N, \forall N \quad (4.6)$$

kısıtına bağlı olarak,

$$J_m(U, R) = \sum_{i=1}^N \sum_{j=1}^K \mu_{i,j}^m |x_i - r_j|^2 \quad (4.7)$$

fonksiyonunu minimize eder.

Burada $X = \{x_i\}_{i=1}^N$ veri noktaları kümesi, $U = \{\mu_{ij}\}_{i,j=1}^{N,K}$ üyelik dereceleri matrisi, $K \in N$ küme sayısı, $R = \{r_i\}_{i=1}^K$ temsilciler kümesi (küme merkezleri) ve m kümenin bulanıklığını tanımlayan durulaştırma parametresidir. FCM algoritması şekil 4.3.'te gösterilmiştir [110].

Verilen $x = \{x_i\}_{i=1}^N$ ve K değerlerine göre U ve R 'yi döndür.

1: FCM'yi işle (Veri Kümesi x , Kümeler K)

2: 0 ve 1 arasındaki değerlerle U^0 'u rastgele başlat

3: Tekrar et

4: Bulanık küme merkezlerini $r_j = \frac{1}{\sum_{i=1}^N \mu_{ij}^m} \sum_{i=1}^N \mu_{ij}^m x_i, j = 1, \dots, K$ hesapla

5: Yeni $u_{ij} = \frac{1}{\sum_{k=1}^K \left(\frac{|x_i - r_j|}{|x_i - r_k|} \right)^{\frac{2}{m-1}}}$ hesapla

6: $|U^{K+1} - U^K| < \epsilon$ 'a kadar


7: İşlemi bitir.

Şekil 4.3. FCM algoritması

FCM algoritmasını kullanmadan önce, küme sayısını K , ‘belirsizlik’ sembolünü m , sonlandırma toleransını ϵ ve norm-herkete geçirme matrisini (küme merkezlerinin) R ile gösterdiğimizizi belirtelim. Ayrıca, bulanık bölümlleme matrisi U sıfırlanmalıdır [109]. Bu çalışmada kullanılan dört girişli ve bir çıkışlı ANFIS modeli (yapısı) Şekil 4.4.'te gösterilmektedir.

Birinci katmanda, girdilerimiz ve $\mu A(x)$ üyelik fonksiyonlarımız vardır. Bu katmandaki düğümler uyarlanabilir, yani, eğitim sırasında parametreler değiştirilir. Her düğümün çıkışları, üyelik fonksiyonlarının hesaplanmasının bir sonucu olan $O_{1,i} = \mu A_i(x)$ biçimindedir.

Üçgen (Triangular) fonksiyonun üç, testere dişi (trapezoidal) fonksiyonun dört parametresine karşılık, Gauss fonksiyonunun ayarlayabileceğimiz sadece iki parametresi vardır. Sınırlı sayıda veriye sahip olduğumuzdan dolayı, girdilerin üyelik fonksiyonları optimize edilecek birçok öncül parametreye sahip olmadığı için Gauss fonksiyonunu tercih ediyoruz. Daha fazla parametreyi optimize etmek için daha fazla veriye ihtiyacımız vardır. [111] çeşitli sınıflandırma problemlerini çözerken özellikle de, ANFIS'in performansı üzerinde sıkça kullanılan dört üyelik fonksiyonunu



Şekil 4.4. Dört girişli ve bir çıkışlı ANFIS yapısı

incelemiş ve Gauss üyelik fonksiyonunun, benzerlerine kıyasla daha az hesaplama karmaşıklığı ile daha yüksek bir doğruluk derecesi göstermiş olduğu sonucuna varmıştır. Giriş üyelik fonksiyonları için (4.8) denklemi ile verilen Gauss fonksiyonunu kullanıyoruz.

$$\mu A(x_i) = \exp\left\{\frac{-(x_i - c_i)^2}{2\sigma_i^2}\right\} \quad (4.8)$$

Burada c_i ve σ_i öncül parametreler olarak adlandırılır. Bu parametreler optimal bir ANFIS durumu elde etmek için bir öğrenme süreci üzerinden ayarlanır. İkinci katmanda kurallar oluşturulur. İkinci katmanın çıkışı, X_1 , X_2 , X_3 ve X_4 girişler olmak üzere her bir kuralın w_i ateşleme gücüdür.

$$O_{2,i} = w_i = \mu A_i(X_1) \mu B_i(X_2) \mu C_i(X_3) \mu D_i(X_4), i = 1, 2, 3, 4. \quad (4.9)$$

Üçüncü katmanda, her bir kuralın ateşleme gücü, (4.10) denklemi kullanılarak normalleştirilir.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum_{i=1}^4 w_i} \quad (4.10)$$

Bir sonraki katman çıktı üyelik fonksiyonlarını tanımlar. Bu çalışmada, üyelik fonksiyonları olarak (4.11) denkleminde gösterilen doğrusal fonksiyonları kullanan Sugeno bulanık modeli kullanılmıştır.

$$f_i = p_i x_1 + q_i x_2 + r_i x_3 + s_i x_4 + t_i, i = 1, 2, 3, 4. \quad (4.11)$$

Burada x_i girişler olup p_i, q_i, r_i, s_i, t_i sonuç parametreleri olarak adlandırılır. Birinci katmandaki öncül parametreler gibi, sonuç parametreleri de optimal bir ANFIS elde etmek için bir öğrenme süreci üzerinden ayarlanır. Her bir kuralın normalize ateşleme gücü (4.12) denkleminde gösterildiği gibi her bir kuralın çıktısını alacak şekilde ona karşılık gelen çıkış üyelik fonksiyonuna uygulanır.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i x_3 + s_i x_4 + t_i), i = 1, 2, 3, 4. \quad (4.12)$$

Beşinci katmanın son çıkışı, ateşleme güçleri ve çıkış üyelik fonksiyonlarından gelen tüm sinyallerin toplamından oluşur. Denklem (4.13) toplamının nasıl yapıldığını göstermektedir.

$$O_{5,i} = \sum \overline{w}_i f_i = \sum_{i=1}^4 \overline{w}_i (p_i x_1 + q_i x_2 + r_i x_3 + s_i x_4 + t_i) \quad (4.13)$$

4.2. Kaynak Araştırması


ANFIS, kontrol sistemleri, görüntü işleme, zaman serileri tahmini ve yük tahmini gibi birçok alanda kullanılmaktadır. Örneğin, [112]'de Portekiz'de kısa dönem rüzgâr gücünü tahmin etmek için hibrid bir PSO-ANFIS yaklaşımı kullanmışlardır. Gözlenen ve tahmin edilen rüzgâr gücü arasındaki hatayı azaltmak için üyelik fonksiyonlarının parametreleri PSO kullanılarak ayarlanmıştır. 1995'ten 2005'e kadar İran'daki aylık elektrik tüketim verisini kullanarak elektrik tüketimini tahmin etmek için hibritleştirilmiş bir ANFIS, bilgisayar simülasyonu ve zaman serileri algoritması [113] tarafından kullanılmıştır. [114]'de hava durumu, zaman, tarihsel veri ve üretim süreci esnasındaki yük tahmininde rastgele oluşan bozulmaların etkisini araştırmak için bulanık kümeleri kullanmışlardır. Bu araştırmacılar araştırmalarının neticesinde, üretim planlaması ve birim mutabakat kararları için Ürdün'ün kısa dönem yüklerini tahmin etmişlerdir. Avustralya'nın Victoria eyaletindeki elektrik talebini tahmin etmek için YSA ve evrimsel bulanık sinir ağını (Evolving Fuzzy Neural Network (EFuNN)) eğitecek şekilde bir ölçekli eşlenik gradyan algoritması (Conjugate Gradient Algorithm (CGA)) ve GY algoritması kullanılmıştır [115]. Bu araştırmacılar, sinirsel-bulanık sistemin performansının, sinir ağları ve ARIMA modellerinden daha iyi olduğu sonucuna varmışlardır. Zaman serileri aylık verileri kullanarak orta dönem elektrik yük tahminini çözümlmek için ANFIS tabanlı bir model, [116] tarafından sunulmuştur. Sonuçların Autoregresif (Autoregressive (AR)) ve ARMA modelleriyle mukayese edilmesi neticesinde, ANFIS modelinin sonuçlarının AR ve ARMA modellerinden daha iyi olduğu gösterilmiştir. [117]'de Kanada'nın Ontario eyaletine ait 1976-2005 yılındaki verileri kullanarak elektrik talebini modellemek için ANFIS'i kullanmışlardır. Bu modelin girdileri, nüfus, GSYİH, istihdam sayısı, konut sayımı, günün en sıcak ve en soğuk dereceleri idi. Sonuçlar, istihdamın elektrik talebini en çok

etkileyen parametre olduğunu göstermiştir. [118] bir sonraki haftanın elektrik yükü tahmin etmek için ANFIS kullanmışlardır. Burada, giriş değişkenleri yarım saatlik haftalık yük zaman seri verilerinden meydana gelmektedir. [119]'de nüfus, GSYİH, Gayri Safi Milli Gelir (GSMG), ithalat ve ihracat verilerini kullanarak Hindistanın elektrik talebini modellemek ve tahmin etmek için ANFIS kullanmışlardır. [120]'de bulanık mantık ve ANFIS kullanarak kısa dönem yük tahmin modelleri geliştirmişlerdir. Bu araştırmacılar, giriş değişkenleri olarak tarihsel yük, sıcaklık ve mevsimi kullanmışlardır. ANFIS modelinin kestirim yeteneği, [121] tarafından gösterilmiş olup, Tayvan'daki bölgesel elektrik yüklerine uygulanmıştır. Gelecekteki birkaç yıl için enerji tüketimini tahmin edecek şekilde yük tahmini için tarihsel enerji verilerini kullanarak bir sinirsel-bulanık yöntem sunmuşlardır [122]. [123] eksiltici kümeleme tekniğini GA ile hibritleyerek ANFIS'i geliştirmiş ve İran'ın sanayi sektörünün elektrik tüketimini tahmin etmek için uygulamıştır. GA, minimum sayıda kural ve hatayı garantileyen küme yarıçapının optimum değerini bulmak için kullanılmıştır. Hem doğruluk hem de kural sayısı için, hibrit yaklaşım, girdi bölümlenme, bulanık c-araçları ve eksiltici kümelenmeye dayalı geleneksel ANFIS'den daha iyi performans göstermiştir. Kısa dönem yük tahmin uzman sistemleri ve kontrolörleri için yeni bir genetik tabanlı uyarlamalı sinirsel-bulanık çıkarım sistemi (GBANFIS) sunulmuştur [124]. GA önce modeli oluşturacak şekilde girdilerin en uygun özelliğini bulmak için, daha sonraki aşamada ise kurallar arasındaki ağırlıkları optimize etmek için kullanılır. GBANFIS, İran'ın aylık enerji talebini tahmin etmek için kullanılır ve regresyona, GA'ya, simüle tabanlı GA'ya, YSA'ya, benzetim tabanlı YSA'ya, bulanık karar ağacı ve benzetim tabanlı ANFIS yaklaşımlarına göre daha iyi sonuçlar verir. Elektrik dağıtım şebekesine bağlı müşteri sayısı, sıcaklık ve yağmur yağı eksojen değişkenleri olarak, elektrik yük zaman serilerini tahmin etmek için mevsimsel otoregresif entegre hareketli ortalama (SARIMAX) ve ANFIS modelleri kullanılmıştır [125]. ANFIS modeli SARIMAX modelinden daha düşük tahmin hatası değerleri vermiştir. Bu nedenle, ANFIS modelinin, elektrik yükü zaman serisi tahmini için SARIMAX modelinden daha iyi sonuç verdiği sonucuna varılmıştır. [126] yük tahmini için hava durumu verilerini kullanarak DR, YSA ve ANFIS modellerini geliştirip karşılaştırmışlar ve ANFIS modelinin daha doğru sonuçlar verdiğini bulunmuşlardır. Ürdün sanayi sektörünün elektrik tüketimi, çok değişkenli DR ve

sinirsel-bulanık yöntemler kullanılarak modellenmiş ve tahmin edilmiştir [127]. Bu yöntemlerde kullanılan değişkenler, elektrik tarifeleri, akaryakıt fiyatları, üretim çıktıları, kapasite kullanımları, işyeri sayısı, çalışan sayısı ve yapısal etkilerdir. MSE'yi kullanan yöntemlerin karşılaştırılması, sinirsel-bulanık yöntemin çok değişkenli DR yönteminden daha iyi performans ortaya koyduğunu göstermiştir. İki farklı strateji gözönüne suretiyle, Hibrid Sinirsel Bulanık Çıkarım Sistemine (Hybrid neural Fuzzy Inference System (HyFIS)) dayanan bir yöntem kullanarak elektrik tüketimini tahmin etmişlerdir [128]. İlk stratejide, giriş sadece elektrik tüketiminden oluşuyor iken ve ikinci stratejide elektrik tüketimi ile çevresel sıcaklığın birleşiminden oluşuyordu. Sonuçlar, ikinci stratejinin daha iyi sonuçlar verdiğini, dolayısıyla HyFIS'in farklı bilgi kaynaklarını birleştirmek için uygun bir yaklaşım olduğunu göstermiştir.

4.3. Uzun Süreli Elektrik Tüketimi Tahmini İçin ANFIS Modeli

Amacımız, sosyo-ekonomik değişkenleri kullanarak Uganda'nın elektrik tüketimi için doğru bir ANFIS tahmin modeli elde etmek ve onu kolaylıkla yorumlayacak şekilde modellemektir. Uzun dönem elektrik tahmini için oluşturulan ANFIS yöntemi, Şekil 4.5'te gösterildiği gibi dört giriş ve bir çıkışa sahiptir. ANFIS'in yorumlanabilirliği yapısıyla alakalıdır. Bu nedenle bir ANFIS yöntemini kolayca yorumlamak için "IF-THEN" kurallarının sayısı ile yapısına ve giriş değişkenlerinin sayısına bakarız. Diğer bir deyişle, daha az sayıda kural sayısı ve daha az sayıda giriş değişkeni olduğunda, ANFIS modelini yorumlamak daha kolay olacaktır.



Şekil 4.5. Elektrik tüketimi tahmini için ANFIS modeli

Diğer taraftan doğruluk, bir ANFIS yönteminin, modellenmiş sistemi ne kadarlık bir doğruluk ile tahmin edebileceği ile alakalıdır. Doğruluk genellikle yüzde olarak ölçülür [129]. Yüzde ne kadar yüksek olursa ANFIS yöntemi de o kadar doğrudur. Yorumlanabilirliği gerçekleştirebilmek için, veri setimizi, girişleri içine alan kümeler ve bunlara karşılık gelen çıkışlar olmak üzere dört kümeye bölecek şekilde FCM kümeleme kullandık. Her küme için bir kural oluşturulur ve Şekil 4.6.'da gösterildiği gibi toplam dört kural verilir.

-
- '1. If (*in1* is *in1cluster1*) and (*in2* is *in2cluster1*) and (*in3* is *in3cluster1*) and (*in4* is *in4cluster1*) then (*out1* is *out1cluster1*) (1)'
- '2. If (*in1* is *in1cluster2*) and (*in2* is *in2cluster2*) and (*in3* is *in3cluster2*) and (*in4* is *in4cluster2*) then (*out1* is *out1cluster2*) (1)'
- '3. If (*in1* is *in1cluster3*) and (*in2* is *in2cluster3*) and (*in3* is *in3cluster3*) and (*in4* is *in4cluster3*) then (*out1* is *out1cluster3*) (1)'
- '4. If (*in1* is *in1cluster4*) and (*in2* is *in2cluster4*) and (*in3* is *in3cluster4*) and (*in4* is *in4cluster4*) then (*out1* is *out1cluster4*) (1)'
-

Şekil 4.6. ANFIS kuralları

Bu kurallarda, *in1* = nüfus, *in2* = GSYİH, *in3* = abone sayısı, *in4* = ortalama elektrik fiyatı ve *out1* = elektrik tüketimidir. Benzer şekilde, “*inX* is *inXclusterY*” demek, *Y* kümesindeki *X* girişi demek olup, “*out1* is *out1clusterY*” demek *Y* kümesindeki 1 çıkışı demektir.

Her bir giriş dört üyelik fonksiyonu ile ve her bir çıkış ise bir üyelik fonksiyonu ile tanımlanır. Her bir küme, her bir giriş için sekiz ($2 \times 4 = 8$) ve her bir çıkış için ise beş (5) olmak üzere toplamda on üç (13) ayarlanabilir parametreye sahiptir. Dört kümenin tamamı için toplam parametre sayısı elli ikidir (52). Bir öğrenme süreci üzerinden ANFIS parametrelerini ayarlamak için bir öğrenme algoritması kullanılır. GY algoritması ve GY ile OLS algoritmalarının hibriti, geleneksel ANFIS öğrenme algoritmalarıdır. Zincir kuralının kullanımı problemin birçok yerel minimumuna takılmasına neden olabileceğinden ve her öğrenme adımında gradyanın hesaplanması zor olduğundan, ANFIS için eğitim yöntemlerinin çoğu, gradyan iniş yaklaşımına dayanır [130][131][132]. Gradyan yöntemi yerel bir arama yöntemi olarak bilinir ve performansı, genel optimal öğrenme oranını bulmayı zorlaştıran parametrelerin başlangıç değerine bağlıdır [133]. Yukarıdaki belirtilen geleneksel ANFIS öğrenme

algoritmalarının aksine, PSO ve GA'lar daha az karmaşıklığa ve hızlı yakınsamaya sahiptir. Bu nedenlerden ötürü, bu çalışmada, ANFIS parametrelerini ayarlamak için PSO ve GA'ları öğrenme algoritmalarını kullanmayı tercih ediyoruz. PSO algoritması bölüm 3.2'de açıklanmıştı. Bir sonraki bölümde ise GA kısaca tarif edilecektir.


4.4. Genetik Algoritma

Genetik algoritma (GA), biyolojik süreçlerin evrimine dayanan olasılıksal (rastgele) bir optimizasyon tekniğidir. GA, arama uzayında rastgele bir başlangıç çözümü ile başlar ve bu ilk çözüm grubu bir popülasyon olarak adlandırılır. Popülasyon, belirli bir durdurma kriterine ulaşılan kadar genetik operatörleri kullanarak çok sayıda iterasyon neticesinde geliştirilir. GA'nın temel operatörleri seçilme, çaprazlama ve mutasyondur. Seçilme, üremeyi sağlayacak bireyleri seçmek için kullanılmaktadır. Seçilme prosedürü, popülasyon içindeki bireylerin uygunluk olasılığına bağlıdır. Bir bireyin uygunluğu ne kadar yüksekse, seçilme olasılığı da o kadar yüksektir. Seçilme olasılığı (4.14) denklemi esas alınarak hesaplanır.

$$P_i = \frac{F_i}{\sum_{k=1}^n F_k} \quad (4.14)$$

Burada, F_i , i çözümünün uygunluk değeri ve n , popülasyon büyüklüğüdür. Yaygın seçilme prosedürleri, rulet tekerleği seçimi (roulette wheel selection), uygunluk sıralaması ve turnuva seçimidir.

Seçilme prosedüründen sonra seçilmiş bireylere çaprazlama operatörü uygulanır. İki veya daha fazla çözümün genetik malzemesi, daha iyi bir çözüm oluşturmak için bir çaprazlama hızı kullanılarak birleştirilir. Mutasyon operatörü, daha geniş bir arama uzayına olanak sağlayacak şekilde yeni popülasyonda çeşitlilik yaratmak için kullanılır. GA'nın akış diyagramı ise Şekil 4.7.'deki gibi verilir.



Şekil 4.7. GA akış diyagramı


4.5. PSO ve GA ile ANFIS Eğitimi

PSO-ANFIS ve GA-ANFIS modellerinde, ANFIS, optimizasyon problemine potansiyel bir çözüm sunan parçacık veya birey olarak gözönüne alınır. ANFIS'ın öncül ve sonuç parametreleri problemin boyutlarıdır. Bir öğrenme algoritması ile eğitim süreci, üyelik fonksiyonlarının parametrelerini, girişleri çıkışlara eşleştirecek şekilde ayarlar. Bu çalışmada, Şekil 4.5.'de gösterilmiş olan ANFIS modelinin giriş ve çıkış üyelik fonksiyon parametrelerini ayarlamak için PSO algoritmasını ve GA'yı kullanıyoruz. Problemin boyutu, ayarlanacak olan parametrelerin sayısıdır. Tüm veri seti, 0,7/0,3 oranında rastgele bir şekilde bir eğitim ve bir test veri setine bölünmüştür. PSO ve GA parametreleri, popülasyon büyüklüğü = 100, maksimum iterasyon sayısı = 1000, alt ve üst sınır aralığı $[-10, 10]$, $c_1 = c_2 = 2,1$, çaprazlama oranı = 0,7 ve mutasyon oranı = 0,15 olacak şekilde belirlenmiştir. Durdurma kriteri maksimum iterasyon sayısı olarak alınmıştır. Modeli eğitmek için ana prosedürün sözde kodu Şekil 4.8.'de gösterilmiştir.

-
1. Veri setini yükle
 2. Temel FIS'ı oluştur
FIS parametrelerini ayarla
 3. FIS Eğitimi
Algoritma seç (PSO veya GA)
 4. Eğitimli ANFIS
 5. Test veri setini kullanarak eğitimli ANFIS'ı test et
 6. Tahmin veri setini kullanarak tahminler yap
-

Şekil 4.8. Ana prosedürün sözde kodu

Önerilen yaklaşımın uygulaması ise Şekil 4.9.'da gösterilmiştir.




Şekil 4.9. Önerilen ANFIS yaklaşım uygulaması


Eğitilmiş ANFIS modeli, öngörülen giriş değişkenlerini kullanarak elektrik tüketimini tahmin etmek için kullanılır (bkz. Bölüm 2.4).

4.6. Sonuçlar

Eğitim süreci birkaç kez gerçekleştirilmiş ve her defasında RMSE ve MAPE değerleri kaydedilmiştir. Burada amaç, en iyi, yani en düşük değerleri elde etmektir. Şekil 4.10. ve Şekil 4.11.'de verilen grafikler, sırasıyla eğitim ve test veri setinde PSO-ANFIS eğitiminin örnek sonuç çıktılarını göstermektedir.




Şekil 4.10. Eğitim veri setindeki PSO-ANFIS sonuç çıktıları




Şekil 4.11. Test veri setindeki PSO-ANFIS sonuç çıktıları

Şekil 4.12. ve Şekil 4.13.'te verilen grafikler ise, sırasıyla eğitim ve test veri setinde GA-ANFIS eğitiminin örnek sonuç çıktıları göstermektedir.



Şekil 4.12. Eğitim veri setindeki GA-ANFIS sonuç çıktıları



Şekil 4.13. Test veri setindeki GA-ANFIS sonuç çıktıları

Her iki algoritma için en iyi RMSE ve MAPE değerleri ise Tablo 4.1.'de gösterilmiştir.

Tablo 4.1. ANFIS eğitiminden sonra RMSE ve MAPE değerleri

PSO-ANFIS tahmini			GA-ANFIS tahmini		
RMSE	(%)MAPE	(%)Doğruluğu	RMSE	(%)MAPE	(%)Doğruluğu
1,4707	9,1164	90,8836	0,8977	5,6543	94,3457

Tablo 4.1.'den, GA eğitilmiş ANFIS, hem RMSE hem de MAPE için PSO eğitilmiş ANFIS'ten daha düşük değerler vermektedir. Bu nedenle GA-ANFIS'in PSO-ANFIS modelinden daha iyi bir tahmin modeli olduğunu söyleyebiliriz. Giriş (c_i ve σ_i) ve çıkış (p_i, q_i, r_i, s_i ve t_i) için eğitim sonundaki ayarlanmış parametrelere göre her bir kümedeki her bir değişken için üyelik fonksiyonları Tablo 4.2.'den Tablo 4.5.'ye kadar gösterilmiştir.

Tablo 4.2. GA-ANFIS giriş üyelik fonksiyon parametreleri

	c_i				σ_i			
	Nüfus	GSYİH	Aboneler	Fiyatlar	Nüfus	GSYİH	Aboneler	Fiyatlar
Cluster 1	8,3422	-16,0665	0,1826	0,9613	-47,4991	62,2421	-1,7039	-4,2939
Cluster 2	-28,3973	73,5477	0,2590	1,2595	87,4971	161,5436	3,1175	-1,1825
Cluster 3	7,4030	2,3957	0,3108	1,5715	106,6436	36,8457	0,0514	0,7184
Cluster 4	-0,2418	-53,1836	0,0921	10,0964	17,7457	-13,6753	-1,0355	-4,8405

Tablo 4.3. GA-ANFIS çıkış üyelik fonksiyon parametreleri

	p_i	q_i	r_i	s_i	t_i
Cluster 1	0,0394	0,8070	350,6072	-5,9580	26,7190
Cluster 2	-0,0481	-0,3026	35,2539	1,5201	4,5978
Cluster 3	-0,0712	-0,1930	36,0973	-0,7921	22,0959
Cluster 4	-0,2162	0,1536	-123,6614	-2,7590	-7,7715


Tablo 4.4. PSO-ANFIS giriş üyelik fonksiyon parametreleri

	c_i				σ_i			
	Nüfus	GSYİH	Aboneler	Fiyatlar	Nüfus	GSYİH	Aboneler	Fiyatlar
Cluster 1	5,1784	7,6310	0,9408	1,5529	61,9177	3,1210	0,1390	1,6332
Cluster 2	4,6763	5,6518	0,0804	0,7211	34,4430	17,7621	0,3404	2,3829
Cluster 3	9,4933	2,8764	0,0742	0,8047	22,3680	5,4896	0,5204	-1,7736
Cluster 4	-6,0896	-68,6463	-5,5083	4,7265	-14,2384	-129,8582	7,2960	112,9578


Tablo 4.5. PSO-ANFIS çıkış üyelik fonksiyon parametreleri

	p_i	q_i	r_i	s_i	t_i
Cluster 1	0,0090	0,4729	38,2469	-3,2428	1,2975
Cluster 2	-0,1323	0,2591	44,5746	-1,3313	4,4321
Cluster 3	0,0493	-0,1541	27,9494	-1,8586	0,5470
Cluster 4	-1,6204	-21,5475	-48,4896	-15,8601	0,8666

Eğitimden sonraki ANFIS modelleri sırasıyla Şekil 4.14. ve Şekil 4.15.'te gösterilmiştir.



Şekil 4.14. Eğitilmiş GA-ANFIS modeli



Şekil 4.15. Eğitilmiş PSO-ANFIS modeli

GA ve PSO ile eğitilmiş ANFIS'in Tablo 4.2.'den Tablo 4.5.'e kadar olan parametrelerin kullanılmasıyla, Tablo 4.6.'da gösterilen tüketim tahminleri elde edilmiştir. Bununla birlikte bizim amacımız, (3.4) denkleminde gösterildiği, gibi alt ve üst sınırlı aralık tahminleri elde etmektir.

Gözlenen yıllar için, yani 1990'dan 2016'ya kadar, GA-ANFIS ve PSO-ANFIS için hata tahmin denklemi (3.6), sırasıyla (4.15a) ve (4.15b) denklemlerindeki gibi gerçekleşir.

$$\widehat{e}_{ga} = -0,0073z + 14,664 \quad (4.15a)$$


$$\widehat{e}_{pso} = 0,0445z - 88,9887 \quad (4.15b)$$

(4.15a) ve (4.15b) denklemlerini kullanarak, 2016'dan 2040'a kadarki karesel $\widehat{e}_{ga}$ ve üstel $\widehat{e}_{pso}$ hatalarını tahmin etmiş olduk. Ardından, 2016'dan 2040'a kadar olan tahmin hatalarını ve $\alpha = 0,1$ değerini kullanarak, her yılın beklenen tahmin hatası, yani yıllık tahminin alt sınırı E_{lower} ve üst sınırı E_{upper} için % 90'lık tahmin aralığını elde edebilmiş olduk. Son olarak, E_{lower} , Y ve E_{upper} değerleri ile (3.5) denklemini kullanarak elde edilen gerçek elektrik tüketim değerlerinin % 90 anlam düzeyinde Tablo 4.6.'da görüldüğü gibi öngörülen aralık içerisinde olmasını bekliyoruz.

Tablo 4.6. Tahmin sonuçlarının ve MEMD tahmin raporunun karşılaştırılması

Yıl	Gerçek (GWh)	MEMD tahmini (GWh)			ANFIS tahmini (GWh)				
		Base case	Vizyon 2040	PSO Alt	PSO	PSO Üst	GA Alt	GA	GA Üst
2015	3.219	4.645	25.506	2.675	3.219	3.408	2.666	3.269	3.479
2016	3.499	6.665	31.090	3.237	3.780	3.970	3.035	3.637	3.847
2017	3.715	7.114	37.035	3.900	4.444	4.633	3.682	4.284	4.494
2018		7.591	43.358	4.803	5.347	5.537	4.496	5.099	5.309
2019		8.099	50.077	6.069	6.614	6.803	5.661	6.264	6.474
2020		8.638	57.214	7.281	7.825	8.015	6.755	7.358	7.568
2021		9.211	64.790	8.638	9.182	9.372	8.026	8.629	8.839
2022		9.819	72.825	10.093	10.638	10.828	9.395	9.997	10.207
2023		10.370	81.344	11.504	12.049	12.239	10.695	11.298	11.508
2024		10.992	90.370	12.920	13.465	13.656	11.999	12.602	12.812
2025		11.648	99.927	14.368	14.914	15.104	13.303	13.906	14.116
2026		12.338	110.033	15.796	16.343	16.533	14.626	15.228	15.438
2027		13.064	120.723	17.319	17.866	18.056	15.977	16.579	16.789
2028		13.828	132.026	18.857	19.404	19.594	17.363	17.966	18.176
2029		14.632	143.973	20.400	20.947	21.138	18.797	19.400	19.610
2030		15.453	156.320	22.180	22.728	22.919	20.298	20.901	21.111
2031		16.289	169.042	23.847	24.395	24.586	21.876	22.479	22.689
2032		17.138	182.087	25.553	26.102	26.293	23.413	24.016	24.226
2033		17.994	195.410	27.248	27.797	27.988	24.975	25.578	25.787
2034		18.857	208.961	28.909	29.458	29.650	26.557	27.160	27.370
2035		19.721	222.688	30.651	31.201	31.392	28.095	28.698	28.908
2036		20.584	236.534	32.330	32.880	33.072	29.670	30.273	30.483
2037		21.441	250.440	34.072	34.623	34.815	31.213	31.816	32.026
2038		22.289	264.345	35.758	36.310	36.502	32.787	33.390	33.600
2039		23.124	278.183	37.504	38.056	38.249	34.323	34.926	35.136
2040		23.941	291.889	39.199	39.751	39.944	35.891	36.494	36.704

Elde edilen tahmin sonuçları, MEMD tarafından yapılan tahminler ile de karşılaştırılmıştır. Sonuçlardan görüldüğü üzere, GA-ANFIS yaklaşımına göre 2040 yılındaki Uganda'nın net elektrik tüketiminin 35.891 GWh ve 36.704 GWh aralığında gerçekleşmesi tahmin edilirken, PSO-ANFIS yaklaşımına göre 39.199 GWh ve 39.944 GWh aralığında gerçekleşmesi tahmin edilmektedir. Şekil 4.16.'daki grafik tüm tahminleri göstermektedir.



Şekil 4.16. Tahminlerin karşılaştırılması

2015, 2016 ve 2017 yıllarına ve özellikle Vizyon 2040'a ait MEMD tahminlerinin göreceli yüzde hataları çok yüksek iken, bunlara kıyasla bizim tahmin değerlerimizin göreceli yüzde hataları çok düşük kalır. Tahminler için göreceli yüzde hatalar Tablo 4.7.'de verilmiştir.

Tablo 4.7. Göreceli yüzde hataları

Yıl	% Göreceli Hata							
	MEMD			ANFIS				
	Base case	Vizyon 2040	Alt	PSO-ANFIS	Üst	Alt	GA-ANFIS	Üst
2015	44,30	692,36	-16,89	0,00	5,87	-17,17	1,55	8,07
2016	91,03	791,09	-7,49	8,03	13,46	-13,26	3,94	9,95
2017	91,49	896,90	4,98	19,62	24,71	-0,88	15,32	20,97

BÖLÜM 5. TAHMİN MODELLERİNİN BİRLEŞTİRİLMESİ

5.1. Giriş

Bu çalışmada, 2015 yılından 2040 yılına kadarki Uganda'nın elektrik tüketimini tahmin etmek için hibrit PSO-YAK ve ANFIS olmak üzere iki yaklaşım kullanılmıştır. Bu iki yaklaşımdan üstel, karesel, PSO-ANFIS ve GA-ANFIS tahmin modeli olmak üzere dört adet model oluşturulmuştur. Bu modellerden elde edilen sonuçlar gerçek tüketim ve MEMD tarafından yapılan tahminler ile karşılaştırılmıştır. Elde ettiğimiz sonuçlar, gerçek tüketim ile bağlantılı olarak MEMD ile karşılaştırıldığında göreceli olarak çok daha az hata göstermektedir. Bu bölümde ise, bu iki yaklaşım kullanılarak elde edilen dört modelin tamamı, son bir tahmin modeli elde etmek için birleştirilmiştir.

[134]'de tahmin yöntemlerini birleştirmenin, bireysel yöntemlerin avantajlarını kendi bünyesinde topladığını ve dezavantajlarını ortadan kaldırdığını söylemişlerdir. Birleştirmiş yöntemin tahmin sonucunun, özgün yöntemlerin tahmin sonuçlarından daha iyi olduğu kanıtlanmıştır. Ayrıca birleştirmiş yöntem, hataları düşürmeyi ve gerçek değerler ile tahmini değerler arasındaki doğruluğu etkin bir şekilde geliştirmeyi başarmıştır.

Birleştirme tahmin teorisi, belirli bir tahmin problemini çözmek için n çeşit tahmin tekniği olduğunda, uygun şekilde ayarlanmış ağırlık katsayıları ile birkaç tekniğin tahmin sonuçları toplanabilir. y_t ($t = 1, 2, \dots, m$) 'nin gerçek zaman serisi verisi olduğunu, t anındaki tahmin değerinin de f_{it} ($i = 1, 2, \dots, n$) olduğunu, w_i 'nin ve i nci tahmin yönteminin ağırlık katsayısı olduğunu varsaydığımızda, birleştirilmiş yöntemin tahmin değeri (5.1) denkleminde gösterildiği gibi hesaplanabilir.

$$\hat{y}_t = \sum_{i=1}^n \hat{w}_i f_{it}, t = 1, 2, \dots, m \text{ burada } \sum_{i=1}^n w_i = 1 \quad (5.1)$$

Benzer bir akıl yürütmeyi kullanarak, sonuçlarımızı nihai bir değer elde edecek şekilde birleştiriyoruz. Birleştirilmiş yöntemin tahmin sonucu aşağıdaki denklem ile ifade edilmektedir.

$$Y = w_{exp}Y_{exp} + w_{quad}Y_{quad} + w_{PSO-ANFIS}Y_{PSO-ANFIS} + w_{GA-ANFIS}Y_{GA-ANFIS} \quad (5.2)$$

Burada Y , birleştirilmiş yöntemin tahmini, $w_i Y_i$ 'ler ise, üstel, karesel, PSO-ANFIS ve GA-ANFIS modelleri olmak üzere, bir tahmin yönteminin ağırlık faktörünün bir sonucu ve onunla ilgili bireysel tahmin modelidir. Birleştirmiş yöntemde her bir tahmin yönteminin ağırlık katsayılarının belirlenmesi önemli bir konudur. Çünkü birleştirmiş yöntemin tahmin yeteneği, birleştirilen yöntemlerin ağırlık katsayılarına bağlıdır. Uygun ağırlık katsayılarına sahip birleştirilmiş bir yöntem, iyi tahmin sonuçlarına ulaşabilir. Aksine, uygun olmayan parametrelere sahip bir birleştirmiş yöntemin tahmin sonuçları, tek bir yöntemin tahmin sonuçlarından daha da kötü olur.

5.2. Modellerin Birleştirmesi

En basit ve en açık yöntem, birleştirilmiş yöntemdeki ağırlık katsayılarını eşit olarak dağıtmak olmakla birlikte, bu çalışmada ağırlıklar her bir tahminin doğruluğuna göre atanmıştır. Çalışmada kullanılan yaygın doğruluk ölçüsü MAPE olup ağırlıklar buna göre belirlenir. En yüksek doğruluk değerine, yani en düşük MAPE değerine sahip olan tahmine, daha yüksek ağırlık değeri ve en düşük doğruluk değerine, yani en yüksek MAPE değerine sahip olan tahmine ise daha az ağırlık değeri atanır. Her bir tahminin ağırlık faktörü, tahmin doğruluğuna (MAPE değerleri) dayanarak hesaplanır, yani daha doğru tahmin, yüksek bir ağırlık faktörüne sahip olup en az doğru tahmin, düşük bir ağırlık faktörüne sahiptir. Ağırlık faktörleri aşağıdaki denklem kullanılarak hesaplanmıştır.

$$w_i = \frac{(MAPE)^{-1}}{\sum_{i=1}^4 (MAPE)^{-1}}, \text{ ve } \sum_{i=1}^4 w_i = 1 \quad (5.3)$$

Her bir tahmin için MAPE değerlerini kullanarak, (5.2) denklemi ile verilen birleştirilmiş yöntemin tahmin sonucu aşağıdaki gibi elde edilir.

$$Y = 0,3791Y_{exp} + 0,4645Y_{quad} + 0,0598Y_{PSO-ANFIS} + 0,0966Y_{GA-ANFIS} \quad (5.4)$$

Birleştirilmiş yöntemin tahmin hatası ise aşağıdaki gibi ifade edilir.

$$e_t = y_t - \hat{y}_t = \sum_{i=1}^n w_i y_t - \sum_{i=1}^n w_i f_{it} = \sum_{i=1}^n w_i (y_t - f_{it}) = \sum_{i=1}^n w_i e_{it} \quad (5.5)$$

Bununla birlikte, tahminlerin her birinin alt ve üst sınırları olduğundan, birleştirilmiş tahminin alt ve üst sınırlarını elde etmek için (5.4) denklemini her bir tahminin üstüne ve altına uyguluyoruz. Tahmin sonuçlarımızı geleneksel istatistik yöntemlerle karşılaştırmak için, elektrik tüketimini ÇDR yöntemini kullanarak da modelliyoruz. ÇDR modelinin regresyon istatistikleri, katsayıları ve model performans ölçüm değerleri Tablo 5.1.'de gösterilmiştir.

Tablo 5.1. ÇDR modelinin regresyon istatistikleri, katsayıları ve performans ölçüm değerleri

Regresyon Analizi				Performans ölçüm	
Regresyon İstatistikleri		Regresyon Katsayıları		değerleri	
R-Kare	0,8682	Kesişim	-0,8025	RMSE	MAPE (%)
Düzeltilmiş R Kare	0,8388	Nüfus	0,2900	6,1025	19,0344
18 sd standart hata	1,6389	GSYİH	0,1322		
F-değeri 4 ve 18 sd	29,6385	Abone sayısı	18,2719		
p-değeri	1,059e-07	Fiyatlar	-0,5442		

(5.4) denklemi kullanılarak elde edilen birleştirilmiş modelin tüketim tahmini ile, MEMD ve ÇDR modelin tahminleri Tablo 5.2.'de gösterilmiştir.

2015, 2016 ve 2017 MEMD tahminleri, dört tahmin modeli, birleştirilmiş model ve ÇDR modeli arasındaki göreceli yüzde hatalarının karşılaştırılması Tablo 5.3.'de gösterilmiştir.

Tablo 5.2. MEMD, birleştirilmiş ve ÇDR tahminlerinin karşılaştırılması

Yıl	Gerçekleşen (GWh)	MEMD (GWh)		Birleştirilmiş (GWh)			ÇDR (GWh)
		Base case	Vizyon 2040	Alt	Tahmini	Üst	
2015	3.219	4.645	25.506	2.627	2.854	3.410	2.738
2016	3.489	6.665	31.090	3.062	3.289	3.846	3.033
2017	3.715	7.114	37.035	3.560	3.788	4.345	3.400
2018		7.591	43.358	4.250	4.479	5.037	3.874
2019		8.099	50.077	5.209	5.438	5.997	4.524
2020		8.638	57.214	6.190	6.419	6.979	5.147
2021		9.211	64.790	7.306	7.535	8.097	5.848
2022		9.819	72.825	8.500	8.730	9.293	6.596
2023		10.370	81.344	9.711	9.941	10.505	7.318
2024		10.992	90.370	10.983	11.214	11.780	8.044
2025		11.648	99.927	12.363	12.594	13.162	8.780
2026		12.338	110.033	13.704	13.936	14.505	9.513
2027		13.064	120.723	15.317	15.549	16.120	10.284
2028		13.828	132.026	17.028	17.260	17.833	11.067
2029		14.632	143.973	18.590	18.823	19.397	11.856
2030		15.453	156.320	20.664	20.897	21.473	12.731
2031		16.289	169.042	22.325	22.558	23.136	13.582
2032		17.138	182.087	24.344	24.578	25.158	14.443
2033		17.994	195.410	26.247	26.482	27.063	15.302
2034		18.857	208.961	28.085	28.321	28.905	16.155
2035		19.721	222.688	30.413	30.649	31.235	17.027
2036		20.584	236.534	32.271	32.508	33.096	17.882
2037		21.441	250.440	34.479	34.716	35.307	18.751
2038		22.289	264.345	36.473	36.711	37.304	19.609
2039		23.124	278.183	39.125	39.364	39.959	20.484
2040		23.941	291.889	41.296	41.535	42.133	21.344

Tablo 5.3. MEMD tahmini ve bu çalışma'nın tahmin modelleri arasındaki göreceli yüzde hatalarının karşılaştırılması

Yıl	MEMD tahmini		Bu Çalışma'nın tahmin modelleri					
	Base case	Vizyon 2040	Üstel	Karesel	PSO-ANFIS	GA-ANFIS	Birleştirilmiş	ÇDR
2015	44,3	692,4	-11,5	-15,3	0,0	1,6	-11,3	-14,94
2016	91,0	791,1	-8,6	-7,2	8,3	4,2	-5,7	-13,07
2017	91,5	896,9	-0,4	-1,1	19,6	15,3	2,0	-8,48
Ortalama	75,6	793,5	-6,8	-7,9	9,3	7,0	-5,0	-12,16

Sonuçlar değerlendirildiğinde, birleştirilmiş modelin genel olarak, bireysel tahmin modellerinden daha düşük göreceli tahmin hataları verdiği gözlemlenmiştir. Bu

nedenle, birleştirilmiş model tahminlerinin, bireysel tahmin yöntemlerine kıyasla tahmin doğruluğunu artırdığını söyleyebiliriz. Ayrıca, hesaplamalı zeka yöntemlerinin ÇDR yönteminden daha düşük göreceli tahmin hataları verdiği de sonuçlardan görülmektedir. Bu, hesaplamalı tahmin yaklaşımlarının ÇDR yönteminden daha iyi sonuçlar verdiğini göstermektedir. Bu sonuç, hibrit hesaplamalı zeka yöntemlerinin geleneksel istatistiksel yöntemlerden daha iyi tahmin sonuçları verdiğini gösteren önceki çalışmalarla uyumludur [72][73][74].



BÖLÜM 6. SONUÇLAR VE ÖNERİLER

6.1. Sonuçlar

Uganda Vizyon 2040 kapsamında ifade edildiği gibi Uganda gelişim hedefleri, kalkınma sürecinde elektriği anahtar değişken olarak tanımlamaktadır. Bu nedenle elektrik sektöründe planlama daha önce hiç olmadığı kadar vurgulanmalıdır. Planlama sürecindeki kritik girdilerden biri gerçekçi ve ulaşılabilir tahmin hedefleridir. Bu çalışmada, sosyo-ekonomik değişkenlere bağlı olarak Uganda'nın elektrik tüketimi için üstel, karesel ve ANFIS tahmin modelleri önerilmiştir. Çalışmada gözönüne alınan sosyo-ekonomik (bağımsız) değişkenler; nüfus, GSYİH, toplam elektrik abone/müşteri sayısı ve ortalama elektrik fiyatlarıdır. Yine bu çalışmada 27 yıllık (1990-2016) tarihsel veriler kullanılmıştır. Üstel ve karesel tahmin modellerinin parametrelerini optimize etmek için PSO ve YAK algoritmalarına dayalı hibritleştirilmiş bir algoritma kullanılmıştır. ANFIS tahmin modelinin parametreleri ise, PSO ve GA kullanılarak ayarlanmıştır. Bu çalışmadan aşağıdaki sonuçlar çıkarılabilir.

Beklendiği gibi, Uganda'daki elektrik tüketimi yıllar içinde artış eğilimi göstermektedir. Regresyon analizine ve korelasyon katsayılarına dayanarak, Uganda'nın elektrik tüketim yörüngesini etkileyen en etkin değişkenin abone sayısı olduğunu belirtebiliriz. Artan abone sayısına rağmen, elektrik fiyatlarındaki artış tüketim için büyük bir sorun haline gelmektedir. Elektrik fiyatlarındaki artışın, tüketimde düşüşe neden olması kaçınılmazdır. Nüfusun büyük bir kısmı ulusal şebekeye bağlanmayan kırsal bölgelerde yaşadığından dolayı, nüfusun, abone sayısından ziyade elektrik tüketimi üzerinde daha az etkisi vardır. Uganda'nın GSYİH'sine en büyük katkıyı sağlayan tarım sektörünü hizmetler sektörü takip etmektedir. Bu sektördeki abone sayısının (ticari aboneler), en az elektrik tüketenlerden olduğu (% 10) ve elektrik tüketiminin tarım sektöründe neredeyse hiç

olmadığını ve bununla ilgili herhangi bir veri de kaydedilmediğini görüyoruz. Bunun neticesinde, GSYİH'nin elektrik tüketimi üzerindeki etkisi daha az olmaktadır.

Üstel ve karesel tahmin modelleri için aşağıdaki sonuçlar çıkarılabilir:

- MAPE ve R^2 değerlerine göre karesel tahmin modeli, üstel tahmin modelinden daha iyidir.
- Üstel modelinin tahmin doğruluğu %98,5613, karesel modelin ise %98,8259 olarak gerçekleşmektedir.
- Dahası sonuçlar, karesel tahmin modelinde, 2015 ile 2040 arasında elektrik tüketimindeki ortalama artışın her yıl %11,2 ila %12,4 arasında olacağına işaret etmektedir. Üstel tahmin modelinde ise aynı yıllar arasında elektrik tüketiminde her yıl ortalama %10,1 ila %11,3 arasında bir artış oranı öngörülmektedir. Bu, önerilen modellerin uygun enerji politikalarını formüle etmek için politika yapıcılara ve enerji planlayıcılarına yardımcı olabilecek olan araçlar sağlar.

ANFIS modeli için çalışmanın sonuçları bizi aşağıdaki sonuçlara götürmüştür;

- RMSE ve MAPE değerlerine göre sonuçlar, GA kullanılarak eğitilen ANFIS modelinin, PSO kullanılarak eğitilen ANFIS modeline kıyasla daha iyi bir model olduğunu göstermektedir.
- Kolay yorumlanabilirlik açısından, dört giriş ve bir çıkışı kullanan sadece dört kural ile ANFIS'ı, modelleme gerçekleştirilmiştir.
- GA-ANFIS ve PSO-ANFIS modellerinin her ikisi de iyi tahmin doğruluğu göstermiştir. GA-ANFIS ve PSO-ANFIS modelleri kullanılarak elde edilen tahmin doğrulukları sırasıyla %94,3457 ve %90,8836 olarak gerçekleşmiştir.
- Sonuçlar ayrıca, GA-ANFIS tahmin modelinde, 2015 ile 2040 yılları arasında elektrik tüketimindeki ortalama artışın her yıl %9,99 ila %11,12 arasında olacağına işaret etmektedir. PSO-ANFIS tahmini modelinde ise aynı yıllar arasında elektrik tüketiminde her yıl ortalama %10,46 ila %11,51 arasında bir artış oranı olacağı öngörülmektedir.

Genel olarak aşağıdaki sonuçlar çıkarılabilir:

- Regresyon analizi, seçilen bağımsız değişkenlerin bağımlı değişkeni tahmin etmek için yeterli olduğunu göstermiştir.
- Zaman serileri tahmini için YSA yaklaşımı kullanılarak bağımsız değişkenlerin tahmini değerlerine dayanılarak tahmin yapılmıştır. Çünkü tahmini değerler verilerin elde edildiği veri kaynaklarında hazır değildir. Bağımsız değişkenlerin tahmininde ortaya çıkan tahmin hataları, önerilen modellerin tahmin doğruluğunu etkilemiş olabilir.
- Gerçek tahminler, MEMD tarafından yapılan tahminler ile karşılaştırıldığında, üç modelin (üstel, karesel ve ANFIS) tamamı ve birleştirmiş model için tahmin sonuçlarımız çok düşük göreceli yüzde hatalar göstermektedir. ÇDR modeli, MEMD tahminlerinden daha iyi sonuçlar vermiş olmasına rağmen, üstel, karesel, ANFIS ve birleştirmiş tahmin modellerinin ÇDR modelinden çok daha iyi sonuçlar verdiği gözlemlenmiştir. Bu, elektrik tüketiminin tahmini için kullanıldığı zaman, hesaplamalı zekâ yöntemlerinin geleneksel istatistiksel ve ekonometrik yöntemlerle karşılaştırıldığında daha iyi sonuçlar vermiş olan önceki sonuçlar ile uyumludur.
- Tahminlerle ilgili belirsizlikleri yakalamak için, %90 anlam düzeyindeki tahminler ile birlikte hataların alt ve üst sınırlarını elde etmek için tahmin edilen artıklar modellenmiştir. Tahmin edilen hatalar tahmin aralıklarını elde etmek için, üstel, karesel, ANFIS ve birleştirmiş modellerden elde edilen nokta tahminlerine eklenmiştir. %90 anlam düzeyinde, 2015, 2016 ve 2017 için gerçek elektrik tüketimi, dört tahmin modelinin tamamında da tahmin aralıklarımız içinde kalmaktadır.
- Birleşik tahminler, 2015, 2016 ve 2017 yıllarına ait ortalama göreceli yüzde hatalarına dayalı olarak düzeltilmiş tahmin sonuçları gösterir.
- Ayrıca, birleştirmiş tahmin modelinde, 2015 ile 2040 arasındaki elektrik tüketimindeki ortalama artışın, her yıl %10,64 ile %11,75 arasında olacağına işaret edilmektedir.

6.2. Öneriler

Elektrik tüketimi tahmini ile ilgili daha fazla araştırma için aşağıdaki önerileri sıralayabiliriz:

- Karşılaştırmalı sonuçlar elde etmek için, YSA, SVM/SVR, GM, rasgele ormanlar ve KA gibi diğer tahmin yaklaşımları da kullanılabilir.
- Bu çalışmada, Uganda'da elektrik tüketimini etkileyen faktörler olarak nüfus, GSYİH, toplam ihracat, toplam ithalat, abone sayısı ve ortalama elektrik fiyatları kullanılmıştır. Bu değişkenlerin seçimi mevcut verilere dayanmaktadır. Bu değişkenler ile elektrik tüketimi arasındaki regresyon ve korelasyon analizine dayanarak; nüfus, GSYİH, abone sayısı ve ortalama elektrik fiyatını etkili değişkenler olarak seçilmiştir. Uganda'da elektrik tüketimini etkileyen en etkili değişkenleri anlamaya yardımcı olmak için elektrik tüketimini etkileyen önemli değişkenlerin kapsamlı bir araştırmasının yapılması gerektiğini öneriyoruz. Aynı zamanda, kentleşme oranı, enerji tüketim yapısı, elektrik ihracatı, vb. gibi daha fazla değişkenin elektrik tüketimine etkisi incelenebilir.
- Uganda'daki elektrik tüketimi üzerindeki değişkenlerin etkisini araştırmak için, Akaike Bilgi Kriteri (Akaike Information Criteria (AIC)), Bayes Bilgilendirme Kriteri (Bayes Information Criteria (BIC)) ve Çapraz Doğrulama (Cross Validation (CV)) gibi diğer belirleyici seçim yöntemleri de kullanılmalıdır. Bu durum, etkili değişkenler kullanarak daha iyi tahmin modelleri geliştirmeye yardımcı olacaktır.
- Uganda'nın tüm sektörlerde net elektrik tüketimi tahmin edilmiştir. Elektrik tüketimini sektör bazında tahmin etmek, bu araştırmaya değer katacak ilginç bir alandır. Sanayi, ticaret, konut, tarım v.b. gibi farklı sektörler için elektrik tahmini yapılması, politika ve karar vericilere her sektörde ne kadar elektrik tüketildiğine dair daha ayrıntılı analizler verebilecektir. Bunun yapılmasını şiddetle öneriyoruz. Buna göre, her sektör için daha uygun yatırım kararları alınabilir ve ona uygun politikalar geliştirilebilir.

Elektrik talebini tahmin etmede, özellikle geliřmekte olan ÷lkelerdeki uzun dönemli tahminler için en büyük sorun, elektrik talebindeki hızlı artıřtır. Böyle ÷lkelerden biri olan Uganda için de bu sorun bir istisna deęildir. Bu çalışmanın araştırma topluluklarına katkısı ařaęıdaki şekillerde ifade edilebilir:

- Bu çalışma, Sahra-altı Afrika ÷lkeleri için elektrik tahminine yönelik daha ileri arařtırmalar için bir temel teşkil eder.
- Yine bu çalışma, politika belirleyicileri, enerji planlamacıları ve araştırma topluluklarına elektrik tüketim tahminlerine yönelik pratik önerilere dikkat çeker.



KAYNAKLAR

- [1] Mawejje, J., Mawejje, N., Electricity consumption and sectoral output in Uganda : an empirical investigation. *J. Econ. Struct.*, 5(21), 1–16, 2016.
- [2] Sekantsi, L. P., Okot, N., Electricity consumption – economic growth nexus in Uganda. *Energy Sources, Part B Econ. Planning, Policy*, 11(12) 1144–1149, 2016.
- [3] Yılmaz, H., Alp Özel B., Electricity Consumption and Economic Growth in Emerging Economies. *J. Knowl. Manag. Econ. Inf. Technol.*, 4(2), 2014.
- [4] Pempetzoglou, M., Electricity Consumption and Economic Growth : A Linear and Nonlinear Causality Investigation for Turkey. *International Journal of Energy Economics and Policy*, 4(2), 263–273, 2014.
- [5] Ozturk, I., A literature survey on energy-growth nexus. *Energy Policy*, 38(1), 340–349, 2010.
- [6] Kavaklioglu, K., Ceylan, H., Ozturk, H. K., Canyurt, O. E., Modeling and prediction of Turkey's electricity consumption using Artificial Neural Networks. *Energy Convers. Manag.*, 50(11), 2719–2727, 2009.
- [7] Urban, F., Benders, R. M. J., Moll, H. C., Modelling energy systems for developing countries. *Energy Policy*, 35(6), 3473–3482, 2007.
- [8] Brew-Hammond, A., Energy access in Africa: Challenges ahead. *Energy Policy*, 38(5), 2291–2301, 2010.
- [9] Hyndman, S., Fan R. J., Density forecasting for long-term peak electricity demand. *IEEE Trans. Power Syst.*, 25(2), 1142–1153, 2010.
- [10] Amjadi, M. H., Nezamabadi-pour, H., Farsangi, M. M., Estimation of electricity demand of Iran using two heuristic algorithms. *Energy Convers. Manag.*, 51(3), 493–497, 2010.
- [11] Kiran, M. S., Özceylan, E., Gündüz, M., Paksoy, T., Swarm intelligence approaches to estimate electricity energy demand in Turkey. *Knowledge-Based Syst.*, 36, 93–103, 2012.

- [12] Yu, S., Wei, Y. M., Wang, K., A PSO-GA optimal model to estimate primary energy demand of China, *Energy Policy*, 42, 329–340, 2012.
- [13] Assareh, E., Behrang, M. A., Assari, M. R., Ghanbarzadeh, A., Application of PSO (particle swarm optimization) and GA (genetic algorithm) techniques on demand estimation of oil in Iran. *Energy*, 35(12), 5223–5229, 2010.
- [14] Singh, A. K., Khatoon, S., An Overview of Electricity Demand Forecasting Techniques. 3(3), 38–48, 2013.
- [15] Almeshaiei, E., Soltan, H., A methodology for Electric Power Load Forecasting. *Alexandria Eng. J.*, 50(2), 137–144, 2011.
- [16] Debnath, K. B., Mourshed, M., Forecasting methods in energy planning models. *Renew. Sustain. Energy Rev.*, 88, 297–325, 2016.
- [17] Saleh, M. I., Syed, M. A., Principles of electricity demand forecasting. *Power Eng.*, 139–143, 1996.
- [18] Shuvra, S., Rahman M. A., Ali, M. M., Khan, A., Modeling and Forecasting Demand for Electricity in Bangladesh: Econometrics Model. *International Proceedings of Economics Development & Research*, 7, 2011.
- [19] Aydin, G., Modeling of energy consumption based on economic and demographic factors: The case of Turkey with projections. *Renew. Sustain. Energy Rev.*, 35, 382–389, 2014.
- [20] Suganthi, L., Samuel, A. A., Energy models for demand forecasting - A review. *Renew. Sustain. Energy Rev.*, 16(2), 1223–1240, 2012.
- [21] Kavaklioglu, K., Modeling and prediction of Turkey's electricity consumption using Support Vector Regression. *Appl. Energy*, 88(1), 368–375, 2011.
- [22] Ghods, L., Kalantar, M., Different Methods of Long-Term Electric Load Demand Forecasting ; A Comprehensive Review. *Iran. J. Electr. Electron. Eng.*, 7(4), 249–259, 2011.
- [23] Liu, X. Q., Ang, B. W., Goh, T. N., Forecasting of electricity consumption: a comparison between an econometric model and a neural network model. *Neural Networks, IEEE Int. Jt. Conf.* 1254–1259, 1991.
- [24] Amarawickrama H. A., Hunt, L. C., Electricity demand for Sri Lanka: A time series analysis. *Energy*, 33(5), 724–739, 2008.
- [25] Adams, F. G., Shachmurove, Y., Modeling and forecasting energy consumption in China: Implications for Chinese energy demand and imports in 2020. *Energy Econ.*, 30(3), 1263–1278, 2008.

- [26] Pokharel, S., An econometric analysis of energy consumption in Nepal. *Energy Policy*, 35(1), 350–361, 2007.
- [27] González, C. F., Miguel, R. E., Diego, A. J. M., Monthly Electric Energy Demand Forecasting Based on Trend Extraction. *IEEE Trans. Power Syst.*, 21(4), 1946–1953, 2006.
- [28] Al-Shobaki, S., Mohsen, M., Modeling and forecasting of electrical power demands for capacity planning. *Energy Convers. Manag.*, 49(11), 3367–3375, 2008.
- [29] Al-Hamadi, H. M., Soliman, S. A., Long-term/mid-term electric load forecasting based on short-term correlation and annual growth. *Electr. Power Syst. Res.*, 74(3), 353–361, 2005.
- [30] Egelioglu, H., Mohamad, F., Guven, A. A., Economic variables and electricity consumption in Northern Cyprus. *Energy*, 26(4), 355–362, 2001.
- [31] Yumurtaci, Z., Asmaz, E., Electric energy demand of Turkey for the year 2050. *Energy Sources*, 26(12), 1157–1164, 2004.
- [32] Al-Ghandoor, A., Al-Hinti, I., Jaber, J. O., Sawalha, S. A., Electricity consumption and associated GHG emissions of the Jordanian industrial sector: Empirical analysis and future projection. *Energy Policy*, 36(1), 258–267, 2008.
- [33] Geem, J., Tseng, Z. W., Kim, C. L., Bae, C., Trenchless Water Pipe Condition Assessment Using Artificial Neural Network. *Pipelines*, 1-9, 2007.
- [34] Sözen, M., Arcaklioğlu, A., Özkaymak, E., Turkey's net energy consumption. *Appl. Energy*, 81, 209–221, 2005.
- [35] Ermis, K., Midilli, A., Dincer, I., Rosen, M. A., Artificial neural network analysis of world green energy use. *Energy Policy*, 35(3), 1731–1743, 2007.
- [36] Sözen, E., Gülseven, A., Arcaklioğlu, Z., Forecasting based on sectoral energy consumption of GHGs in Turkey and mitigation policies. *Energy Policy*, 35(12), 6491–6505, 2007.
- [37] Sözen, E., Arcaklioglu, A., Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey. *Energy Policy*, 35(10), 4981–4992, 2007.
- [38] Geem, W. E., Roper, Z. W., Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, 37(10), 4049–4054, 2009.
- [39] Kankal, M., Akpınar, A., Kömürcü, M. I., Özşahin, T. Ş., Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Appl. Energy*, 88(5), 1927–1939, 2011.

- [40] Hong, W. C., Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model. *Energy Convers. Manag.*, 50(1), 105–117, 2009.
- [41] Pai, P. F., Hong, W. C., Support vector machines with simulated annealing algorithms in electricity load forecasting. *Energy Convers. Manag.*, 46(17), 2669–2688, 2005.
- [42] Niu, D., Wang, Y., Wu, D. D., Power load forecasting using support vector machine and ant colony optimization. *Expert Syst. Appl.*, 37(3), 2531–2539, 2010.
- [43] Montgomery, K. C., Drake, G. J., Abductive reasoning networks. *Neurocomputing*, 2, 97–104, 1991.
- [44] Liu, H. S., Tarng, Y. S., An abductive network for predicting tool life in drilling. *IEEE Trans. Ind. Appl.*, 35(1), 190–195, 1999.
- [45] Keith, A., Johnson, E., Abductive networks: generalization, pattern recognition, and prediction of chemical behavior. *Can. J. Chem.*, 71, 1993.
- [46] Abdel-Aal, R. E., Short-Term Hourly Load Forecasting Using Abductive Networks. *IEEE Trans. Power Syst.*, 19(1), 164–173, 2004.
- [47] Abdel-Aal, R. E., Modeling and forecasting electric daily peak loads using abductive networks. *Int. J. Electr. Power Energy Syst.*, 28(2), 133–141, 2006.
- [48] Abdel-Aal, R. E., Al-Garni, A. Z., Al-Nassar, Y. N., Modelling and forecasting monthly electric energy consumption in eastern Saudi Arabia using abductive networks. *Energy*, 22(9), 911–921, 1997.
- [49] Ding, Q., Long-term load forecast using decision tree method. *IEEE Power Syst. Conf. Expo.*, 1, 1541–1543, 2006.
- [50] Tso, G. K. F., Yau, K. K. W., Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks. *Energy*, 32(9), 1761–1768, 2007.
- [51] Rao, M. S. S., Soman, S. A., Menezes, B. L., Chawande, P., Dipti, P., Ghanshyam, T., An expert system approach to short-term load forecasting for Reliance Energy Limited, Mumbai. 2006 IEEE Power India Conf., 763–768, 2005.
- [52] Dash, P., Building a Fuzzy Expert System for Electric Load Forecasting Using a Hybrid Neural Network. *Expert Syst. Appl.*, 9(3), 407–421, 1995.

- [53] Castro, F., Castro, R., Luiz, F., Oliveira, C., Francisco, J., Pessanha, M., Long term electricity consumption forecast in Brazil: A fuzzy logic approach. *Socioecon. Plann. Sci.*, 54, 18–27, 2016.
- [54] Kucukali, K., Baris, S., Turkey's short-term gross annual electricity demand forecast by fuzzy logic approach. *Energy Policy*, 38(5), 2438–2445, 2010.
- [55] Hamzacebi C., Es, H. A., Forecasting the annual electricity consumption of Turkey using an optimized grey model. *Energy*, 70, 165–171, 2014.
- [56] El-Fouly, T. H. M., El-Saadany, E. F., Salama, M. M. A., Grey Predictor for Wind Energy Conversion Systems Output Power Prediction. *Power Syst. IEEE Trans.*, 21(3), 1450–1452, 2006.
- [57] Zhao, H., Guo, S., An optimized grey model for annual power load forecasting. *Energy*, 107, 272–286, 2016.
- [58] Miranda L. M., Srinivasan, V., Proença, D., Evolutionary computation in power systems. *Eletr. Power Energy Syst.*, 20(2), 89–98, 1998.
- [59] Eiben, A. E., Schoenauer, M., Evolutionary computing. *Inf. Process. Lett.*, 82, 1–6, 2002.
- [60] Lee, D. G., Lee, B. W., Chang, S. H., Genetic programming model for long-term forecasting of electric power demand. *Electr. Power Syst. Res.*, 40, 17–22, 1997.
- [61] Geem, G. V., Kim, Z. W., Loganathan, J. H., A New Heuristic Optimization Algorithm: Harmony Search. *Simulation*, 76,(2), 60–68, 2001.
- [62] Wang, Z., Li, Ji., Niu, L., Tan, D., An annual load forecasting model based on support vector regression with differential evolution algorithm. *Appl. Energy*, 94, 65–70, 2012.
- [63] Hong, W. C., Electric load forecasting by support vector model. *Appl. Math. Model.*, 33(5), 2444–2454, 2009.
- [64] Liao, G. C., Tsao, T. P., Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting. *IEEE Trans. Evol. Comput.*, 10(3), 330–340, 2006.
- [65] Chen, J. F., Lo, S. K., Do, Q. H., Forecasting monthly electricity demands: An application of neural networks trained by heuristic algorithms. *Information*, 8(1), 2017.
- [66] Hu, Z., Bao, Y., Xiong, T., Electricity load forecasting using support vector regression with memetic algorithms. *The Scientific World Journal*, 2013, <https://doi.org/10.1155/2013/292575>.

- [67] Hu, Z., Bao, Y., Chiong, R., Xiong, T., Mid-term interval load forecasting using multi-output support vector regression with a memetic algorithm for feature selection. *Energy*, 84, 419–431, 2015.
- [68] Hu, Z., Bao, Y., Xiong, T., Comprehensive learning particle swarm optimization based memetic algorithm for model selection in short-term load forecasting using support vector regression. *Appl. Soft Comput. J.* 25,15–25, 2014.
- [69] Hong, W. C., Application of chaotic ant swarm optimization in electric load forecasting. *Energy Policy*, 38(10), 5830–5839, 2010.
- [70] Forouzanfar, M. B., Doustmohammadi, M., Menhaj, A., Hasanzadeh, S., Modeling and estimation of the natural gas consumption for residential and commercial sectors in Iran. *Appl. Energy*, 87(1), 268–274, 2010.
- [71] Ardakani, F. J., Ardehali, M. M., Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types. *Energy*, 65,452–461, 2014.
- [72] AlRashidi, M. R., EL-Naggar, K. M., Long term electric load forecasting based on particle swarm optimization. *Appl. Energy*, 87(1), 320–326, 2010.
- [73] El-naggar, K. M., Al-rumaih, K. A., Electric Load Forecasting Using Genetic Based Algorithm, Optimal Filter Estimator and Least Error Squares Technique: Comparative Study. *Int. J. Energy Power Eng.*, 1(6), 941–945, 2007.
- [74] Yu, S., Zhang, J., Zheng, S., Sun, H., Provincial carbon intensity abatement potential estimation in China: A PSO-GA-optimized multi-factor environmental learning curve method. *Energy Policy*, 77, 46–55, 2015.
- [75] Mondal, S.K., Chatterjee, A., Tudu, B., A Hybrid Particle Swarm Optimization and Artificial Bee Colony Algorithm for Image Contrast Enhancement. *Proc. Int. Conf. Comput. Commun. Syst. Lect. Notes Networks Syst.*, 24, 277–285, 2018.
- [76] May, T. M. K. G., Maier, R. J., Dandy, H. R., Fernando, G. C., Non-linear variable selection for artificial neural networks using partial mutual information. *Environ. Model. Softw.*, 23(10-11), 1312–1326, 2008.
- [77] Tran, B. J. C., Muttill, H. D., Perera, N., Selection of significant input variables for time series forecasting. *Environ. Model. Softw.*, 64, 156–163, 2015.
- [78] Gokhan, A., Modeling of energy consumption based on economic and demographic factors: The case of Turkey with projections. *Renew. Sustain. Energy Rev.*, 35, 382–389, 2014.

- [79] Fan, S., Hyndman, R. J., Short-term load forecasting based on a semi-parametric additive model. *IEEE Trans. Power Syst.*, 27(1), 134–141, 2012.
- [80] Hong, T., Fan, S., Probabilistic electric load forecasting: A tutorial review. *Int. J. Forecast.*, 32(3), 914–938, 2016.
- [81] Hyndman, R. J., Koehler, R. D., Ord, A. B., Snyder, J. K., 2008, *Forecasting with Exponential Smoothing: The State Space Approach*. Springer.
- [82] Jebaraj, S., Iniyar, S., A review of energy models. *Renew. Sustain. Energy Rev.*, 10(4), 281–311, 2006.
- [83] Toksari, D. M., Ant colony optimization approach to estimate energy demand of Turkey. *Energy Policy*, 35(8), 3984–3990, 2007.
- [84] Bilgili, E., Sahin, M., Yasar, B., Simsek, A., Electric energy demands of Turkey in residential and industrial sectors. *Renew. Sustain. Energy Rev.*, 16(1), 404–414, 2012.
- [85] E. Erdogdu, “Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey,” *Energy Policy*, vol. 35, no. 2, pp. 1129–1146, 2007.
- [86] Oğcu, G., Demirel, O. F., Zaim, S., Forecasting Electricity Consumption with Neural Networks and Support Vector Regression. *Procedia - Soc. Behav. Sci.*, 58, 1576–1585, 2012.
- [87] Nazari, H., Kazemi, A., Hashemi, M., Nazari, M., The application of particle swarm optimization algorithm in forecasting energy demand of residential-commercial sector with the use of economic indicators. *Manag. Sci. Lett.*, 4(11), 2415–2422, 2014.
- [88] Taşpinar, N., Çelebi, N., Tutkun, F., Forecasting of daily natural gas consumption on regional basis in Turkey using various computational methods. *Energy Build.*, 56, 23–31, 2013.
- [89] Mabea, G. A., Forecasting Electricity Demand for Kenya using ECM. *Researchjournali Journal of Economics*, 2(1), 1–21, 2014.
- [90] Toksarı, M. D., Estimating the net electricity energy generation and demand using the ant colony optimization approach : Case of Turkey. *Energy Policy*, . 37, 1181–1187, 2010.
- [91] Uzlu, E., Akp, A., Tahsin, H., Nacar, S., Kankal, M., Estimates of hydroelectric generation using neural networks with the arti fi cial bee colony algorithm for Turkey. *Energy*, 69, 638–647, 2014.

- [92] Eberhart, R. C., Shi, Y., Particle swarm optimization: developments, applications and resources. Proc. 2001 Congr. Evol. Comput. (IEEE Cat. No.01TH8546), 1, 81–86, 2001.
- [93] Chen, D. B., Zhao, C. X., Particle swarm optimization with adaptive population size and its application. Appl. Soft Comput. J., 9(1), 39–48, 2009.
- [94] Nickabadi, A., Ebadzadeh, M. M., Safabakhsh, R., A novel particle swarm optimization algorithm with adaptive inertia weight. Appl. Soft Comput. J., 11(4), 3658–3670, 2011.
- [95] Gou, J., Lei, Y. X., Guo, W. P., Wang, C., Cai, Y. Q., Luo, W., A novel improved particle swarm optimization algorithm based on individual difference evolution. Appl. Soft Comput. J., 57, 468–481, 2017.
- [96] Civicioglu, P., Besdok, E., A conceptual comparison of the Cuckoo-search, particle swarm optimization, differential evolution and artificial bee colony algorithms. Artif. Intell. Rev. 39(4), 315–346, 2013
- [97] Karaboga, D., Akay, B., A comparative study of Artificial Bee Colony algorithm. Appl. Math. Comput., 214(1), 108–132, 2009.
- [98] Karaboga, D., Basturk, B., On the performance of artificial bee colony (ABC) algorithm. Appl. Soft Comput., 8, 687–697, 2008.
- [99] Akay, B., Karaboga, D., A modified Artificial Bee Colony algorithm for real-parameter optimization. Inf. Sci., 192, 120–142, 2012.
- [100] Del Valle, R. G., Venayagamoorthy, Y., Mohagheghi, G. K., Hernandez, S., Harley, J. C., Particle swarm optimization: basic concepts, variants and applications in power systems. IEEE Trans. Evol. Comput., 12(2) 171–195, 2008.
- [101] Xu, Y., Fan, P., Yuan, L., Xu, Y., Fan, P., Yuan, L., A Simple and Efficient Artificial Bee Colony Algorithm. Math. Probl. Eng., 2013, 1–9, <https://doi.org/10.1155/2013/526315>.
- [102] Shi, X., Li, Y., Li, H., Guan, R., Wang, L., Liang, Y., An integrated algorithm based on artificial bee colony and particle swarm optimization. 2010 Sixth Int. Conf. Nat. Comput., 2586–2590, 2010.
- [103] Kiran, M. S., Gündüz, M., A recombination-based hybridization of particle swarm optimization and artificial bee colony algorithm for continuous optimization problems. Appl. Soft Comput. J, 13(4), 2188–2203, 2013.
- [104] El-Abd, M., A hybrid ABC-SPSO algorithm for continuous function optimization. IEEE SSCI 2011 - Symp. Ser. Comput. Intell. - SIS 2011 2011 IEEE Symp. Swarm Intell., 96–101, 2011.

- [105] Li, Z., Wang, W., Yan, Y., Li, Z., PS-ABC: A hybrid algorithm based on particle swarm and artificial bee colony for high-dimensional optimization problems. *Expert Syst. Appl.*, 42(22), 8881–8895, 2015.
- [106] Hasan, M. H., Aziz, I. A., Jaafar, J., Rahim, L. A. B., Mabor, J., Manyiel, A., A Comparative Study of Mamdani and Sugeno Fuzzy Models for Quality of Web Services Monitoring. *Int. J. Adv. Comput. Sci. Appl.*, 8(9), 2017.
- [107] Jang, J. R., ANFIS : Adaptive-Ne twork-Based Fuzzy Inference System. *IEEE Trans. Syst. Man. Cybern.*, 23(3), 665–685, 1993.
- [108] Takagi, T., Sugeno, M., Fuzzy Identification of Systems and Its Applications to Modeling and Control. *IEEE Trans. Syst. Man. Cybern.*, 15(1) 116–132, 1985.
- [109] Babuska, R., October, 2001, Fuzzy and Neural Control, DISC Course Lecture Notes, Fuzzy clustering, 55–72.
- [110] Stetco, J., Zeng, A., Keane, X. J., Fuzzy C-means++: Fuzzy C-means with effective seeding initialization. *Expert Syst. Appl.*, 42(21), 7541–7548, 2015.
- [111] Talpur, N., Salleh, M. N. M., Hussain, K., An investigation of membership functions on performance of ANFIS for solving classification problems. *IOP Conf. Ser. Mater. Sci. Eng.*, 226(1), 2017.
- [112] Pousinho, H. M. I., Mendes, V. M. F., Catalão, J. P. S., A hybrid PSO – ANFIS approach for short-term wind power prediction in Portugal. *Energy Convers. Manag.*, 52(1), 397–402, 2011.
- [113] Azadeh, A., Saberi, M., Gitiforouz, A., Saberi, Z., A hybrid simulation-adaptive network based fuzzy inference system for improvement of electricity consumption estimation,” *Expert Syst. Appl.*, 36(8), 11108–11117, 2009.
- [114] Mamlook, R., Badran, O., Abdulhadi, E., A fuzzy inference model for short-term load forecasting. *Energy Policy*, 37, 1239–1248, 2009.
- [115] Abraham, A., Nath, B., A neuro-fuzzy approach for modelling electricity demand in Victoria. *Appl. Soft Comput. J.*, 1, 127–138, 2001.
- [116] Ucenic, C., George, A., A Neuro-fuzzy Approach to Forecast the Electricity Demand. *Proceedings of the 2006 IASME/WSEAS International Conference on Energy & Environmental Systems*, 2006, 299–304.
- [117] Zahedi, G., Azizi, S., Bahadori, A., Elkamel, A., Wan, S. R., Electricity demand estimation using an adaptive neuro-fuzzy network : A case study from the Ontario province-Canada. *Energy*, 49, 323–328, 2013.

- [118] Mordjaoui, B., Boudjema M., Forecasting and Modelling Electricity Demand Using Anfis Predictor. *J. Math. Stat.*, 7(4), 275–281, 2011.
- [119] Saravanan, S., Kannan, S., Thangaraj, C., Prediction of India's Electricity Consumption using ANFIS. *ICTACT J. Soft Comput.*, 5(3), 985–990, 2015.
- [120] Çevik, H., Çunkaş, H., Short-term load forecasting using fuzzy logic and ANFIS. *Neural Comput Appl.*, 26, 1355–1367, 2015.
- [121] Ying, M., Pan, L., Using adaptive network based fuzzy inference system to forecast regional electricity loads. *Energy Convers. Manag.*, 49, 205–211, 2008.
- [122] Haydari, M., Kavehnia, Z., Askari, F., Ganbariyan, M., Time-Series Load Modelling and Load Forecasting Using Neuro-Fuzzy Techniques. 2007 9th International Conference on Electrical Power Quality and Utilization, 2007.
- [123] Mollaiy-Berneti, S., Optimal design of adaptive neuro-fuzzy inference system using genetic algorithm for electricity demand forecasting in Iranian industry. *Soft Comput.*, 20(12), 4897–4906, 2016.
- [124] Kazemi, S. M. R., Seied Hoseini, M. M., Abbasian-Naghneh, S., Rahmati, S. H. A., An evolutionary-based adaptive neuro-fuzzy inference system for intelligent short-term load forecasting. *Int. Trans. Oper. Res.*, 21(2), 311–326, 2014.
- [125] Pereira, C. M., De Almeida, N. N., Velloso, M. L. F., Fuzzy modeling to forecast an electric load time series. *Procedia Comput. Sci.*, 55, 395–404, 2015.
- [126] Sarduy, J. R. G., Di Santo, K. G., Saidel, M. A., Linear and non-linear methods for prediction of peak load at University of São Paulo. *Meas. J. Int. Meas. Confed.*, 78, 187–201, 2016.
- [127] Al-Ghandoor, M., Samhour, A., Electricity Consumption in the Industrial Sector of Jordan : Application of Multivariate Linear Regression and Adaptive Neuro-Fuzzy Techniques. *Jordan J. Mech. Ind. Eng.*, 3(1) 69–76, 2009.
- [128] Jozi, A., Pinto, T., Praca, I., Silva, F., Teixeira, B., Vale, Z., Energy consumption forecasting based on Hybrid Neural Fuzzy Inference System. 2016 IEEE Symposium Series on Computational Intelligence (SSCI), 1–5.
- [129] Rini, D. P., Shamsuddin, S. M., Yuhaniz, S. S., Particle swarm optimization for ANFIS interpretability and accuracy. *Soft Comput.*, 20(1), 251–262, 2016.
- [130] Sarkheyli, S., Zain, A., Sharif, A. M., Robust optimization of ANFIS based on a new modified GA. *Neurocomputing*, 166, 357–366, 2015.

- [131] Jiang, W. H., Kwong, H. M., Ip, C. K., Modeling customer satisfaction for new product development using a PSO-based ANFIS approach. *Appl. Soft Comput. J.*, 12(2), 726–734, 2012.
- [132] Shihabudheen, K. V., Pillai, G. N., Recent advances in neuro-fuzzy system: A survey. *Knowledge-Based Syst.*, 152, 136–162, 2018.
- [133] Lin, W., Sun, X., Palade, J., Fang, V., Wu, W., Xu, X., Training ANFIS Parameters with a Quantum-behaved Particle Swarm Optimization Algorithm. *Advances in Swarm Intelligence. ICSI 2012. Lecture Notes in Computer Science*, 148–155. 2012
- [134] Yang, L., Chen, Y., Wang, Y., Li, Y., Li, C., Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting. *Appl. Soft Comput. J.*, 49, 663–675, 2016.
- [135] Kasule, A., Ayan, K., Forecasting Uganda's Net Electricity Consumption Using a Hybrid PSO-ABC Algorithm, *Arab. J. Sci. Eng.*, (2018), <https://doi.org/10.1007/s13369-018-3383-z>.

ÖZGEÇMİŞ

Abdal Kasule, 09.10.1978'de Uganda'da doğdu. İlk, orta ve lise eğitimini Uganda'da tamamladı. 1997 yılında başladığı Makerere Üniversitesi Matematik Bölümü'nü 2000 yılında bitirdi. 2001 yılında Bweyogerere lisesi'nde Matematik eğitim görevlisi olarak çalışmaya başladı. 2003 yılında başladığı Makerere Üniversitesi Bilgisayar Bilimleri Bölümü'nde yüksek lisans eğitimine 2006 bitirdi. 2007 yılında Uganda İslam Üniversitesi Bilgisayar ve Bilişim Teknoloji Bölümü'nde eğitim görevlisi olarak çalışmaya başladı. Halen Uganda İslam Üniversitesi Bilişim ve İletişim Bölümü'nde bilgisayar ağları yönetimi görevlisi olarak görev yapmaktadır. 2013 yılında Sakarya Üniversitesi'nde TÖMER Türk dili eğitimi aldı. 2014 yılında doktora eğitimine Sakarya Üniversitesi Bilgisayar ve Bilişim Mühendisliği Bölümü'nde başladı.