



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

**Yeni Bir Metot Olan Geri Beslemeli
Lineer Regresyon İle Akıllı Şebekeye
Bağlı Meskenlerde Kısa Dönem Yük
Tahmini**

HAZRET TEKİN

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

**EKİM-2019
BATMAN
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Hazret Tekin tarafından hazırlanan “Yeni Bir Metot Olan Geri Beslemeli Lineer Regresyon İle Akıllı Şebekeye Bağlı Meskenlerde Kısa Dönem Yük Tahmini” adlı tez çalışması 18/10/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Necmettin Sezgin

Danışman

Doç. Dr. Ömer Faruk Ertuğrul

Üye

Dr. Öğr. Üyesi Yılmaz Kaya

İmza



Yukarıdaki sonucu onaylarım.


Prof. Dr. Sahnaz TIGREK
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

HAZRET TEKİN

Tarih: 18/10/2019

ÖZET

YÜKSEK LİSANS TEZİ

Yeni Bir Metot Olan Geri Beslemeli Lineer Regresyon İle Akıllı Şebekeye Bağlı Meskenlerde Kısa Dönem Yük Tahmini

Hazret Tekin

Batman Üniversitesi Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ömer Faruk Ertuğrul

2019, 53 Sayfa

Jüri

Prof. Dr. Necmettin Sezgin
Doç. Dr. Ömer Faruk Ertuğrul
Dr. Öğr. Üyesi Yılmaz Kaya

Bir ilin ya da bölgenin şebekeden çektiği elektrik enerjisini kısa veya uzun dönemli tahmin etmek klasik elektrik iletim ve dağıtım şebekesinin yönetimi açısından oldukça önemlidir. Günümüzde ise akıllı şebekeler kapsamında artık her bir meskenin kendi özelinde şebekeden çektiği yük miktarı önem kazanmıştır. Akıllı şebekeden elektrik çeken meskenler aynı zamanda güneş enerjisi gibi alternatif enerji kaynakları ile elektrik üretebilmektedir. Bu durum göz önüne alınarak böyle bir meskenin şebekeden çektiği elektrik yükünün tahmini bu çalışmada klasik yöntemlerden lineer regresyon ve yapay sinir ağları ile test edilmiş ancak istenen oranda başarı elde edilememiştir. Bu sebeple güneş enerjisi ile elektrik üretebilen bir meskenin şebekeden çektiği elektrik miktarını tahmin etmek için yeni bir metoda gereksinim duyulmuştur. Bu sebeple bu çalışmada birçok regresyon probleminde başarılı sonuçlar üreten lineer regresyon yöntemi geliştirilerek, dinamik sistemleri modelleyebilmesi ve herhangi bir zamana ait şebekeden çekilen elektrik miktarını tahminde tahmin başarısını arttıran ve geçmiş verileri de dikkate alan geri beslemeli lineer regresyon olarak isimlendirilen yeni bir yöntem önerildi. Önerilen yaklaşımı test etmek için, Smart Project kapsamında U Toplu İz Havuzunda paylaşılan Sundance veri seti kullanılmıştır. Önerilen yöntemin başarısını doğrulamak için her bir veri setine lineer regresyon ve aşırı öğrenme metotları uygulanmıştır. 59 farklı mesken için elde edilen sonuçlara bakıldığında, geri beslemeli lineer regresyon ile elde edilen kök ortalama kare hata (RMSE) değerlerinin lineer regresyon ve aşırı öğrenme yöntemine kıyasla daha düşük olduğu yani daha başarılı tahmin sonuçları verdiği saptanmıştır. Bu başarının nedeni zaman sıralı veri setlerinde ve sinyallerde geri beslemeli yöntemlerin dinamik modelleme kabiliyetleri sayesinde sistemi daha başarılı bir şekilde modelleyebilmeleridir.

Anahtar Kelimeler: Akıllı şebekeler, aşırı öğrenme makineleri, geri beslemeli lineer regresyon, lineer regresyon, zaman sıralı veri seti.

ABSTRACT

MS THESIS

Forecasting Short-Term Grid Electricity Load In Homes That Were Connected To The Smart Grid By A Novel Method: Recurrent Linear Regression

HAZRET TEKİN

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL-ELECTRONICS ENGINEERING**

Advisor: Assoc. Prof.Dr. Ömer Faruk Ertuğrul

2019, 53 Pages

Jury

**Prof.Dr. Necmettin Sezgin
Assoc. Prof.Dr. Ömer Faruk Ertuğrul
Asst. Prof. Yılmaz Kaya**

The short and long-term forecasting of grid electrical energy of a province or region is important for the management of the conventional electricity transmission and distribution network. Nowadays, the amount of electrical energy that each residential building has taken from the grid has gained importance within the scope of smart grids. Residential buildings that take electricity from the smart grid can generate electricity with alternative energy sources such as solar energy. Considering this situation, it has been tested in this project with linear regression and artificial neural networks, which are the classical methods for estimating the electrical energy of such a residential building, but, the desired success rate was not achieved. For this reason, a new method is needed to estimate the amount of electricity of a residential building that can generate electricity with solar energy. For this reason, in this study, linear regression method, which produces successful results in many regression problems, has been developed and proposed a new method called recurrent linear regression which is able to model dynamic systems and increase the estimation success in estimating the amount of electricity drawn from the grid at any time and taking historical data into consideration. In order to test and validate the proposed approach, the Sundance dataset, which is shared in the U Mass Trace Repository according to Smart Project was used. To confirm the success of the proposed method, the linear regression and extreme learning machines methods were used for each different data set. Obtained results, which were taken from 59 different residential buildings, showed that lower root mean square error (RMSE) values were achieved by recurrent regression compared to linear regression and extreme learning method. The reason for this success is the ability to model the system more successfully thanks to the dynamic modeling capabilities of recurrent methods in time-sequential data sets and signals.

Keywords: smart grids, Extreme learning machines, linear regression, recurrent linear regression, time series dataset.

ÖNSÖZ

Öncelikle tez çalışmam ve tüm eğitim hayatım boyunca beni destekleyerek bu aşamaya gelmemi sağlayan anneme, babama ve kardeşlerime teşekkürü borç bilirim. Seminer çalışmam süresince, yoğun programı içinde benim için vakit ayırıp çalışmalarımı ilgilenen, yol gösteren danışman hocam Doç. Dr. Ömer Faruk Ertuğrul'a teşekkürlerimi sunarım.

HAZRET TEKİN

BATMAN-2019



İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
2.1. Literatürde Yapılan Kısa Dönem Yük Tahmin Çalışmaları	4
3. AKILLI ŞEBEKELER	8
3.1. Akıllı Sayaçlar	10
4. YÜK TAHMİNİ	12
4.1. Yük Tahmin Uygulamalarının Zamansal Olarak Sınıflandırılması.....	12
4.1.1. Uzun dönem yük tahmini.....	12
4.1.2. Orta dönem yük tahmini	12
4.1.3. Kısa dönem yük tahmini	13
4.2. Yük Tahminini Etkileyen Faktörler	13
4.2.1. Ekonomik ve demografik faktörler.....	13
4.2.2. Meteorolojik faktörler	13
4.2.3. Zaman faktörü.....	14
4.2.4. Diğer faktörler.....	14
5. MATERYAL	15
6. METOT	19
6.1. Metodolojide Genel Yaklaşım	19
6.2. Uygulamada Kullanılan Tahmin Metotları	21
6.2.1. Lineer regresyon	21
6.2.2. Geri beslemeli lineer regresyon	24
6.2.3. Aşırı öğrenme makinaları	26
6.3. Uygulamada Değerlendirme ve Performans Kriterleri	27
7. ARAŞTIRMA BULGULARI	28

8. TARTIŞMA ve SONUÇ	35
KAYNAKLAR	38
ÖZGEÇMİŞ	41



SİMGELER VE KISALTMALAR

Simgeler

- y : Regresyon analizinde bağımlı değişken (çıkış değeri)
- β_0 : Regresyon katsayısı
- β_1 : Basit regresyon giriş parametresinin katsayısı
- x : Basit regresyon giriş değişkeni (bağımsız değişken)
- ε : Regresyon hata parametresi
- β_t : Çoklu regresyon analizinde giriş değişkenlerinin regresyon katsayıları
- x_t : Çoklu regresyon analizinde giriş değişkenleri (bağımsız değişkenler)
- β_i : Geri beslemeli lineer regresyon analizinde giriş değişkenlerinin regresyon katsayıları
- β_{j+m} : Geri beslemeli lineer regresyon analizinde geri besleme elemanlarının geri besleme regresyon katsayıları
- x_i : Geri beslemeli lineer regresyon analizinde giriş değişkenleri (bağımsız değişkenler)
- k : Geri beslemeli lineer regresyonda anlık zaman ifadesi
- d : Geri beslemeli lineer regresyonda çıkıştan alınan geri besleme çıkış sayısı
- w_{ij} : İleri beslemeli YSA modelinde girdi ağırlığı
- b_j : İleri beslemeli YSA modelinde eşik değeri terimi
- x_i : İleri beslemeli YSA modelindeki giriş vektörü
- Y : İleri beslemeli YSA modelindeki çıkış vektörü
- β_j : İleri beslemeli YSA modelindeki çıktı ağırlığı
- $g()$: İleri beslemeli YSA modelindeki aktivasyon fonksiyonu

Kısaltmalar

BT	:	Bilgi Teknolojileri
DD	:	Dalgacık Dönüşümü
DRNN	:	Derin Yinelemeli Sinir Ağları (Deep Recurrent Neural Network)
EKK	:	En Küçük Kareler Metodu
ELM	:	Aşırı Öğrenme Makinaları (Extreme Learning Machines)
GBLR	:	Geri Beslemeli Lineer Regresyon
GKA	:	Görgül Kip Ayrışımı
GPR	:	Gauss Proses Regresyonu (Gaussian Process Regression)
GRNN	:	Genelleştirilmiş Regresyon Sinir Ağları (Generalized Regression Neural Network)
KNNR	:	k-En Yakın Komşu Regresyonu (k Nearest Neighborhood Regression)
KSR	:	k-Düz Regresyonu(k-Smooth Regression)
LR	:	Lineer Regresyon
LSTM	:	Uzun Kısa Vadeli Bellek (Long-Short Term Memory)
NARX	:	Lineer Olmayan Otoregresif Sinir Ağları (Nonlinear Autoregressive Neural Network)
RELM	:	Geri Beslemeli Aşırı Öğrenme Makinaları (Recurrent Extreme Learning Machines)
GBLR	:	Geri Beslemeli Lineer Regresyon
RMSE	:	Kök Ortalama Kare Hata (Root Mean Square Error)
RNN	:	Yinelemeli Sinir Ağları (Recurrent Neural Network)
RTFSA	:	Radyal Tabanlı Fonksiyon Sinir Ağları
SARIMA	:	Mevsimsel Otoregresif Hareketli Ortalamalar (Seasonal Autoregressive Integrated Moving Average)
SHLRNN	:	Tek Katmanlı Jordan Yinelemeli Sinir Ağı (Single Hidden Layer Jordan Recurrent Neural Network)
SVM	:	Destek Vektör Makinaları (Support Vector Machines)
SVR	:	Destek Vektör Regresyonu (Support Vector Regression)
YSA	:	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 3.1. Akıllı şebeke yapısı	9
Şekil 3.2. Akıllı sayaçlar	10
Şekil 5.1. Şebekeden çekilen elektrik yükünün zamana göre değişim grafiği	18
Şekil 6.1. Uygulama metodolojisinin işlem akış diyagramı	20
Şekil 6.2. Elman ve Jordan ağ modelleri	25
Şekil 6.3. İleri beslemeli tek gizli katmanlı YSA	26
Şekil 7.1. 1135 numaralı mesken için ELM parametrelerine göre	29
Şekil 7.2. 1135 numaralı mesken için GBLR metodunda geri besleme eleman sayısına göre ortalama RMSE değişimleri	29
Şekil 7.3. 2714 numaralı mesken için ELM parametrelerine göre RMSE değişimleri ..	30
Şekil 7.4. 2714 numaralı mesken için GBLR metodunda geri besleme eleman sayısına göre ortalama RMSE değişimleri	30
Şekil 7.5. 3065 numaralı mesken için ELM parametrelerine göre RMSE değişimleri ..	31
Şekil 7.6. 3065 numaralı mesken için GBLR metodunda geri besleme eleman sayısına göre ortalama RMSE değişimleri	31
Şekil 7.7. 1135 numaralı meskene ait bir günlük şebeke yük tahmini eğrileri.....	32
Şekil 7.8. 2714 numaralı meskene ait bir günlük şebeke yük tahmini eğrileri.....	32
Şekil 7.9. 3065 numaralı meskene ait bir günlük şebeke yük tahmini eğrileri.....	32

ÇİZELGELER DİZİNİ

Çizelge 2.1. Literatürde yapılan elektrik yük tahmin çalışmaları.....	7
Çizelge 5.1. 1135 numaralı meskenin 1 günlük veri seti.....	16
Çizelge 5.2. 3065 numaralı meskenin 1 günlük veri seti.....	16
Çizelge 7.1. Her bir meskenin uygulanan tahmin modellerine göre RMSE değerleri ...	34
Çizelge 7.2. Uygulamada kullanılan metotların tüm veri setlerini kapsayan ortalama RMSE değerleri	34



1. GİRİŞ

Enerji ihtiyacı ve enerjinin temini konusu insanlık tarihi boyunca toplumların üzerine uğraş verdiği birincil sorunlardan biri olagelmıştır. Geçmişten günümüze, değişen yaşam koşullarına bağlı olarak toplumların enerjiye ve enerjinin farklı türlerine olan bağımlılığı da artan bir eğilim göstermiştir. Özellikle birinci Sanayi Devrimi ile ortaya çıkan ve dünya çapında iktisadi, sosyal ve siyasi etkileri de olan buhar gücü ile çalışan makineler ve araçların hayatımıza girişi ile enerjiye ve bunu sağlayan ham maddelere de bağımlılık oldukça artmıştır (Alçin, 2016).

İlk sanayi devriminin ardından gerçekleşen ikinci sanayi devrimi ile elektrik gücü temelli sanayileşme düzenine geçilmiştir (Alçin, 2016). Üçüncü sanayi devrimi ile başlayan dijital devrim, elektronik alanındaki gelişmeler ve BT (Bilgi Teknolojileri)'nin hayatımıza girmesiyle üretim daha da otomatikleştirilmiş ve sonuç olarak elektrik enerjisine olan ihtiyaç ve bağımlılık artmıştır (Alçin, 2016). Elektrik enerjisine olan bağımlılık ve ihtiyacın artmasına bağlı olarak elektrik enerjisinin üretilip temininin sağlanması için çeşitli kaynakların kullanılmasına başlanmıştır. Bunlardan biri olan fosil kaynaklar, hidrokarbon ve yüksek oranlarda karbon içeren kömür, petrol ve doğal gaz gibi kaynaklardan oluşurken; güneş, rüzgâr, hidroelektrik, jeotermal gibi kaynaklar ise yenilenebilir enerji kaynakları olarak sınıflandırılmaktadır (Şeker, 2016). Yenilenebilir enerji kaynakları, rezerv sınırı olan ve çevreye olan olumsuz etkilerinden dolayı fosil kaynaklara alternatif olmak üzere kullanılmaktadır. Özellikle ülkemiz gibi petrol ve doğal gaz rezerv durumu sınırlı olan ve sonuç olarak enerjide dışa bağımlı olan ülkeler açısından değerlendirildiğinde yenilenebilir enerjiden maksimum seviyede faydalanma elzemdir.

Elektrik enerjisinin üretimi kadar üretilen enerjinin tüketicilere arzı ve bunun işlem akışı bir o kadar önemlidir. Elektrik enerjisinin iletim ve dağıtım sistemleri ile tüketicilere ulaştırılmasında çevre güvenliğinin sağlanarak sürekli, güvenilir, kaliteli ve düşük maliyetle enerji talebinin karşılanması temel amaçtır (Akman, 2018). Bu verimli ve istenen akışın sağlanması için gerek iletim aşamasına yön veren kamu kuruluşları gerekse dağıtım aşamasını yöneten dağıtım şirketleri bir dizi plan ve program dahilinde bu süreçleri yönetmektedir. Özellikle dağıtım şirketleri günlük, haftalık, aylık ve yıllık periyotlarda şebekeden talep edilecek enerji miktarlarını önceden tespit eden çeşitli tahmin simülasyonları sayesinde yapacakları plan ve iş akışını belirlemektedir (Akçin ve ark., 2013). Bu sayede gerekli altyapı hizmetlerini vermekte ve enerjinin kesintisiz, kaliteli ve minimum maliyetle arzını sağlamaktadırlar.

Gerçekleştirilecek şebeke yükü tahmin çalışmalarının doğruluk derecesi, yapılacak olan planlamaları doğrudan etkileyebilmektedir. Gerçek değerlerden daha az miktarda enerji talebi tahmini yapıldığında planlanandan daha fazla talep durumu oluşacağından dağıtım şirketleri yük dengesini sağlamak adına elektrik kesintileri yapmak zorunda kalacaktır (Es, 2013). Bu durum özellikle sanayi kuruluşları açısından telafisi zor maliyet ve üretim kayıplarına sebep olacaktır. Eğer gerçek talep değerlerinden daha fazla enerji talep tahmini yapılırsa bu durum gereksiz altyapı çalışmalarının yapılmasına ve israfa sebep olacaktır (Es, 2013). Bu durum özellikle dağıtım şirketlerini olumsuz etkileyecektir. Bu yüzden yük tahmini çalışmalarında uygulamada gerçeğe yakın sonuçlara ulaşabilmek için eldeki verilerin analizi ve bu verileri işlemek üzere uygulanacak tahmin algoritmasının seçimi büyük önem arz etmektedir (Çevik, 2013).

Literatürde şebekeden çekilen yük miktarını tahmin için lineer regresyon (LR), yapay sinir ağları (YSA), destek vektör makineleri (SVM) de dâhil birçok makine öğrenmesi metodunun kullanılması önerilmektedir (Gajowniczek, 2017). Bu çalışmalarda veri setlerinde genellikle sıcaklık, nem gibi fiziksel parametreler ve belli periyotlar dahilinde kaydedilmiş elektrik enerjisi tüketim verileri bulunmaktadır (Esener ve ark., 2012). Uygulamalarda sıcaklık, nem gibi parametreler giriş değişkeni alınarak bu girişlere göre çıkış parametresi olarak seçilen elektrik enerjisi tüketim miktarı tahmin edilmeye çalışılmaktadır (Esener ve ark., 2012).

Bu çalışmamızda ise literatürdeki çalışmalardan farklı olarak akıllı şebeke mimarisine bağlı, güneş paneli ile kendi enerjisini üreten meskenlerden akıllı sayaçlar üzerinden alınan elektriksel tüketim verileri ve güneş paneli üretim verileri kullanılarak meskenler için bir günlük periyodu kapsayan kısa dönem yük tahmini çalışması yapılmıştır. Akıllı şebekeye bağlı dağıtım sistemlerinin klasik yapıdaki şebeke yapısına göre farklı özellikleri mevcuttur. Bu özelliklerden en önemlisi kendi enerjisini üreten tüketici profili nedeniyle şebeke üzerinden çift yönlü enerji akışı durumunun gözlemlenmesidir (Zehir ve Bağrıyanık, 2013). Bu durum bu şebeke yapısına bağlı meskenler için yapılacak yük tahmini çalışmalarını da etkilemektedir. Çünkü çift yönlü enerji akışının olması şebeke yük karakteristiğini daha kompleks bir hale dönüştürmektedir. Diğer bir deyişle sistem dinamikliği artmaktadır (Bollen ve ark., 2016).

Çalışmada tahmin metodu olarak basit bir yapısı bulunan ve birçok çalışmada başarılı sonuçlar veren, ancak metodolojik yapısı itibariyle verileri ileri doğru işleyen lineer regresyonun (LR'nin) geri beslemeli olarak geliştirilmesi durumunda zaman sıralı

verilerde daha başarılı sonuçlar vereceđi öngörölmüştür. Bu mantıktan yola çıkarak, bu çalışmamızda literatürdeki mevcut çalışmalardan farklı olarak yeni bir regresyon modeli olarak tasarlanan geri beslemeli lineer regresyon (GBLR) önerilmiştir. Önerilen GBLR metodunun başarısının doğrulanması amacıyla her bir veri seti LR ve aşırı öğrenme makinaları (ELM) ile de test edilmiştir. Çalışmada elde edilen sonuçlara bakıldığında GBLR metodunun daha düşük hata oranları ile gerçek değerlere en yakın sonuçlara ulaşabildiđi görölmüştür.



2. KAYNAK ARAŞTIRMASI

Literatürde kısa dönem yük tahmini çalışmaları incelendiğinde genellikle analitik yöntemler, yapay zeka yöntemleri ve bu iki tür yöntemin birlikte kullanıldığı hibrit yöntemler olmak üzere 3 tür yöntemin kullanıldığı görülmektedir (Esener ve ark., 2012). Analitik yöntemlere benzer gün yöntemi, lineer regresyon (LR), en küçük kareler yöntemi, ARIMA VE SARIMA modelleme yöntemleri örnek olarak verilebilir (Esener, 2012). Yapay zeka yöntemleri ise yapay sinir ağları (YSA) ve yapay sinir ağlarının farklı yapıdaki türevleri(ileri beslemeli YSA, geri beslemeli YSA, derin öğrenme, yinelemeli YSA, aşırı öğrenme makinaları (ELM) ve destek vektör makinelerini (SVM) kapsamaktadır (Dong ve ark., 2016). Hibrit yöntemler ise analitik yöntemler ile yapay zeka yöntemlerinin birlikte kullanılarak uygulamada her iki yöntemin avantajlarının kombine edildiği yöntemlerdir.

2.1. Literatürde Yapılan Kısa Dönem Yük Tahmin Çalışmaları

Haida ve ark. (1994) yaptıkları çalışmada, regresyon tabanlı yük tahmini yapmışlardır. Bağıl nem, son iki günün ortalama sıcaklığı ve yük tahmini yapılacak günün maksimum sıcaklığı giriş parametreleri olarak tanımlanmıştır. Mevsimsel şartlardan dolayı yük karakteri dinamikleşen ilkbahar ve sonbahar aylarındaki veriler için bir doğrusallaştırma tekniği uygulamışlardır. Yöntem Tokyo elektrik şebekesinde denenmiştir.

Amjady'nin (2001) çalışmasında, yük kontrolünü yöneten uzman operatörün, deneyimleri ile yönetebileceği yeni bir ARIMA yapısı kullanılarak, kısa dönem yük tahminine farklı bir yaklaşım ile sonuç aranmıştır. Yöntem İran şebekesi verileri ile test edilmiştir ve beklenen gerçek değerlere yakın sonuçlar alınmıştır.

Balcı ve ark. (2012) Türkiye'nin 2003-2010 yılları arasındaki saatlik enerji tüketim verilerini kullanarak 2004-2010 yılları arasındaki günlük yük tahminini LR ile belirlemişlerdir.

Jain ve Satish, (2008) yaptıkları çalışmada destek vektör makineleri (SVM) metodu ile 24 saatlik kısa dönem yük tahmini çalışması yapmışlardır. Serbest değişken(giriş parametresi) olarak sıcaklık verisi ve gün tipi verisi kullanılmıştır. 24 saatlik yük tahmini yanı sıra gün içindeki puant yükün (tepe yük) tahmini de gerçekleştirilmiştir.

Azadeh ve ark. (2009) yaptıkları çalışmada giriş parametreleri (bağımsız değişkenler) olarak gün tipi, tahmin öncesi günün yük verisi, maksimum-minimum ortalama sıcaklık verileri kullanılarak İran geneli 2003-2005 yılları için yük tahmin uygulaması yapılmıştır. Metot olarak YSA kullanılmıştır. Mevsimsel farklılıkların etkisinden dolayı her mevsim için farklı yapıda sinir ağları kullanılmıştır. Bu sayede her mevsimin kendi özel şartlarında tahmin sonuçları elde edilmiştir.

Esener ve ark. (2012) Türkiye geneli için 24 saatlik yük tahminini bağımsız değişken olmaksızın sadece saatlik elektrik yük verilerini kullanarak yapay sinir ağı (YSA), dalgacık dönüşümü (DD), radyal tabanlı sinir ağları (RTFSA) ve görgül kip ayrışımı (GKA) yöntemlerini kullanarak başarılı sonuçlar elde etmişlerdir. Uygulamada YSA, dalgacık dönüşümü (DD) ve YSA hibrit yapısı, dalgacık dönüşümü (DD) ve Radyal Tabanlı Fonksiyon Sinir Ağları (RTFSA) hibrit yapısı ve görgül kip ayrışımı (GKA) ve RTFSA hibrit yapıları oluşturulmuştur. Sonuçlar incelendiğinde DD ve GKA yapılarının YSA ve RTFSA metotlarına eklenmelerinin YSA ve RTFSA yapılarının yük tahmin uygulamasında daha doğruya yakın tahmin sonuçları verdiğini göstermiştir.

Hocaoğlu ve ark. (2015) yaptıkları çalışmada Denizli ilinin Güney ilçesi için YSA, YSA ve lineer regresyon hibrit yapısını kullanarak kısa dönem yük tahmin çalışması yapmışlardır. Sonuçlar incelendiğinde YSA ile hata oranı %6,67 iken YSA ve regresyon hibrit modelinde hata oranı %5,2 değerine düştüğü gözlemlenmiştir.

Ceylan ve Demirören (2006) yaptıkları çalışmada benzer gün yaklaşımı ile YSA metotlarını melezleyerek İç Anadolu Bölgesi için kısa dönem yük tahmini çalışması yapmışlardır. Serbest değişkenler (giriş parametreleri) olarak bölgeye ait 2002 ve 2003 yılları yük verileri ve meteorolojik veriler kullanılmıştır. Sonuçlar incelendiğinde YSA ve benzer gün yaklaşımı hibrit modelinin YSA metodundan daha düşük hata oranları verdiği gözlemlenmiştir.

Guan ve ark. (2013) sadece zamansal verileri giriş parametresi olarak kullanarak şebeke yükünü hibrit yapıdaki dalgacık dönüşümlü yapay sinir ağı ile tahmin etmeye çalışmışlardır.

Literatürde son dönem çalışmalar incelendiğinde derin öğrenme kavramı bağlamında yinelemeli YSA ve geri beslemeli YSA gibi yeni yaklaşımların kullanımının yaygınlaşmaya başladığı görülmüştür.

Kong ve ark. (2017) Avustralya'da akıllı şebekeye bağlı 10000 farklı meskenin akıllı sayaç verilerini kullanarak her bir mesken için kısa dönem yük tahmin çalışması yapmışlardır. Derin öğrenme modellerinden biri olan uzun kısa vadeli bellek (LSTM)

algoritmasını yinelemeli YSA'ya (RNN) uygulamışlardır. Çıkan sonuçları ELM, k en yakın komşuluk ve geriye yayılım algoritması modelleri ile karşılaştırıp, test ederek LSTM RNN modelinin daha iyi performans gösterdiğini ispatlamışlardır.

Zheng ve ark. (2017) akıllı şebekeye bağlı bir bölgeden alınan akıllı sayaç verilerine uzun kısa vadeli bellek (LSTM) RNN metodunu kullanmış ve elde edilen sonuçları SARIMA (Seasonal Autoregressive Integrated Moving Average), NARX (Nonlinear Autoregressive Neural Network), SVR (Support Vector Regression) metodları ile karşılaştırarak LSTM öğrenme modelinin diğerlerinden daha iyi tahmin sonuçları elde ettiğini saptamışlardır.

Bir diğer çalışmada, Rahman ve ark. (2018) ABD'nin Texas ve Austin eyaletlerinde bulunan ticari mesken ve standart mesken abonelerin elektrik yükünü yinelemeli derin yapay sinir ağı modeli (DRNN) ile ileri beslemeli YSA'dan daha başarılı bir şekilde tahmin etmiştir.

Ertuğrul (2016) çalışmasında aşırı öğrenme makineleri (ELM) metodunun yüksek genelleme yeteneği ve hızlı öğrenme gibi avantajlarını tek katmanlı Jordan yinelemeli yapay sinir ağının (SHLRNN) eğitiminde kullanarak R-ELM denilen geri beslemeli yeni bir öğrenme algoritması tasarlamıştır. 2011-2014 yıllarına ait Portekiz'de 10 adet trafo merkezinin yük verileri kullanılmıştır. R-ELM metodu, RNN (Recurrent Neural Network), LR (Linear Regression), KSR (k-Smooth Regression), KNNR (k Nearest Neighborhood Regression), GPR (Gaussian Process Regression), GRNN (Generalized Regression Neural Network) metotlarıyla karşılaştırılmış ve RELM metodunun daha iyi tahmin sonuçları verdiği saptanmıştır. Aşağıda çizelge 2.1'de literatürde yapılan kısa dönem elektrik yük tahmin çalışmaları liste halinde verilmiştir.

Çizelge 2.1. Literatürde yapılan elektrik yük tahmin çalışmaları

Yazar	Tahmin Bölgesi	Tarih	Veri Tipi	Kullanılan Yöntemler
Haida ve arkadaşları	Japonya-Tokyo	1994	Bağıl nem, Ortalama sıcaklık, Maksimum sıcaklık, Geçmiş yük verileri	LR
N. Amjady	İran	2001	Geçmiş yük verileri	ARIMA
Ceylan ve arkadaşları	Türkiye-İç Anadolu Bölgesi	2006	Geçmiş yük verileri, Meteorolojik veriler	Hibrit SA+Benzer gün yaklaşımı
Jain ve Satish		2008	Sıcaklık verisi, Gün tipi	Destek Vektör Makineleri (SVM)
Azadeh ve arkadaşları	İran	2009	Gün tipi, Geçmiş yük verileri, Sıcaklık verileri	YSA
Balcı ve arkadaşları	Türkiye geneli	2012	Geçmiş yük verileri	LR
Esener ve arkadaşları	Türkiye geneli	2012	Geçmiş yük verileri	YSA, YSA+DD hibrit yapısı, RTFSA+DD hibrit yapısı, GKA+RTFSA hibrit yapısı
Guan ve arkadaşları		2013	Geçmiş yük verileri, Zamansal veriler(gün, hafta, ay, yıl)	YSA+DD hibrit yapısı
Hocaoğlu ve arkadaşları	Denizli-Güney ilçesi	2015	Geçmiş yük verileri, Zamansal veriler	YSA, YSA+LR hibrit yapısı
Ö.F Ertuğrul	Portekiz'de bir bölge	2016	Geçmiş yük verileri, Zamansal veriler	R-ELM, LR, KSR, KNNR, GPR
Kong vd.	Avustralya'da bir bölge	2017	Akıllı sayaç yük verileri, Zamansal veriler	LSTM+RNN, ELM, KNN, BPNN
Zheng ve arkadaşları		2017	Akıllı sayaç yük verileri, Zamansal veriler	LSTM+RNN, SARIMA, NARX, SVR
Rahman ve arkadaşları	ABD-Texas ve Austin eyaletleri	2018	Zamansal veriler, Geçmiş yük verileri	YSA, RNN, DRNN

3. AKILLI ŐEBEKELER

Genel olarak bugünkü elektrik Őebeke sistemine baktığımızda büyük ve çeŐitli elektrik santrallerinin ürettiđi enerjinin uzun iletim hatları boyunca belirli trafo merkezlerinden dağıtım ünitelerine aktarılması ve tüketici abonelere kullanabilecekleri gerilim seviyesinde verilmesi ile oluşan bir sistemdir (Yurdabak ve Őekkeli, 2014). Bu sistemde üretim aşamasında devreye giren veya çıkan jeneratör sayısı, üretilen enerjinin iletimi sırasında yaşanan elektriksel iletim kayıpları doğrudan dağıtım Őebekelerinin yapısına ve tüketicilerin enerji tüketim davranışlarına bađlıdır (Kabalcı ve Kabalcı, 2017). Gerek üretim aşamasında maksimum verimliliđi sağlamak gerekse iletim kayıplarını azaltarak tüketici abonelere ucuz, güvenilir, kaliteli elektrik enerjisinin temin edilebilmesi için gelişen teknolojiye paralel olarak klasik Őebeke yapısı yerini akıllı Őebeke yapısına bırakmıştır.

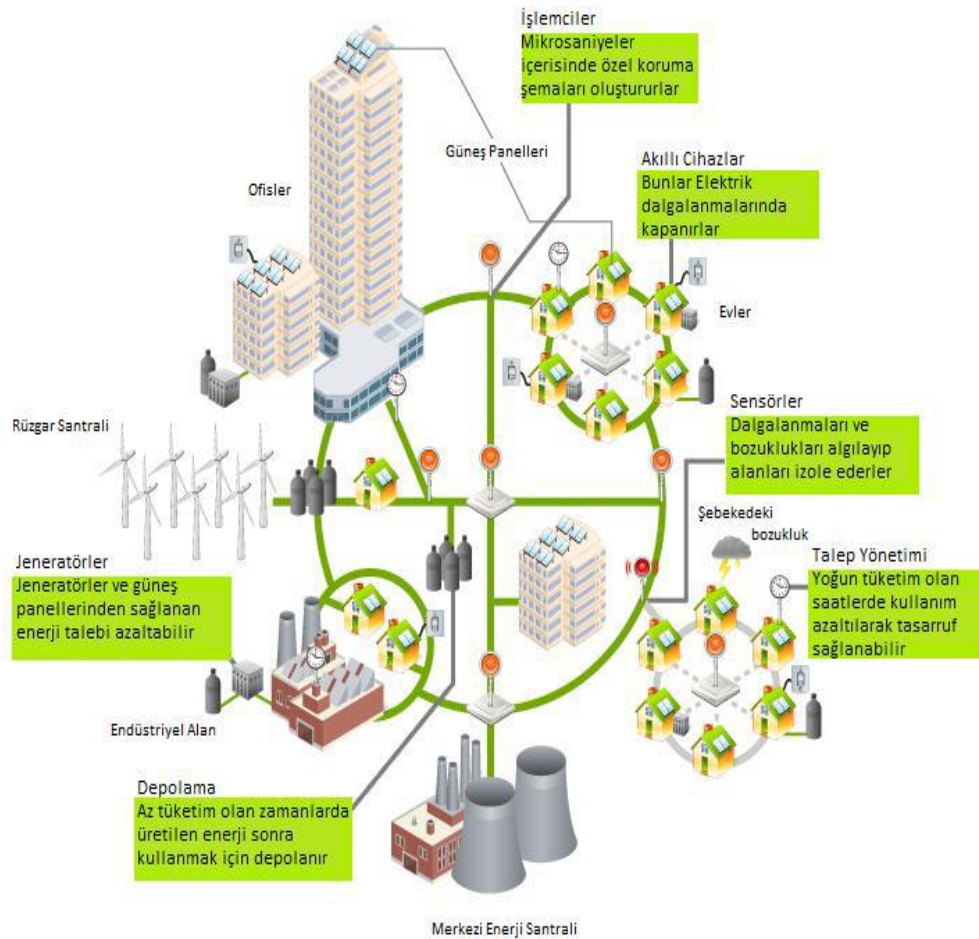
Elektronik alanındaki hızlı gelişim ve bilgi teknolojilerinin elektronik donanımlarla entegrasyonu ile uzaktan ölçüm ve izleme yapabilen, Őebeke üzerinde herhangi bir noktada yapısındaki sensör ađları sayesinde anlık deđişimlere hızlı tepkiler verebilen Őebeke yapısı akıllı Őebeke yapısı olarak adlandırılmaktadır (Kabalcı ve Kabalcı, 2017). Ayrıca akıllı Őebeke sistemine bađlı tüketiciler güneş panelleri, rüzgar türbinleri gibi yenilenebilir enerji kaynakları ile elektrik enerjisi ihtiyacının bir kısmını kendi üretebilmekte ve yoğun kullanım olmadığı zamanlarda üretilen enerjiyi Őebekeye aktarabilmektedir (Balođlu, 2017). Akıllı Őebekelerin klasik yapıdaki Őebeke yapısına göre sağlayacağı bazı avantajlar Őunlardır:

- Akıllı Őebekeler, enerji tüketiminin uzak mesafelerden ve anlık olarak izlenebilmesine ve kontrol edilebilmesine imkân sağlayacaktır. Böylece, klasik Őebekelerde kullanıcı verilerinin temini için gerekli olan insan kaynađı ihtiyacı ortadan kalkmış olacaktır.
- İletim ve dağıtım altyapısının iyileştirilmesi ve geliştirilmesini sağlayacaktır. Acil durumları erkenden algılayıp düzeltecek veya oluşmasını önleyecek Őekilde kendi kendini iyileştirebilecektir.
- Elektrik tüketim oranları belirli noktalarda gerçek zamanlı olarak karşılaştırılarak elektrik kayıp kaçak oranı azaltılabilecektir.
- Dağıtım ve iletim Őirketlerine daha fazla Őebekeyi yönetme fırsatı sunacaktır. Abonelerle elektronik ortamda iletişim sağlanacak, ticari-ekonomik kayıplar

azalacaktır. Tahakkuk tahsilât oranları artacak, sistem daha dengeli işletilecek, teknik kayıplar azaltılacak, kalite yükselecektir.

- Yenilenebilir enerji kaynaklarının daha kolay ve hızlı bir şekilde enterkonnekte sisteme dahil edilebilmesi sağlanacaktır.
- Kullanılacak elektrik enerjisi kadar elektrik üretimi yapılacağından Kyoto Protokolü'nde kabul edilen karbon salınımını azaltma hedefi için önemli bir atılım olacaktır.

Akıllı şebekelerin yapısı gereği farklı bileşenleri vardır. Birimler arası koordinasyonu sağlayacak, sahadan gerekli ölçümleri alacak bunları hızlı bir şekilde iletecek, anlık karar alma, değerlendirme yapmayı gerektirecek donanımsal ve yazılımsal bileşenlerinin olması gerekmektedir. Aşağıda şekil 3.1'de örnek bir akıllı şebeke yapısı ve bileşenleri verilmiştir.



Şekil 3.1. Akıllı şebeke yapısı (Okyay, 2012)

3.1. Akıllı Sayaçlar

Tüketici aboneler ile dağıtım şirketleri arasında PLC (Power Line Communication), RF (Radio Frequency), GPRS (General Packet Radio Service) gibi iletişim sistemlerini kullanarak çift yönlü veri akışını sağlayabilen sayaçlar akıllı sayaçlar olarak adlandırılmaktadır (Baloğlu, 2017). Anlık ve gerçek zamanlı verilerin toplanması, güç tüketim verileri, yenilenebilir enerji ile üretim yapılıyorsa bu enerjinin şebekeye aktarılan miktarı, diğer elektriksel parametrelerin anlık değişimi ve enerji kesintisi ile ilgili kayıtlar akıllı sayaçlar ile anlık kaydedilmekte ve bu veriler ilgili dağıtım merkezlerinin bilgi havuzlarında toplanmakta ve izlenmektedir (Yurdabak ve Şekkeli, 2014).

Akıllı sayaçlar sayesinde tüketicilerin kendi tüketim davranışlarını anlık olarak izleyebilmesi ile bireysel tüketicilerin enerji tüketimi konusundaki farkındalığı ve sorumluluğu artmaktadır. Çünkü tüketici gün bazında herhangi bir zaman diliminde harcadığı enerjiyi gözlemleyebilmektedir ve izleyebilmektedir. Bu sayede her bir tüketici kendi sayaç verilerini izleyerek kendi tüketim alışkanlıklarına yön verir ve bir bakıma bireysel olarak elektrik yük yönetimini gerçekleştirmiş olmaktadır. Kendine uygun yük tarifesini seçerek yük profilini belirleyebilmektedir. Bu ayrıca dağıtım şirketlerinin yük yönetimi adı altında yaptıkları benzer çalışmalarda iş yükünü azaltmaktadır. Aşağıda şekil 3.2’de örnek bir akıllı şebekeye bağlı meskenler için kullanılan akıllı sayaçlar gösterilmiştir.



Şekil 3.2. Akıllı sayaçlar

Akıllı sayaçlar ile beraber kullanımı yaygınlaşmaya başlayan akıllı priz ve akıllı ev aletleri gibi uygulamalar sayesinde meskenlerde her bir elektrikli cihazın tükettiği yükün izlenebilmesi ve bu verilerin kaydedilmesi sağlanmaktadır. Bu durum, gün içinde veya

yıl içinde herhangi bir zaman dilimi için tüketici abonenin yük profiline en çok etki eden elektrikli aletlerin kullanımı noktasında tüketici abonelere yol göstermekte ve elektrikli aletlerin tasarruf açısından en verimli şekilde kullanılmasına olanak sağlamaktadır.



4. YÜK TAHMİNİ

Veri tahmini, çoğu aktif sürecin işleyişi ve programlanması açısından gerekli bir ön ihtiyaçtır. Geleceği tahmin etmeden istenen eylemlerin miktarını planlamak, tasarımı yapılacak, planlanacak ve kontrol edilecek kaynakları tahmin etmek mümkün değildir.

Yük tahmini, geçmiş veriler ve mevcut durum verileri göz önüne alınarak gelecekteki durumunun ne olacağı varsayımına yönelik bir uygulamadır. Elektrik enerjisinin üretim, iletim ve dağıtım süreçlerinde gerekli olan tüm plan ve programlar yük tahmini uygulaması ile şekillenmektedir. Doğruluk oranı yüksek yük tahmini sonuçları alabilmek için uygulamanın esasını teşkil eden veri setinin iyi bir şekilde analiz edilmesi ve zamansal olarak hangi tahmin kategorisinde uygulama yapılacağı titizlikle belirlenmelidir. Yük tahmininde tahmin edilecek parametre olan yük tüketim verisine etki eden tüm faktörlerin de belirlenmesi ve veri olarak işlenip analiz edilerek uygulamaya dahil edilmeleri gerekmektedir.

4.1. Yük Tahmin Uygulamalarının Zamansal Olarak Sınıflandırılması

4.1.1. Uzun dönem yük tahmini

Yük tahmini çalışmalarının zamansal olarak sınıflandırılmaları, geliştirilen yeni metotlarla birlikte değişkenlik göstermiştir (Çevik, 2013). İlk yük tahmini uygulamaları uzun dönem yük tahmini için 10-30 yıllık bir aralığı kapsarken; bugün ise 1 yıldan fazla olan süreçleri kapsayan yük tahmini uygulamaları uzun dönem yük tahmini kapsamında yapılmaktadır (Çevik, 2013).

Uzun dönem yük tahminlerinde giriş parametreleri olarak ekonomik ve sosyal veriler sıklıkla kullanılmaktadır. Nüfus, gayri safi yurt içi hasıla, kişi başına düşen milli gelir gibi faktörler uzun dönem yük tahmininde önemli parametrelerdendir (Gürsoy, 2000).

4.1.2. Orta dönem yük tahmini

Bir aydan bir yıla kadarki zaman aralığı için yapılan yük tahmini çalışmaları orta dönem yük tahmini sınıfında yer almaktadır. Orta dönem yük tahmini uygulamaları enerji iletim ve dağıtım sistemleri için yapılacak yıllık işletme bakım programlarının oluşturulması ve mevcut santrallerin kapasitelerini arttıracak gerekli yatırımların

belirlenmesi için yapılmaktadır. Orta dönem yük tahmini uygulamalarında veri girdisi olarak ekonomik ve demografik-sosyal parametreler kullanılmaktadır.

4.1.3. Kısa dönem yük tahmini

Kısa dönem yük tahmini çalışmaları bir saatten bir haftaya kadar olan zaman aralığını kapsamaktadır (Akman,2018). Dağıtım sistemlerinde enerji yönetimi açısından enerjinin gerçek zamanlı kontrolünde kısa dönem yük tahmini uygulaması oldukça önemli bir konudur. Gün içindeki yük değişimlerinin ve puant yük miktarının belirlenmesi için dağıtım şirketleri kısa dönem yük tahmini yapmaktadır. (Ceylan, 2004). Ayrıca enerji santralleri için yapılacak kısa vadeli ünite açma-kapama programları ve yük paylaşımı düzenlemeleri için kısa dönem yük tahmini yapılmaktadır (Es, 2013). Kısa dönem yük tahminlerinde giriş parametresi olarak günlük, saatlik geçmiş zamanlı güç verileri, meteorolojik veriler, gün bilgisi gibi parametreler dikkate alınmaktadır.

4.2. Yük Tahminini Etkileyen Faktörler

4.2.1. Ekonomik ve demografik faktörler

Elektrik enerjisine olan talep miktarının değişimi, nüfus miktarı ve ekonomik refah seviyesi ile doğrudan bağlantılıdır (Es, 2013). Bir ülkede ya da bir ülkenin herhangi bir bölgesinde gelişmişlik göstergesi de olan elektrik tüketim miktarı ekonomik koşullara bağlı olarak artmakta veya azalmaktadır. Örneğin sanayileşmiş ve ekonomik refah seviyesi yüksek ülkelerde kişi başına düşen enerji tüketim miktarı da artmaktadır. Ancak sanayileşmemiş ve ekonomik refah seviyesi düşük olan ülkelerde kişi başına düşen enerji tüketim miktarı da düşmektedir.

4.2.2. Meteorolojik faktörler

Kısa dönem yük tahmini çalışmalarında en önemli parametreler meteorolojik faktörlerdir. Sıcaklık, nem, bulutluluk oranı, güneşlenme süresi, rüzgar hızı gibi faktörler yük tahmini çalışmalarında dikkate alınan faktörlerdir. Havadaki bu faktörlerin değişimi kullanılan ısıtıcı ve soğutucuların kullanım miktarını etkileyerek yük eğrilerinin sıklıkla değişmesine sebep olmaktadır. Örneğin kış aylarında sıcaklığın aşırı düştüğü zamanlarda

ısıtma amaçlı kullanılan elektriksel araç ve makinelerden dolayı yük talebi normal değerlerden fazla olmaktadır. Kış dönemlerindeki puant yük durumunun değişimi de, hem kış aylarındaki sıcaklık farklılıklarına bağlı olarak hem de gün içinde günün farklı saatleri için farklı değerlerde olmaktadır. Yaz aylarında ise sıcaklığın artmasına bağlı soğutma amaçlı kullanılan elektrikli araç ve gereçlerden dolayı yük talebi normal değerlerden fazla olmaktadır. Özellikle ülkemizde Güneydoğu Anadolu Bölgesinde yaz aylarında sulama amaçlı motor ünitelerinin kullanılması yük dengesizliğini daha çok arttırmaktadır (Gümüş ve Aydınöz, 2014). Nem parametresi de sıcaklık gibi özellikle etkisinin aşırı hissedildiği zamanlarda önemli bir parametre olmaktadır. Örneğin Akdeniz bölgesinde nemin aşırı hissedildiği yaz aylarında bunaltıcı havadan dolayı kullanımı artan klima ve benzeri soğutucu makinalardan dolayı enerji talebinde artış olmaktadır.

4.2.3. Zaman faktörü

Yük değişimlerinde zaman faktörünün de önemli etkileri vardır. Gün içinde farklı saatlerde farklı yük karakteristikleri gerçekleşebilmektedir. Gün bilgisi olarak verilen hafta içi ile hafta sonu günlerinde yük talebi miktarında büyük farklılıklar oluşabilmektedir. Tatil günleri ile tatil olmayan günler arasında da yük eğrilerinde büyük farklılıklar oluşmaktadır. Mevsimsel farklılıklar da yük talep miktarına etki etmektedir. Çünkü hem mevsimlere göre değişen sıcaklık, nem gibi meteorolojik faktörlerin yanında mevsimlere göre değişen gündüz ve gece süreleri arasındaki farklılıklar da enerji tüketim miktarını etkilemektedir.

4.2.4. Diğer faktörler

Yük değişimine etki eden bazı faktörler rastlantısal olarak oluşan olaylardan meydana gelebilmekte ve yük karakteristiğine etki edebilmektedir. Şebeke hattı üzerinde öngörülemeyen bir arıza veya doğal afetler sonucunda oluşan hasarlar ve bunun insanlar üzerindeki etkileri rastlantısal faktörlere örnek olarak verilebilir. Yine sosyal aktivitelerin arttığı ve buna paralel enerji tüketiminin de arttığı uluslararası spor müsabakaları, konserler gibi aktiviteler de rastlantısal faktörlere örnek olarak verilebilir.

5. MATERYAL

Yük tahmininde kullanılacak veriler analiz edilirken, yükü etkileyen faktörler göz önüne alınmalıdır. Bu faktörler genellikle zamansal (yıl, ay, hafta-içi, hafta-sonu ve gün içindeki saat bilgileri) veriler ile sıcaklık, nem, güneşlenme süresi ve havadaki bulutluluk oranı gibi coğrafi ve mevsimsel şartlara bağlı olan veriler olmaktadır (Cervone ve ark., 2017). Bunların yanında tahmin edilecek yük parametresinin tahmin sonuçlarının test edilmesi için geçmiş yük miktarı verileri bu giriş parametreleri baz alınarak kullanılır. Uygulamalarda ise giriş verisi olarak kullanılacak bazı parametrelerin çıkış verisine olan etkileri ihmal edilecek kadar az olduğunda bunlar işleme alınmaz ve çıkış verisine etki oranı en yüksek olan giriş parametreleri kullanılarak uygulamada yalınlık sağlanır ve işlem hacmi azaltılmış olur (Özel ve Topsakal, 2014).

Bu çalışmada sürdürülebilir meskenlere ilişkin Amerika Birleşik Devletleri'nin New York, Chicago, Denver, Los Angeles, Honolulu ve Phoenix eyaletlerinde bulunan mesken tipi güneş paneli ile elektrik enerjisi üreten 59 adet birbirinden bağımsız ve ayrı meskenden 2015 yılına ait bir yıllık saat başı alınan güneş paneli üretim-tüketim, şebekeden çekilen elektrik yük verileri ve her bir meskenin kendi özelinde olan çeşitli elektriksel araç-gereçlerin tüketim verilerini içeren Sundance veri seti kullanılmıştır (Chen ve Irwin, 2017). Bu veri seti <http://traces.cs.umass.edu/index.php/Smart/Smart> internet adresinden paylaşılmıştır. Uygulamada kullanılan 59 meskene ait şebeke yük miktarının tahmini her bir mesken için ayrı ayrı hesaplanmıştır. İçerik olarak sayaç şebeke tüketim verisi, güneş paneli üretim-tüketim verisi ve zamansal veriler tüm meskenlerde var olan ortak verilerdir. Aşağıda örnek olarak uygulamada kullanılan iki meskene ait bir günlük verileri içeren tablolar çizelge 5.1 ve çizelge 5.2'de gösterilmiştir.

Çizelge 5.1. 1135 numaralı meskenin 1 günlük veri seti


Gün	Ay	Haftanın günü	Hafta içi/Hafta sonu	Saat	Güneş paneli üretim-tüketim (kw)	Şebekeden çekilen enerji(kw)
1	1	4	1	0	-0,002	1,2873
1	1	4	1	1	-0,002	1,3277
1	1	4	1	2	-0,002	1,5567
1	1	4	1	3	-0,002	1,2112
1	1	4	1	4	-0,002	1,3174
1	1	4	1	5	-0,002	1,8415
1	1	4	1	6	-0,002	1,3530
1	1	4	1	7	-0,002	1,1442
1	1	4	1	8	-0,002	1,3695
1	1	4	1	9	-0,0028	2,1578
1	1	4	1	10	0,0163	2,4169
1	1	4	1	11	0,1355	1,7836
1	1	4	1	12	0,0918	1,9488
1	1	4	1	13	0,1522	2,1473
1	1	4	1	14	0,1017	1,6488
1	1	4	1	15	0,0720	1,5143
1	1	4	1	16	0,0435	0,8798
1	1	4	1	17	-0,0002	1,4260
1	1	4	1	18	-0,002	2,2283
1	1	4	1	19	-0,002	2,2104
1	1	4	1	20	-0,002	1,0508
1	1	4	1	21	-0,002	1,2903
1	1	4	1	22	-0,002	1,5245
1	1	4	1	23	-0,002	1,2448

Çizelge 5.2. 3065 numaralı meskenin 1 günlük veri seti

Gün	Ay	Haftanın günü	Hafta içi/Hafta sonu	Saat	Güneş paneli üretim-tüketim (kw)	Şebekeden çekilen enerji(kw)
1	1	4	1	0	-0,0052	0,7299
1	1	4	1	1	-0,0051	0,7064
1	1	4	1	2	-0,0051	0,7650
1	1	4	1	3	-0,0051	0,6639
1	1	4	1	4	-0,0050	0,5587
1	1	4	1	5	-0,0050	0,4413
1	1	4	1	6	-0,0050	0,5086
1	1	4	1	7	-0,0050	0,4656
1	1	4	1	8	-0,0050	0,4867
1	1	4	1	9	-0,0055	0,4591
1	1	4	1	10	0,3041	0,4290
1	1	4	1	11	0,3237	0,3900
1	1	4	1	12	1,1337	0,3347
1	1	4	1	13	0,7919	0,3576
1	1	4	1	14	0,4528	0,3256
1	1	4	1	15	0,2297	0,3461
1	1	4	1	16	0,1376	0,4817
1	1	4	1	17	0,0540	0,6307
1	1	4	1	18	-0,0036	0,6466
1	1	4	1	19	-0,0052	0,6779
1	1	4	1	20	-0,0052	0,7419
1	1	4	1	21	-0,0052	0,6460
1	1	4	1	22	-0,0052	0,6966
1	1	4	1	23	-0,0052	0,7393

Tablolardan anlaşıldığı üzere tüm zamansal veriler nümerik olarak ifade edilmiştir. İlk sütunda herhangi bir aya ait günler [1-31] arasındaki sayılarla, ikinci sütun bilgileri tarihsel olarak ay bilgisi [1-12] arasındaki sayılarla, üçüncü sütun olan haftanın günleri bilgisi [1-7] arasındaki sayılarla ve dördüncü sütun olan hafta içi-hafta sonu bilgisi [1-2] arasındaki sayılarla ifade edilmiştir. Beşinci sütun olan zaman verisi gün içi saat bilgisidir. Uygulamada incelenen 59 farklı meskenin güneş enerjisi üretim- tüketim miktarları meskenlerin içinde bulunduğu meteorolojik faktörler ile meskenlerde kullanılan güneş panellerinin sayısına göre farklılık oluşturmaktadır. Ayrıca güneş enerjisi üretim miktarı bir bakıma gün içindeki sıcaklık, nem, bulutluluk oranı gibi meteorolojik verilerin etkilediği bir parametre olması hasebiyle de bu faktörlerin dolaylı bileşkesi olarak düşünülerek uygulamamızda yük miktarını tahminde en etkili giriş değişkeni olarak alınmıştır. Şebekeden çekilen enerji verileri ise ana sayaç verisinden elde edilmiştir ve gün içinde kullanılan elektriksel araç-gereçlerin sayısı ve kullanım miktarı sıklığına göre gün içinde değişim göstermektedir.

Yenilenebilir enerji kaynağı (güneş paneli veya rüzgâr türbini) ile desteklenen bir meskenin şebekeden çektiği yükün hava şartlarına ve zamana bağımlılığının klasik şebekeye bağlı meskenlerin çektiği yüke kıyasen daha yüksek olması yük değişim karakteristiğini daha çok karmaşık hale getirmektedir (Bollen ve ark., 2016). Bu çalışmada da meskenlerde güneş paneli kullanılması sebebiyle şebekeden çekilen yükün zaman içindeki değişimi oldukça dinamiktir ve tahmini zordur. Örnek olarak iki meskene ait yük miktarının zamana göre değişimi Şekil 5.1’de verilmiştir.



Şekil 5.1. Şebekeden çekilen elektrik yükünün zamana göre değişim grafiği: (a) 1135 numaralı mesken, (b) 3065 numaralı mesken.

Şekil 5.1’de görüleceği üzere bu tip meskenlerde yük değişimi çok dinamiktir ve tahmini daha zordur. Çünkü yük tahmini anlık hava şartlarına ve kullanıcı alışkanlıklarına bağlı olduğundan dolayı veri değişimi çok hızlıdır.

6. METOT

6.1. Metodolojide Genel Yaklaşım

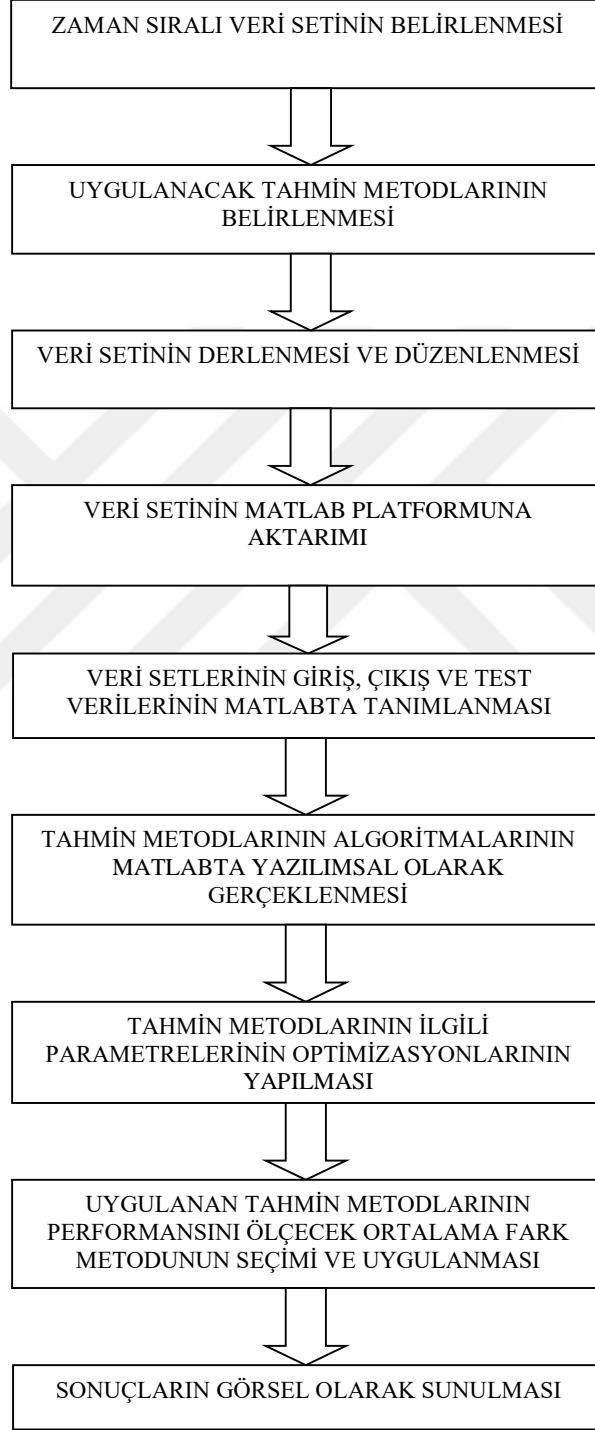
Yük tahmini yöntemleri incelendiğinde, yük tahmini yapılacak yerleşkenin bulunduğu coğrafi şartlar, iklimsel, çevresel etmenler ve şebekenin yapısı uygulanacak tahmin metodunu etkilemektedir (Karaca ve Karacan, 2016). Ayrıca tahmini yapılacak yüke ait veri setinin zamansal sınır aralığı da uygulanacak metodun seçiminde belirleyici bir unsurdur.

Tahmin yöntemleri genel olarak istatistiksel yöntemler ve akıllı yöntemler olmak üzere iki gruba ayrılmaktadır (Esener ve ark., 2012). “İstatistiksel yöntemler, zaman serileri analizi, regresyon analizi, hareketli ortalamalar analizi, yüzeysel verileri ile yapılan tahmin, ekonomik verileri ile yapılan tahmin yöntemleri olarak sayabiliriz (Esener ve ark., 2012). “Akıllı yöntemler ise yapay sinir ağları, bulanık mantık ve her iki yöntemi de kullanan uzman sistemler olarak adlandırılan yöntemlerdir” (Balcı ve ark., 2012). Literatürde yapılan yük tahmini uygulamalarında, kısa dönem yük tahmini için hem geleneksel yöntemlerle hem de yapay sinir ağları yöntemi ile yapılmış birçok çalışma vardır ve bu çalışmaların çoğunda birbirinden farklı yapıda YSA modelleri ve istatistiksel yöntemler kullanılmıştır (Balcı ve ark., 2012). Her şebeke yapısındaki yapısal farklılıklar ve şebekeye bağlı tüketicilerin enerjiyi kullanma davranışlarının çeşitlilik göstermesi uygulamalarda çeşitlilik arz eden tahmin metotlarının meydana gelmesine sebep olmuştur.

Günümüzde akıllı şebekeler kapsamında şebekeden alınan toplam yük durumunun yanı sıra bireysel bazda tüketici abonelerin şebeke yüküne olan etkileri daha ayrıntılı olarak analiz edilebilmektedir. Akıllı şebekeden elektrik çeken meskenler güneş enerjisi gibi alternatif enerji kaynakları ile elektrik üretebilmektedir. Böylece tüketici aboneler hem şebekeden enerji alan hem de belli şartlar altında şebekeye enerji tedarik eden bir konuma evirilmiştir. Bu çift yönlü enerji akışının olduğu şebeke yapısında yük karakteristiği daha karmaşık ve dinamik bir hale dönüşmüş olmaktadır.

Bu çalışmada birçok regresyon probleminde başarılı sonuç üreten lineer regresyon yöntemini dinamik sistemlere uygulayabilmek ve herhangi bir zamana ait şebekeden çekilen elektrik miktarının tahmin başarısını arttırmak için geçmiş verilerin de önemli olduğu geri beslemeli lineer regresyon adı verilen yeni bir yöntem önerilmiştir (Ertuğrul, 2016). Önerilen yaklaşımı test etmek için, Smart Project kapsamında U Toplu İz

Havuzunda paylaşılan Sundance veri seti kullanılmıştır (UMass Trace Repository, 2018). Önerilen yöntemin başarısını doğrulamak için her bir veri setine lineer regresyon ve aşırı öğrenme metotları uygulanmıştır. Aşağıda şekil 6.1’de bu uygulamada kullanılan metodolojinin genel yaklaşımı akış diyagramı ile gösterilmiştir.



Şekil 6.1. Uygulama metodolojisinin işlem akış diyagramı

Akış diyagramı incelendiğinde birinci aşamada uygulamada kullanılacak veri seti belirlenmiştir. Uygulama zamana bağlı anlık değişen elektriksel yük tahmini ile ilgili olduğundan veri seti olarak zaman sıralı veri seti seçilmiştir ve kısa dönem yük tahmini için zamansal olarak gerekli sınırları barındırması da dikkate alınmıştır. İkinci aşamada veri setine uygulanacak en uygun ve işlem hacmi az olan, hızlı olan metotlar seçilmiştir. Üçüncü aşamada veri setinin tablo olarak derlenmesi ve düzenlenmesi sağlanmıştır. Bunun yanında veri setinde bulunan parametrelerin giriş değişkenleri ve çıkış değişkeni olarak ayrılması da bu aşamada yapılmıştır. Dördüncü aşamada derlenmiş ve düzenlenmiş veri setleri Matlab platformuna aktarılmıştır. Beşinci aşamada her bir veri seti için giriş ve çıkış verileri ve test verileri Matlabta tanımlanmıştır. Altıncı aşamada veri setlerine uygulanacak tahmin metotlarının algoritmalarının Matlabta yazılıma dökümü sağlanmıştır. Yedinci aşamada yine Matlabta her bir metodun kendi özelinde gerekli parametre optimizasyonları yapılmıştır. Geri beslemeli lineer regresyon modelinde geri besleme eleman sayısı, aşırı öğrenme makinelerinde aktivasyon fonksiyonu, gizli katmandaki nöron sayısı gibi parametreler optimize edilerek uygulanan metotların en iyi sonuçları vermeleri sağlanmıştır. Sekizinci aşamada, uygulanan metotların performans ölçümü için ortalama fark metodu olan Kök Ortalama Kare Hata (RMSE) metodu kullanılmıştır. Son aşamada ise sonuçlar görsel olarak sunulmuştur.

6.2. Uygulamada Kullanılan Tahmin Metotları

6.2.1. Lineer regresyon

Doğada meydana gelen birçok olayda sebep sonuç ilişkisi vardır ve bu ilişkinin saptanması ve yorumlanması bilimsel çalışmaların konusu olmuştur. Regresyon analizi de aralarında sebep sonuç ilişkisi bulunan iki veya daha fazla değişken arasındaki ilişkiyi istatistiksel olarak inceleyen ve bu inceleme ve analiz ile o konu ile ilgili çıkarımlar, tahminler üreten bir istatistiksel analiz metodudur (Çevik, 2013). Regresyon analizi ile iki veya daha fazla değişken arasında matematiksel ve istatistikî açıdan bir bağıntı olup olmadığı eğer varsa bu bağıntının hangi oranda olduğu saptanmaktadır. Bu saptanan orana bağlı olarak ilgili değişkenin tahmin analizi yapılmaktadır.

Regresyon analizi ile yapılan tahmin sonuçlarının doğruluk oranı değişkenler arasındaki bağıntı kuvvetine göre değişmektedir (Balcı ve ark., 2012). Bağımsız

değişkenin tahmini yapılacak bağımlı değişkeni etkileme oranı arttıkça tahmin sonucunun doğruluk oranı da artmaktadır (Karaca ve Karacan, 2016). Lineer regresyonda serbest değişkenin tek bağımlı değişken üzerindeki etkisinin analizi yapılabildiği gibi serbest değişkenlerin birden fazla olduğu durumlarda da analiz yapılabilmektedir.

Basit regresyon analizi

Bir bağımlı değişkenin sadece bir bağımsız değişkene göre lineer ilişkisini saptamak üzere kullanılan regresyon yöntemidir. Tahmin analizinde tahmin edilecek değişken bağımlı değişken olarak tanımlanırken, diğer değişken ise bağımsız değişken olarak tanımlanır ve bağımlı değişken üzerindeki etkisi oranında sonuca etki eder.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (6.1)$$

Yukarıdaki denklemde basit lineer regresyonun matematiksel ifadesi verilmiştir. Bu denklemde x değişkeninin değerine göre y bağımlı değişkenin değeri, β_0 ve β_1 katsayılarının minimum ε hata parametresini bulmak üzere her bir döngüde değiştirilmesi ile sağlanır (Palit ve Popovic, 2005). Yani tahmin sonuçlarının doğruluk oranı β_0 ve β_1 katsayılarının en küçük hata miktarını sağlayan değerlerinde gerçekleşmektedir. En küçük hata miktarının tespiti ise en küçük kareler metodu (EKK) ile belirlenmektedir (Palit ve Popovic, 2005). Aşağıdaki denklemde hata miktarını hesaplayan denklem verilmiştir.

$$\varepsilon = \sum [y - (\beta_0 + \beta_1 \cdot x)]^2 \quad (6.2)$$

Yukarıdaki denklemde minimum hata miktarını bulmak için denklemin sırayla β_0 ve β_1 katsayılarına göre kısmi türevleri alınarak sıfıra eşitlenir ve bu durumda aşağıdaki denklemler elde edilir.

$$\frac{d\varepsilon}{d\beta_0} = -2 \sum [y - (\beta_0 + \beta_1 \cdot x)] = 0 \quad (6.3)$$

$$\frac{d\varepsilon}{d\beta_1} = -2 \sum [y - (\beta_0 + \beta_1 \cdot x)] \cdot x = 0 \quad (6.4)$$

$$\sum y = \beta_0 \cdot \sum 1 + \beta_1 \cdot \sum x \quad (6.5)$$

$$\sum x \cdot y = \beta_0 \cdot \sum x + \beta_1 \cdot \sum x^2 \quad (6.6)$$

Yukarıda verilen denklemler normal denklemleri olarak adlandırılır ve minimum hata miktarını verecek olan β_0, β_1 katsayıları bu denklemlerin analizi ile belirlenmektedir (Balcı ve ark., 2012).

Çok değişkenli regresyon analizi

Çok değişkenli regresyon analizinde bağımlı değişkene etki eden birden fazla bağımsız değişken olması durumu incelenmektedir. Örneğin elektrik enerjisi tüketim miktarının tahminine etki eden birden çok faktör vardır. Çevresel etmenler (sıcaklık, nem) sosyo-ekonomik faktörler, şebeke yapısı gibi birden fazla değişken tahmini etkileyebilmektedir (Gajowniczek ve Zabkowski, 2017). Her bir bağımsız değişkenin tahmini yapılacak değişken ile olan istatistikî bağı farklı oranda olduğundan tahmin sonucuna etkileri de farklı olmaktadır. Çoğu zaman uygulamalarda çok sayıda bağımsız değişkeni olan sistemler için yalınlık sağlamak ve işlem hızını arttırmak için bağımsız değişkenlerden bağımlı değişkene etkileri en fazla olanlar seçilip; bağımlı değişkene etkileri ihmal edilecek kadar az olan değişkenler ise elimine edilmektedir (Gajowniczek ve Zabkowski, 2017). Aşağıdaki denklemde çok değişkenli regresyon metodunun matematiksel ifadesi verilmiştir.

$$Y = \beta_0 + \sum_{t=1}^m \beta_t X_t + \varepsilon \quad (6.7)$$

Yukarıdaki denklemde Y bağımlı değişkeni ve X_t serbest değişkenleri göstermektedir. Regresyon katsayıları olarak ifade edilen β_0 ve $\beta_t, t=1, m$ her bir bağımsız değişkenin değişiminin bağımlı değişken üzerindeki etkisini belirleyen katsayılardır. Basit regresyon analizinde olduğu gibi çok değişkenli regresyon analizinde de minimum ε hata miktarını bulmak için $\beta_0, \beta_1, \beta_2, \beta_3, \dots, \beta_m$ regresyon katsayıları en küçük kareler metodundan (EKK) yola çıkarak belirlenmektedir. Aşağıda iki bağımsız değişkenli bir sisteme ait ana denklem ve normal denklemleri verilmiştir.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon \quad (6.8)$$

$$\sum y = m\beta_0 + \beta_1 \sum x_1 + \beta_2 \sum x_2 \quad (6.9)$$

$$\sum x_1 y = \beta_0 \sum x_1 + \beta_2 \cdot \sum x_1 x_2 + \beta_1 \sum x_1^2 \quad (6.10)$$

$$\sum x_2 y = \beta_0 \sum x_2 + \beta_1 \cdot \sum x_1 x_2 + \beta_2 \sum x_2^2 \quad (6.11)$$

Yukarıda verilen bu denklemlerin analizi ile regresyon katsayıları en küçük ε hata miktarını verecek şekilde belirlenmektedir (Balcı ve ark., 2012).

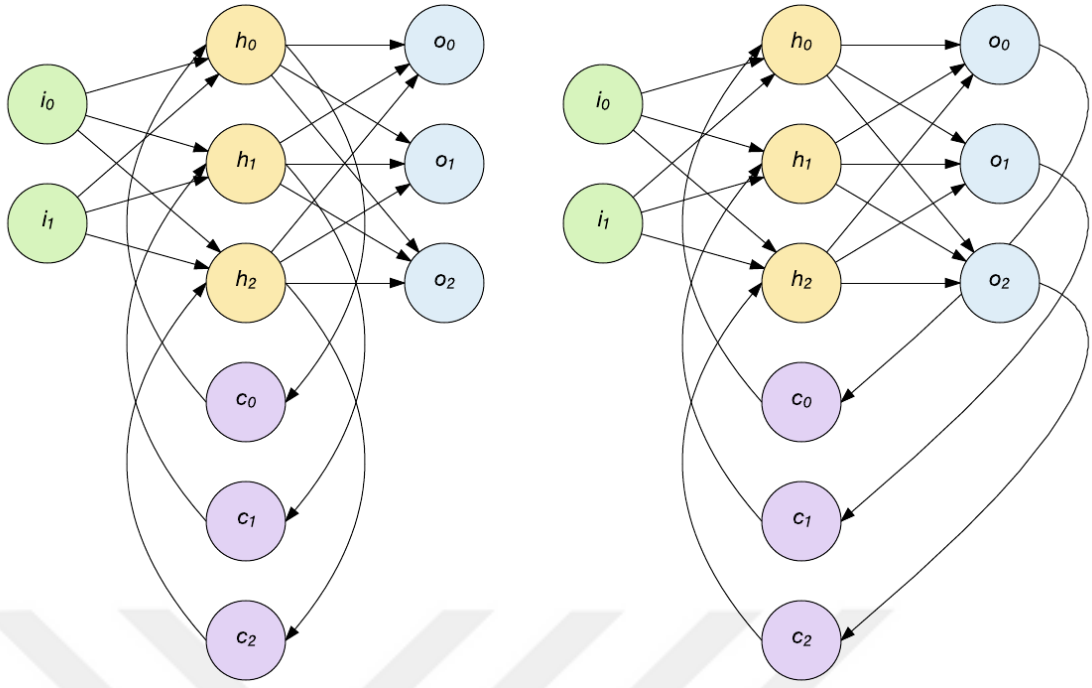
6.2.2. Geri beslemeli lineer regresyon

Yenilenebilir enerji kaynağı ile desteklenen ve akıllı şebekeye bağlı bir meskenin şebekeden çektiği yük hava şartlarına, zamana ve tüketici abonelerin tüketim davranışlarına bağlı olduğundan elektrik dağıtım sisteminin lineer olmama özelliği artmaktadır. Diğer bir deyişle sistemin dinamikliği artmaktadır (Ertuğrul,2016).

GBLR metodu, LR'nin lineer olmayan, dinamik sistemlerin modellenmesinde yetersiz kalması ve zaman sıralı veri setlerinde istenen performansta tahmin analizi yapamadığı için bu çalışmada yeni bir metot olarak önerilmiştir. Bu yeni metodun ortaya çıkmasında özellikle belirli bir düzen ve sıra ile oluşturulmuş zaman sıralı veri setlerinde oldukça iyi tahmin sonuçları veren geri beslemeli sinir ağlarından (GBSA) esinlenilmiştir (Hardalaç ve Kutbay, 2013). GBYSA'da ileri beslemeli sinir ağlarından (İBYSA) farklı olarak verinin işlenmesi çift yönlü sağlanmaktadır. Anlık giriş verilerinin yanında önceki girişlerden elde edilmiş çıktı verileri kontekst adı verilen katman üzerinden ağ yapısındaki gizli katmanlara aktarılarak bir veri döngüsü oluşturulmaktadır (Ataseven, 2013). Bu yapılarıyla GBSA topolojileri doğrusal olmayan dinamik bir davranış göstermektedir. Uygulamalarda sıkça kullanılan GBSA'lara örnek olarak Hopfield, Elman ve Jordan ağları örnek olarak verilmektedir.

Jordan ve Elman ağ yapılarında katmanlar önceki girişlerden elde edilmiş çıktı verilerini bir sonraki iterasyon işlemine kadar geçici olarak saklamaktadır (Hardalaç ve Kutbay, 2013). Yani bir bakıma bu ağ yapılarında geçici hafıza oluşturulmaktadır. İşte tam da bu özellikleri itibarıyla belli bir düzen ve sıra ile oluşturulmuş zaman sıralı veri setlerinde GBYSA metotları İBYSA metotlarına göre uygulamalarda daha iyi veri tahmini sonuçları vermektedir.

Aşağıda şekil 6.2'de GBSA metotlarından Elman ve Jordan ağlarının genel yapısı gösterilmiştir.



Şekil 6.2. Elman ve Jordan ağ modelleri (Jones, 2017)

Şekil 6.2’de görüldüğü üzere Elman ağında (soldaki resim), gizli katmandan kontekst katmanına bir bağlantı oluşturulmakta ve gizli katmandan alınan çıkış elemanları kontekst katmanında yeniden değerlendirilerek, optimize edilerek tekrar gizli katman girişine dönmektedir. Elman ağı bir sonraki iterasyona kadar eski değerleri kontekst katmanında tutar. İterasyonlar, çıkış hata miktarının uygun değerlerde minimize edilmesine kadar devam ettirilir. Jordan ağında (sağ taraftaki resim) ise çıkış katmanından alınan çıktı elemanları kontekst katmanına alınır ve burada yeniden değerlendirilerek ve uygun katsayılarla optimize edilerek gizli katman girişlerine gönderilir. Kontekst katmanı bir sonraki iterasyona kadar katmanında yeniden değerlendirilen çıkış elemanlarını bir müddet saklar.

İşte yukarıda anlatıldığı gibi belirli bir düzen ve sırayla oluşturulan zaman sıralı veri setlerinde geri beslemeli ağ topolojilerinin sağladığı avantajlardan dolayı klasik lineer regresyon modeli modifiye edilip geri beslemeli ve lineer olmayan bir yapı olarak geri beslemeli lineer regresyon metodu tasarlanmıştır. LR yapı olarak tek katmanlı bir yapıda iken geri beslemeli lineer regresyon ise çıkıştan alınan elemanların bir ara birimde tekrar değerlendirilip uygun katsayılar ile optimize edilerek giriş olarak sisteme adapte edilmesi ile çok katmanlı bir yapıda işlem görmektedir. Klasik LR’de verilerin sıralamasının hiçbir önemi yoktur. Bu sebeple aslında önemli bir parametre olan verinin sırasının da etkili


olması önerilen metodun zaman sıralı veri setlerinde başarısını artırabilecek bir faktördür. GBLR için çıkış değerinin “k” anındaki denklemi aşağıda verilmiştir.

$$Y[k] = \beta_0 + \sum_{i=1}^m \beta_i X_i[k] + \sum_{j=1}^d \beta_{m+j} Y[k-j] \quad (6.12)$$

Yukarıdaki denklemde k verinin zaman sırasını d ise geri beslemeli çıkış sayısını göstermektedir. Regresyon katsayıları olarak ifade edilen β_0 ve β_i , $i=1, m$ her bir bağımsız değişkenin değişiminin bağımlı değişken üzerindeki etkisini belirleyen katsayılardır. Burada geri besleme olarak girişe aktarılan değerler regresyon katsayılarını optimize ederek regresyon analizinde çıkış değerinin doğruluğunu arttırmaktadır. Önceki çıktı bilgileri önemsiz sistem girişine dahil edilerek, uygulamada tahmin analizinin doğruluk oranı arttırılmaktadır.

6.2.3. Aşırı öğrenme makinaları

Aşırı öğrenme makinaları (ELM) tek bir gizli katmana sahip ileri beslemeli bir YSA modelidir (Kaya ve ark., 2014). ELM gradyan tabanlı tek katmanlı ileri beslemeli YSA modellerinden farklı olarak ağırlıklar ve eşik değerleri yenilenerek (iterasyon) belirlenmemektedir. Bunun yerine giriş katmanı ağırlıkları ve eşik değerleri rastgele olarak atanmakta ve çıkış katmanı ağırlıkları ise analitik olarak hesaplanmaktadır (Kaya ve ark., 2014). Tek gizli katmanlı ileri beslemeli bir YSA modeli Şekil 6.3'te gösterilmiştir.



Şekil 6.3. İleri beslemeli tek gizli katmanlı YSA

Şekil 6.3'te verilen ileri beslemeli sinir ağı modelinin çıkış ifadesi aşağıdaki gibi hesaplanmaktadır.

$$y = \sum_{j=1}^m \beta_j g\left(\sum_{i=1}^n w_{ij} x_i + b_j\right) \quad (6.13)$$

Denklem (6.13)'te β_j , $g(\cdot)$, w_{ij} , x_i , ve b_j sırasıyla çıktı ağırlığını, aktivasyon fonksiyonunu, girdi ağırlığını, giriş vektörünü ve eşik değerini göstermektedir. ELM'nin en önemli özelliği gradyan tabanlı YSA'lara kıyasla eğitim süreçlerinin çok daha hızlı olması ve yerel minimum değerlerine yakalanmamalarıdır. ELM'nin performansı seçilecek aktivasyon fonksiyonu ile gizli katmandaki nöron sayısının en iyi sonucu verecek şekilde seçilmesiyle artmaktadır.

6.3. Uygulamada Değerlendirme ve Performans Kriterleri

Önerilen GBLR metodunun başarısının doğrulanması amacıyla her bir veri seti LR ve ELM ile test edilmiştir. GBLR metodunda çıkıştan alınan "d" geri besleme eleman sayısı parametresi optimize edilerek GBLR'nin en iyi performansı vermesi sağlanmıştır. Yine ELM metodunda aktivasyon fonksiyonu ve gizli katmandaki nöron sayısı gibi parametreler optimize edilmiştir. GBLR metodunu LR ve ELM ile karşılaştırmak ve performans değerlendirmesini yapmak için RMSE metodu kullanılmıştır. Aşağıdaki denklemde RMSE metodunun matematiksel ifadesi verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_{gerçek,i} - x_{tahmin edilen,i})^2}{n}} \quad (6.14)$$

Burada $x_{gerçek}$ ve $x_{tahmin edilen}$ sırasıyla ilgili verinin gerçek değerleri ve tahmin edilen değerleri göstermektedir.

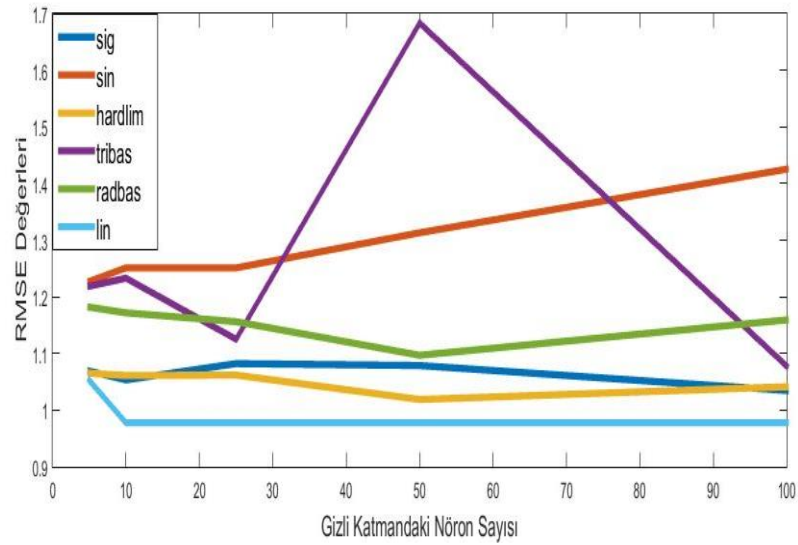
7. ARAŞTIRMA BULGULARI

Bu çalışmamızda, 59 farklı meskenden alınmış elektrik tüketim ve güneş paneli üretim verilerinden faydalanılarak her bir mesken için şebekeden talep edilecek bir günlük yük tahmini yapılmıştır. Meskenleri tanımlamak için veri seti dosya numaralarını ifade eden sayılar kullanılmıştır. Çalışmada önerilen GBLR metodunun başarısının doğrulanması amacıyla her bir veri seti LR ve ELM ile test edilmiştir. Uygulanan metotların en iyi performansı vermesi için yapılan parametre optimizasyonlarının sonucu her bir veri setinin kendine has giriş değişkenleri olduğundan ve verilerin toplandığı meskenlerin farklı coğrafi bölgelere ait olması gibi sebeplerden dolayı farklı çıkmıştır. Tahmin metotlarının karşılaştırılması için RMSE metodu kullanılmıştır. Uygulamada kullanılan işlem akışının ana hatları aşağıda maddeler halinde açıklanmıştır.

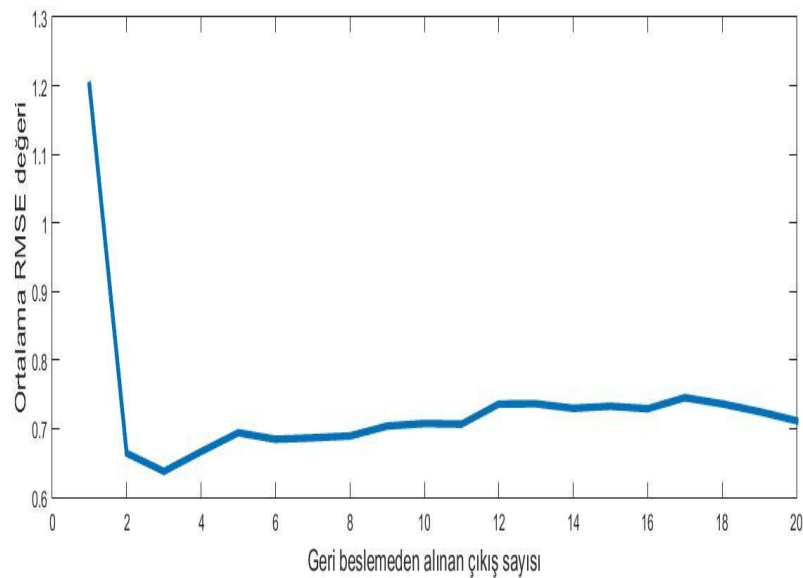
- Kullanılan her bir veri seti için rastgele 10 ayrı veri anı belirlenmiş ve bu anlardan öncesine ait veriler kullanılarak şebekeden çekilen bir günlük yük tahmini yapılmıştır. Diğer bir deyişle her bir meskenin için başarı çapraz doğrulama yöntemiyle belirlenmiştir. Böylece uygulamada sonuçların daha tutarlı olması sağlanmıştır.
- Aşırı öğrenme metodunun performansını etkileyen en önemli parametreler olan aktivasyon fonksiyonu çeşidi ve gizli katmandaki nöron sayısı Matlab'ta yapılan bir uygulama ile her bir veri seti için ayrı olarak belirlenmiştir.
- Geri beslemeli lineer regresyonda en önemli parametre olan geri besleme eleman sayısı yine Matlab'ta yapılan bir uygulama ile her bir veri seti için belirlenmiştir.

Aşağıda örnek olarak verilen grafiklerde 1135, 2714, 3065 numaralı meskenler için yapılan parametre optimizasyon sonuçları verilmiştir.

Verilen grafikler incelendiğinde şekil 7.1'de de görüldüğü üzere, 1135 numaralı meskene ait veri setine uygulanacak ELM için minimum RMSE değerini veren yani ELM'nin en iyi performans gösterdiği parametreler lineer aktivasyon fonksiyonu ile gizli katmandaki nöron sayısının 10 olduğu noktadır. Aynı mesken için geri beslemeli lineer regresyon uygulaması için belirlenecek geri besleme eleman sayısı parametresi ise şekil 7.2'de görüldüğü üzere minimum RMSE değerini verdiği ve geri besleme eleman sayısının 3 olduğunu gösteren $x=3$ için $y=0,6377$ noktasındadır.

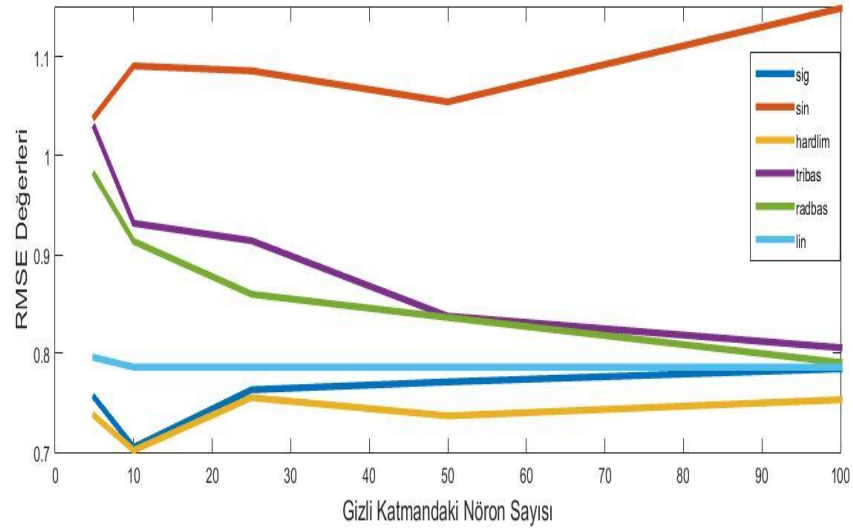


Şekil 7.1. 1135 numaralı mesken için ELM parametrelerine göre RMSE değişimleri




Şekil 7.2. 1135 numaralı mesken için GBLR metodunda geri besleme eleman sayısına göre ortalama RMSE değişimleri

2714 numaralı mesken için ise şekil 7.3 incelendiğinde ELM için en iyi sonuçları hardlim aktivasyon fonksiyonunda ve gizli katmandaki nöron sayısının 10 olduğu noktada olduğu görülmektedir. Ayrıca şekil 7.4'te 2714 numaralı mesken için uygulanacak geri beslemeli lineer regresyonda geri besleme eleman sayısı 2 olarak seçilmesi durumunda minimum RMSE değerini aldığını görülmektedir

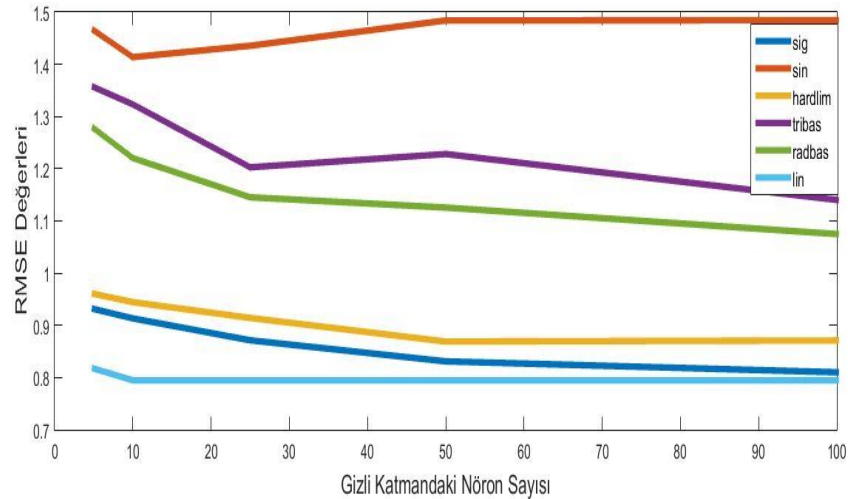


Şekil 7.3. 2714 numaralı mesken için ELM parametrelerine göre RMSE değişimleri

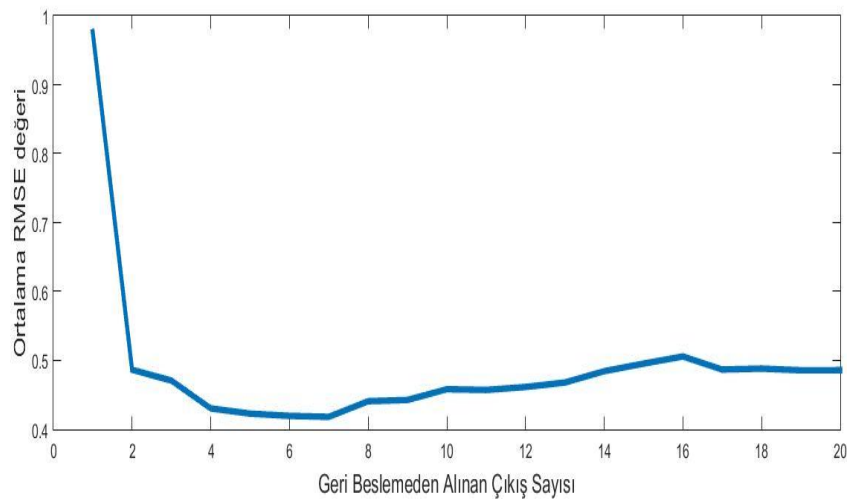


Şekil 7.4. 2714 numaralı mesken için GBLR metodunda geri besleme eleman sayısına göre ortalama RMSE değişimleri

Son olarak 3065 numaralı mesken için şekil 7.5 incelendiğinde ELM için en iyi sonuçları lineer aktivasyon fonksiyonunda ve gizli katmandaki nöron sayısının 10 olduğu noktada olduğu görülmektedir. Geri beslemeli lineer regresyon için en iyi performansı ise şekil 7.6'dan görüldüğü üzere geri besleme eleman sayısının 7 olarak alınması durumunda gerçekleşeceği açıkça görülmektedir.




Şekil 7.5. 3065 numaralı mesken için ELM parametrelerine göre RMSE değişimleri

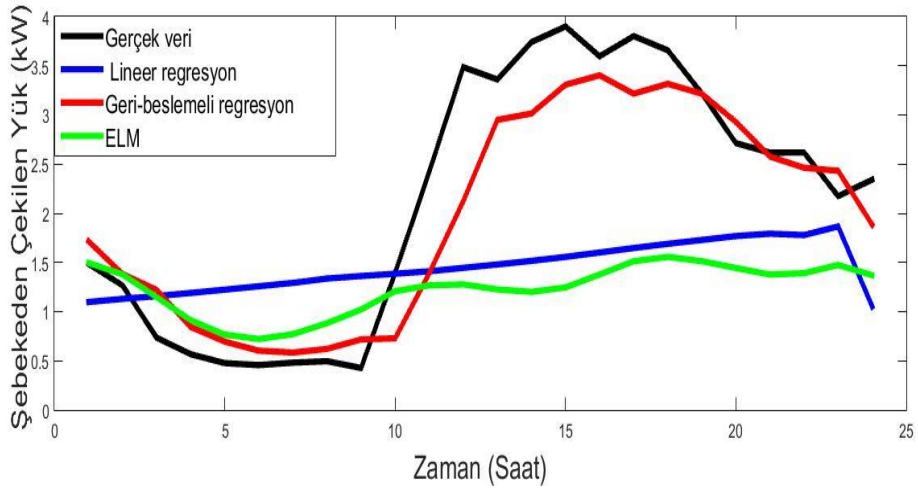


Şekil 7.6. 3065 numaralı mesken için GBLR metodunda geri besleme eleman sayısına göre ortalama RMSE değişimleri

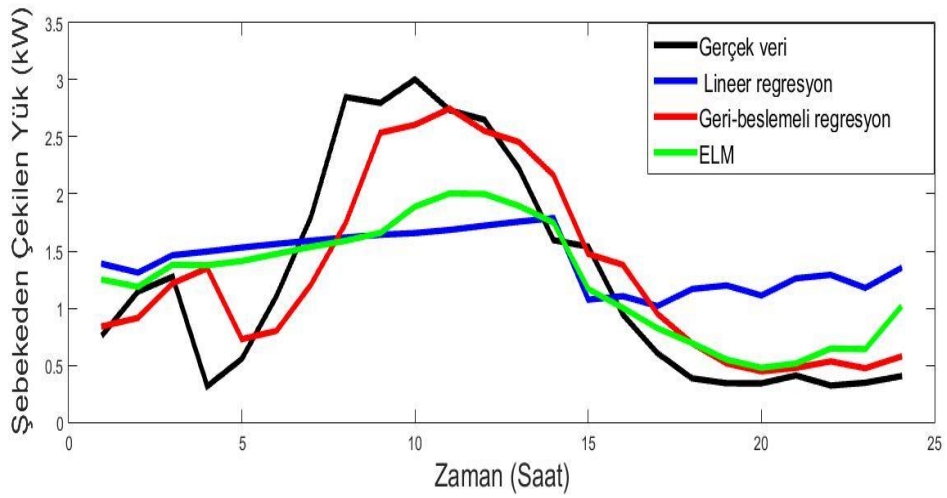
Uygulama aşamasında kullanılan metotların parametre optimizasyonları sonrasında tahmin metotlarının bir günlük tahmin performans eğrileri gerçekleştirilmiştir. Aşağıdaki şekil 7.7, şekil 7.8 ve şekil 7.9'da verilen grafiklerde örnek olarak 1135, 2714, 3065 numaralı meskenlerin bir günlük şebeke yük tahmini eğrileri verilmiştir.



Şekil 7.7. 1135 numaralı meskene ait bir günlük şebeke yük tahmini eğrileri



Şekil 7.8. 2714 numaralı meskene ait bir günlük şebeke yük tahmini eğrileri



Şekil 7.9. 3065 numaralı meskene ait bir günlük şebeke yük tahmini eğrileri

Yukarda verilen grafikler incelendiğinde meskenlerin her birinden elde edilen tahmin hatasının diğer meskenlerden farklı olduğu görülmüştür. Bunun nedeni olarak

- Her bir meskende yaşayanların farklı tüketim davranışlarının olması
- Meskenlerde kurulu olan güneş panellerinin üretim kapasitesi
- Meskenlerin farklı coğrafik bölge özelliklerinin olması
- Meskenlere ait tüm veri setlerinde çıkış verisi olarak şebekeden çekilen yük miktarı alınmıştır ancak giriş olarak her bir meskende farklı sayıda bulunan ve birbirinden farklı giriş parametreleri içermesi düşünülmektedir.

Aşağıda çizelge 7.1’de tüm veri setleri için (her bir mesken için) uygulanan metotlara göre RMSE değerlerinin sonuçları verilmiştir. Çizelge 7.2’de ise tüm veri setlerini baz alarak tahmin metotlarının RMSE değerlerinin ortalaması verilmiştir.



Çizelge 7.1. Her bir meskenin uygulanan tahmin modellerine göre RMSE değerleri

Mesken No	LR	ELM	GBLR	Mesken No	LR	ELM	GBLR	Mesken No	LR	ELM	GBLR
049	0,3699	0,5772	0,3483	950	1,21	1,07	0,87	2141	0,6957	0,6932	0,591
068	0,4235	0,5266	0,3933	953	0,53	0,73	0,47	2145	0,8319	1,1844	0,7661
114	0,4095	0,6119	0,3709	1004	1,2735	1,06	0,8726	2543	0,3897	0,498	0,3532
116	0,3606	0,6519	0,3424	1007	0,4462	1,2097	0,4717	2701	0,2234	0,3946	0,207
119	0,2759	0,3749	0,2357	1008	0,9993	1,09	0,9573	2705	0,8427	0,876	0,6694
121	0,5628	0,7594	0,5259	1009	0,9237	0,906	0,8123	2714	0,8216	0,7942	0,4812
123	0,5144	0,6153	0,4547	1135	1,1074	1,0493	0,6766	2722	0,9473	0,874	0,7224
124	0,2731	0,3204	0,2416	1230	0,8326	0,9093	0,6668	2727	0,7207	0,8818	0,6649
500	0,5071	0,6404	0,4905	1333	0,799	1	0,7319	2851	0,5281	0,6473	0,5101
502	0,4394	0,6638	0,3734	1955	0,5248	0,6066	0,4022	3065	0,8574	0,7188	0,3932
554	0,5972	0,6535	0,543	1956	0,283	0,4329	0,2625	3134	0,9814	1,0689	0,7417
625	0,34	0,49	0,31	1960	0,2327	0,5706	0,2191	3173	0,9615	1,0248	0,822
703	1,28	1,14	0,91	1962	0,1933	0,4025	0,179	3610	0,5902	0,5988	0,4931
704	0,23	0,4	0,22	1965	0,6409	0,7871	0,5632	3923	0,6504	0,5967	0,3153
736	0,7	0,62	0,42	1966	0,2504	0,5182	0,2445	3924	0,2698	0,3446	0,2297
766	0,35	0,64	0,3	1969	0,2232	0,4737	0,2212	4336	1,5113	1,6021	0,7907
800	0,95	0,93	0,68	1974	0,7992	0,7708	0,5426	4839	0,0471	0,4025	0,0527
805	0,22	0,86	0,22	1975	0,4734	0,6631	0,3772	10011	0,4261	0,5277	0,3579
891	0,26	0,9	0,24	2066	0,4647	0,8909	0,4483	10015	0,7169	0,703	0,7007
948	0,95	0,97	0,74	2130	1,0049	0,892	0,7076				

Çizelge 7.2. Uygulamada kullanılan metotların tüm veri setlerini kapsayan ortalama RMSE değerleri

METOT	ORTALAMA RMSE
LR	0,614
ELM	0,743
GBLR	0,490

8. TARTIŞMA ve SONUÇ

Elektrik yük tahmininde kullanılan yöntemler, yükün zamana göre değişim karakteristiğine ve yük tahminine etki eden çevresel faktörlere göre çeşitlilik arz etmektedir. Kimi elektriksel yük tahmini çalışmalarında, analitik yöntemler ile başarılı sonuçlar elde edilebilirken kimi çalışmalar da ise analitik yöntemler yetersiz kalmakta ve yapay zeka yöntemlerine müracaat edilmektedir.

Yük tahmini çalışmalarında, uygulanacak tahmin metodunun seçiminden önce materyal olarak veri setinin iyi analiz edilmesi gerekmektedir. Veri setindeki geçmiş yıllara ait verilerin miktarı ve sıklığı, veri setindeki giriş değişkeni (serbest değişken) olarak alınan parametrelerin sayısı ve bu değişkenlerin tahmini yapılacak değişken (bağımlı değişken) ile olan oransal, matematiksel ilişkisi gibi faktörler uygulayacağımız tahmin metodunun seçiminde oldukça etkili olmaktadır.

Müşteri konumundaki bireysel tüketici abonelerin tükettiği enerji miktarından başlamak üzere bölgesel veya ülke bazındaki toplam enerji tüketim miktarları incelendiğinde tüm aşamalarda yük karakteristiğinin değişkenlik gösterdiği görülmektedir. Bu değişkenlikler, bireysel tüketici abonelerin tüketim davranışlarının, şebeke yapısının, coğrafi faktörlerin ve sosyo-ekonomik koşulların yerden yere farklı olmasından kaynaklanmaktadır. Bu farklılıklar şebekeyi ve şebekeye bağlı meskenlerin yük karakteristiğini kompleks hale dönüştürmekte ve sistem dinamikliğini arttırmaktadır. Bu kompleks ve dinamik yapıdan dolayı yük tahmini uygulamalarında standart veya sabit olarak kullanılacak bir tahmin metodu tasarlamak oldukça zordur. Bundan dolayı yük tahmini çalışmalarında veri seti ve veri setindeki parametrelerin özelliklerine göre en uygun tahmin metodunun seçilmesi gerekmektedir.

Bu çalışmada klasik şebeke yapısına bağlı olmayan, akıllı şebeke yapısına bağlı olan ve güneş panelleri ile kendi enerjisini üreten meskenler için günlük şebeke yük tüketim tahmini yapılmıştır. Meskenler ABD’de 6 farklı eyalette bulunmakta olup, meskenlerden elde edilen veri setleri meskenlerin akıllı sayaçlarının 2015 yılını kapsayan kayıtlarından elde edilmiştir. Klasik şebeke yapısındaki tek yönlü enerji akışından farklı olarak bu meskenlerin bağlı olduğu şebeke yapısında çift yönlü enerji akışı gerçekleşmektedir. Yani tüketici aboneler hem üretici hem de tüketici konumunda olmaktadır. Bu durum klasik şebekeye bağlı meskenlere göre yük karakteristiğini daha da kompleks hale getirmekte ve sistem dinamikliğini arttırmaktadır. Meskenlerden elde edilen akıllı sayaç verilerinde bir saatlik toplam şebeke tüketim verileri, güneş

panellerinden elde edilen enerji miktarı, net tüketim miktarı, her meskenin kendi bünyesinde bulunan farklı elektrikli araçların saatlik tüketim verilerinden oluşmaktadır. Çalışmada kullanılan veri setleri zaman sıralı veri seti sınıfında bulunmaktadır.

Uygulama kullanılan tahmin metotlarının seçimi için yapılan literatür araştırmasında genellikle analitik yöntem olarak lineer regresyon (LR) ve yapay zeka yöntemi olarak YSA yönteminin kullanıldığı görülmüştür. Bu çalışmada ise lineer regresyon (LR), ileri beslemeli YSA'nın bir modeli olan aşırı öğrenme makineleri (ELM) ve geri beslemeli yapay sinir ağları (GBYSA) ve geri beslemeli aşırı öğrenme makinelerinin (RELM) geri beslemeli yapısından esinlenerek yeni bir regresyon modeli olarak tasarlanan geri beslemeli lineer regresyon (GBLR) metodu uygulanmıştır. Yeni bir metot olarak sunulan GBLR metodunun zaman sıralı veri setlerinde ileri doğru işleyen klasik yapıdaki LR metoduna göre daha iyi sonuçlar verdiği bu çalışmada alınan sonuçlar ile teyit edilmiştir.

Uygulamada kullanılan tüm metotların parametre optimizasyonları yapılarak en iyi tahmin performans sonuçlarını vermeleri sağlanmıştır. Uygulanan metotların tahmin hatalarının tespiti için RMSE metodu kullanılmıştır. Tüm meskenlere ait veri setlerindeki RMSE değerleri incelendiğinde en doğruya yakın tahmin sonuçlarının GBLR ile sağlandığı görülmüştür. GBLR'nin LR'den daha iyi sonuçlar vermesi çıkıştan alınan geri besleme elemanlarının modeli optimize ederek daha az hata ile çıkış değerleri üretmesi ve analizde önemli bir nokta olan verinin sırasının da etkili olması olduğu düşünülmektedir. Öte yandan birçok uygulamada başarılı sonuçlar üreten ELM'nin kısa dönem yük tahmini için istenen performansta sonuçlar vermediği görülmüştür. Bunun sebebinin veri setlerinin sadece bir yıllık dönem ile ilgili bilgileri içermesi, ELM'nin eğitim performansını sağlayacak yeterli giriş parametrelerinin bulunmayışı gibi sebeplerden dolayı olduğu düşünülmektedir. Sonuç olarak GBLR metodun zaman sıralı ve dinamik veri setlerinde başarıyla kullanılabildiği görülmüştür.

Öneriler

Klasik şebeke yapısının, git gide artan enerji talebine karşı yetersiz kalması sebebiyle alternatif olarak tasarlanan ve tesisi yaygınlaşan akıllı şebeke yapısı yük tahmini çalışmalarına da yeni bir yön vermiştir. Artık çok fonksiyonlu akıllı sayaçların yaygınlaşması ile şebeke yapısında bulunan herhangi bir noktanın periyodik olarak yük durumu kayıt altına alınarak, spesifik olarak her bir tüketici abonenin bireysel anlamda tüketim verileri ayrıntılı olarak belirlenebilmektedir. Bu geniş ve kompleks bilgi

havuzunun sağladığı veriler ile yapılacak yük tahmin çalışmalarında uygulanacak tahmin metotlarının seçiminde dinamik sistemleri analiz etme yeteneği olan ve zaman sıralı veri setleri için en uygun metot veya metotların seçimi gerekmektedir. Bu çalışmada önerilen GBLR metodu ve diğer metotların tahmin performansı, veri setinin kapsadığı bir yıllık veri miktarının birkaç yıllık verileri kapsayacak şekilde arttırılıp, güncellenmesi ile daha az hata ile tahmin sonuçlarının elde edilebileceği öngörülmektedir. Uygulamada mevsimsel şartlara göre farklı zaman dilimlerine farklı yöntemlerin uygulanması ile de tahmin hata oranlarının düşürülebileceği düşünülmektedir.



KAYNAKLAR

- Akçin, M., Alagöz, B.,B., Keleş C., Karabiber A., Kaygusuz A., 2013, Dağıttık kontrol ile akıllı şebekelerde geniş alan yönetimi ve geleceğe dönük projeksiyonlar, SAÜ Fen Bilimleri Dergisi, 17(3), 457-460.
- Akdemir, B., Güneş, S. and Genç, A., 2009, Artificial neural network training models in prediction of concrete compressive strength using euclidean normalization method, *3rd Int. Conf. on Complex Systems and Applications-ICCSA 2009*, Le Havre-France, 160-165.
- Akman, T., 2018, Yapay zeka modelleri kullanarak Ankara Bölgesinin kısa dönem yük tahmini, Yüksek Lisans Tezi,Gazi Üniversitesi Fen Bilimleri Enstitüsü,Ankara,1-4.
- Alçin, S., 2016, Üretim için yeni bir izlek: sanayi 4.0., *Journal of Life Economics*, 8, 19-30.
- Amjady, N., 2001, Short-term hourly load forecasting using time-series modeling with peak load estimation capability, *IEEE Transactions on Power Systems*, Vol. 16, No.4, pp.798-805.
- Ataseven, B., 2013, Yapay sinir ağları ile öngörü modellenmesi, *Öneri Dergisi*,cilt.10,no.39, 101-115.
- Azadeh, A., Ghadrei, S. F. and Pourvalikhan Nokhandan, B., 2009, Short term load forecasting by ANN, *Hybrid Intelligent Models and Applications*, 39-43.
- Balcı, H., Esener, İ. ve Kurban,M.,2012, Regresyon analizi kullanılarak kısa dönem yük tahmini, *Eleco Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, Bursa, 796-797.
- Baloğlu, U., B., 2017, Akıllı şebekelerde hesapsal yöntem uygulamaları,Doktora Tezi, Fırat Üniveristesi Fen bilimleri Enstitüsü,1-10.
- Bollen, M., Das, R., Djokic, S., Ciufo, P., Meyer, J., Rönnberg, S and Zavoda, F., 2016, 'Power quality concerns in implementing smart distribution-grid applications', *IEEE Transactions on Smart Grid*, vol. PP, no. 99, 1-5.
- Cervone, G., Harding, L., Alessandrini, S., Monache, L., 2017, Short-term photovoltaic power forecasting using Artificial Neural Network and an analog ensemble, *Renewable Energy*,108(2017), 274-280.
- Ceylan, G., 2004, Yapay sinir ağları ile kısa dönem yük tahmini, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, 5-31.
- Chen, D., Irwin, D., 2017, Sundance: Black-box behind the meter solar disaggregation, *e-Energy'17 Proceedings of The Eight International Conference On Future Energy System*, Shatin, Honkong, 45-50.
- Çevik, H.H.,2013, Türkiyenin kısa dönem elektrik yük tahmini, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 1-5.
- Dong, B., Li, Z., Rahman, S.,M. and Vega R., 2016, A hybrid model approach for forecasting future residential electricity consumption, *Energy and Buildings*, 117(2016), 341-347.

- Ertugrul, Ö. F., 2016, Forecasting electricity load by a novel recurrent extreme learning machines approach, *International Journal of Electrical Power&EnergySystems*,78, 429–435.
- Es, H.,A., 2013, Yapay sinir ağları ile Türkiye net enerji talep tahmini, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü,Ankara,1-10.
- Esener, İ.,I., Yüksel T., 2012, Kurban M., *Sıcaklık verisi olmadan kısa dönem yük tahmini için yapay zeka tabanlı melez yapılar*, ELECO 2012 Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu,Bursa, 84-86.
- Esener, İ.,I.,2012, Akıllı sistemler kullanılarak güç sistemlerinde yük tahmini analizi ve uygulaması, Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü,Bilecik, 1-7.
- Gajowniczek, K., Zabkowski, T., 2017, Two-stage electricity demand modelling using machine learning algorithms, *Energies*, 10(10), 1547-1560.
- Guan, C., Luh, P.B., Michel, L.D., Wang, Y., Friedland, P.B., 2013, Very short-term load forecasting: wavelet neural networks with data pre-filtering, *IEEE Trans. Power Syst.*, 28(1), 30-41.
- Gümüş, B., Aydınöz H., İ., 2014, Gerilim bozulmalarının tarımsal sulamada kullanılan besleme türlerine sahip asenkron motorlar üzerindeki etkilerinin araştırılması, *Dicle Üniversitesi Mühendislik Dergisi*, c.5, No.2, 129-140.
- Gürsoy, E., 2000, Yük tahmini yöntemleri ve Çukurova Elektrik A.Ş., Kepez Elektrik T.A.Ş. bölgelerine uygulanması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 6-7.
- Haida, T., Muto, S., 1994, Regression based peak load forecasting using a transformation technique, *IEEE Transactions on Power Systems*, Vol. 9, No.4, pp.1788-1794.
- Hamzaçebi, C., 2011, Yapay sinir ağları, Ekin Basım Yayıncılık, İstanbul, 1-20.
- Hardalaç, F., Kutbay, U., 2014, İlaç ilaç etkileşimlerinin Jordan Elman ağları kullanılarak sınıflandırılması, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi Cilt.29, No.1*, 149-154.
- Hocaoğlu, F. O., Kaysal, K. and Kaysal, A., 2015, Hybrid model for load forecasting (ANN and Regression), *Academik Platform*, 33-39.
- Jain, A. ve Satish, B.,2008, Integrated architecture for short-term load forecasting using support vector machines, *NAPS'08*, 1-8.
- Jones, M., T., 2017, Recurrent neural Networks deep dive, developer.ibm.com/articles/cc-cognitive-recurrent-neural-networks/, [28 Eylül 2019].
- Kabalıcı, Y., Kabalıcı, E., 2017, Akıllı şebekeler için kablosuz enerji izleme sistemi tasarımı ve gerçekleştirilmesi, *Gazi Üniversitesi Fen Bilimleri Dergisi*, 5(2), 137-145.
- Karaca, C., Karacan, H., 2016, Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi, *Selçuk Üniversitesi Mühendislik Bilim ve Teknik. Dergisi*, c.4, 185-188.

- Kaya, Y., Kayci, L., Tekin, R., Ertuğrul, Ö. F., 2014, Evaluation of texture features for automatic detecting butterfly species using extreme learning machine, *Journal of Experimental & Theoretical Artificial Intelligence*, 26(2), 267-281.
- Kong, W., Dong, Z.Y., Jia, Y., Hill, D.J., Xu, Y., Zhang, Y., 2017, Short term residential load forecasting based on LSTM recurrent network, *IEEE Transactions On Power System*, pp (99):1-1, 1-5.
- Okyay, G., 2012, Akıllı Elektrik Şebekelerinde SIP Protokolünün Kullanımı , İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 1-10.
- Özel, C., Topsakal, A., 2014, Veri madenciliği kullanarak beton basınç dayanımının belirlenmesi, *Cumhuriyet Üniversitesi Fen Edebiyat Fakültesi Fen Bilimleri Dergisi* 35 (2014),1-20.
- Palit, A. K. and Popovic, D., 2005, Traditional problem definition: computational intelligence in time series forecasting, Springer, 17-75.
- Rahman, A., Srikumar, V., Smith, A. D., 2018, Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks, *Applied energy*, 212, 372-385.
- Şeker, A., 2016, Yenilenebilir enerji, Türkiye’de yenilenebilir enerji potansiyeli ve yeşil pazarlama ve yenilenebilir enerjinin pazarlanması, *Journal of International Social Research*. Cilt.9 sayı.46. syf 810-820.
- Yurdabak, M., Şekkeli, M.,2014, Elektrik dağıtım şebekelerinde Scada/Dms sistemlerinin incelenmesi ve uygulanması, *KSU Mühendislik Bilimleri Dergisi*, 17(2), 26-31.
- Zehir,M.A.,Bağrıyanık,M., 2013, Akıllı şebekelerde gelişmiş yerel talep yönetimi, *Enerji Verimliliği ve Kalitesi Sempozyumu*, Kocaeli, 14-16.
- Zheng, J., Xu, C., Zhang, Z., Li, X., 2017, Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network, *IEEE 2017 51st Annual Conference on Information Sciences and Systems (CISS)*, pp. 1-6.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : HAZRET TEKİN
Uyruğu : TÜRKİYE CUMHURİYETİ
Doğum Yeri ve Tarihi : BATMAN-15.04.1991
Telefon : 0545 340 53 39
Faks : -
e-mail : hazret.tekin@hotmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Batman Anadolu Lisesi/Batman-Merkez	2008
Üniversite	: Çukurova Üniversitesi Mühendislik Fakültesi/Adana-Merkez	2015
Y. Lisans	: Batman Üniversitesi Fen Bilimleri Enstitüsü	2019

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2017-2018	Mono Elektrik Malzemeleri San.Tic Ltd.Şti	Bakım-Onarım Mühendisi
2019-Devam	Mono Aydınlatma Ürünleri San. Tic. Ltd.Şti	Arge ve Kalite Kontrol Mühendisi

YABANCI DİLLER: İngilizce, Arapça

UZMANLIK ALANI : Makine Öğrenmesi, Akıllı Şebekeler, Led Aydınlatma Sistemleri ve Uygulamaları.

YAYINLAR: Ertuğrul, Ö.,F., Tekin, H., 2019, Geri beslemeli aşırı öğrenme makineleri ile İstanbul borsa indeksinin tahmin edilmesi, International Engineering and Science Symposium, Siirt,559-567.