

# Elektrik Enerjisi Tüketim Tahmini Modellerinin İncelenmesi

Özge Sağlıyan<sup>1</sup>

Elektrik-Elektronik Mühendisliği Bölümü,  
Mühendislik Fakültesi,  
Medeniyet Üniversitesi,  
İstanbul, Türkiye  
<sup>1</sup> osagliyan@gmail.com

*Özetçe* —Elektrik enerjisi endüstrisinde tüketimin modellenmesi önemli bir rol oynamaktadır. Elektrik enerjisi tüketimi modellenerek enerjinin üretimi ve dağıtımını verimli bir şekilde planlamak ve enerji israfını en aza indirilmektedir. Ayrıca, güç sisteminin ekonomik olarak çalıştırılması ve şebeke yatırımları için uygun kararların alınması da elektrik enerjisi tüketiminin doğru bir şekilde modellenmesine dayanır. Bununla birlikte, elektrik enerjisi tüketimini etkileyen birçok faktör bulunmakta ve bu da modelleme çalışmalarını zorlaştırmaktadır. Bu çalışmada akıllı şebekelerde yük sınıflandırması ve yük tahmini konuları incelenmiştir. Bu konular hakkında detaylı bilgilere yer verilmiştir.

*Anahtar Kelimeler* — yük tahmini, optimizasyon algoritması, elektrik enerjisi tüketiminin modellenmesi

## 1. GİRİŞ

Geleneksel elektrik şebekelerinde üreticiler ve tüketiciler arasında gerçek zamanlı bilgi akışı yoktur. Elektrik üretmek için fosil yakıtları ana kaynak olarak kullanmaktadırlar. İşte bu yüzden karbon salınım oranı dünyada her geçen gün daha da artmaktadır. Yapılan bir araştırma sonucunda ABD gibi gelişmiş ülkelerde sera gazı oranı 1990 ve 2012 yılları arasında %5 artış göstermiştir [1-3].

Peki bu karbon emisyonunu önlemek için neler yapmalıyız;

- Elektrik şebekelerindeki elektrik üretim, dağıtım ve iletimdeki kayıpları azaltmalıyız.
- Verimli bileşenler kullanmalıyız.
- Rüzgar ve güneş gibi alternatif yenilenebilir enerji kaynakları kullanılmalıdır.
- Elektrik tüketimini azaltmak için talep tarafı yönetimi etkin halde kullanılmalıdır. Bunun içinde gerekli yük tahminleri yapılmalıdır [1].

Akıllı şebekenin ana hedefi güç sistemini verimli kılmaktır [3,4]. Tepe yükünü azaltarak enerjinin en verimli şekilde planlanması sağlanmalıdır. Tepe yükünü ortalama değerine kadar düşürebilsek eğer böylece maliyetimizi

minimize etmiş oluruz. Ve böylece ilerleyen çalışmalarda yenilenebilir enerji kaynaklarını da sisteme dahil edebiliriz. Böylece akıllı şebekenin sağladığı kolaylıklar ile yenilenebilir enerji kaynaklarının pürüzsüzce birleşimi sağlanır [2,4].

Akıllı şebekenin hedeflerinden birisi de elektrikli araçların yaygınlaştırılmasıdır. Bu teknoloji diğer taşıma sistemlerine göre daha çevrecidir [1,5].

Gerçek zamanlı fiyatlandırma akıllı şebekenin bir diğer hedefidir. Elektrik üretim maliyeti ile elektrik kullanım süresi arasında ilişki vardır. Daha fazla saatler kullanımı için yüksek ücretlendirme mevcutken kullanım süresi azaldıkça bu maliyette düşmektedir [1,2].

Bilgi iletişim teknolojileriyle ilgili kuruluşlar arasında iki yönlü iletişim sağlanır. Yani tüketiciler ve hizmet programı arasında gerçek kontrolü düzenlemek için haberleşme teknikleri kullanılır [1,6]. Akıllı sayaçlar bu hedef için kullanılmaktadır. Böylelikle yük tahmini ve talep tarafı yönetimi için veriler elde edilmiş olunur [1,2].

Akıllı şebekenin enerji ile ilgili iki ana hedefi vardır. Bunlar talep tarafı yönetiminde önemli roller oynamaktadır. Birinci hedefi enerji tüketimini iyileştirmektir [8]. Bir diğer hedefi ise yenilenebilir enerji kaynaklarının sistemle pürüzsüz entegre içerisinde çalışmasıdır [6]. Pürüzsüz entegrasyon yenilenebilir enerji kaynakları için oldukça önemlidir. Çünkü güç kaynağı çevreye zarar verebilecek kömür benzin gibi maddeler ile çalışmaktadır [1,2].

## 2. YÜK TAHMİNİ

Bir önceki veriye dayanarak bir sistemin gelecekteki enerji gereksinimlerini tahmin etmek için kullanılır [1,15]. Hava koşulları ve yenilenebilir enerji kaynaklarının uygunluğu yük tahmini için önemli bir parametrelerdir.

Yük tahmini çoğunlukla belirli bir sistemde gelecekteki yükü öngörebilmek için kullanılır. Ve fayda planlama başlangıç çalışmalarının yapı taşıdır [1].

Üç ana alanda sınıflandırılır;

Kısa Dönem Yük Tahmini: Yükü saatlik bazda bir haftaya kadar tahmin edebilmek için kullanılır. Günlük çalışma ve maliyetin azaltılması oldukça önemli bir kısastır [1]. ARIMA

(Box-Jenkins modeli olarak da bilinir), ARMAX ve ARIMAX (dışa dönük değişkenlerle otoregresif bütünleşik hareketli ortalama) ve FARMAX (Harici giriş değişkenleri ile bulanık otoregresif hareketli ortalama) durağan olmayan işlemleri varsayarak kullanılır. Bu modellerin matematiksel formülleri literatürde mevcuttur. ARMA ve daha önce bahsedilen versiyonlar kısa dönem yük tahmininde yaygın olarak kullanılır [1,13,22]. Kısa dönem yük tahmini yapmak için yapay sinir ağları (ANN) ile tekil değer ayrıştırma (SVD) tekniğini uygulayan önemli sayıda yayın bulunduğunu belirtmek gerekir [10].

Kısa dönem yük tahmini güç sistemlerinin güvenliği için, enerji fiyatlandırılmasının doğruluğu için ve tüm bunların tahmin edilebilir olması açısından oldukça önemlidir. Yük tahminini önceden bilinmeyen pek çok faktör etkiler. Bu faktörler şunlardır; ekonomi, çevre ve elektrik yük şartları. Bu faktörlerin tahmin edilmesi oldukça zordur. Kısa dönem yük tahmininin performansını geliştirmek için yıllardır çalışılıyor [22]. İstatistik ve yapay zekâ metotları olarak bu çalışmalar iki ana başlıkta toplanabilir. 1980'lere kadar hemen hemen tüm yük tahmini modelleri istatistik yöntemlere dayalıydı. Ama 1990 ve sonrasında yapay zekaya dayalı yöntemler kullanılmaya başlandı. Hatta kısa dönem yük tahmini için istatistiksel yöntemler ve yapay zekaya dayalı yöntemler birleştirilerek de kullanıldı. Buna örnek olarak bulanık lineer regresyon modelini verebiliriz [13]. Grey modelde bir diğer kısa dönem yük tahmini için kullanılan modeldir. Sonuçlardan elde edilen veriye göre bu metod tam olarak doğru sonuçlar vermemektedir. Birkaç çalışmada bu metod uygulanmış ve bazı hatalarla karşılaşmıştır. Kısa dönem yük tahmini için bazı hibrit modeller üretilmiştir [23]. Grey model ile dalgacık dönüşümü kullanılarak bir model oluşturulmuştur. Bu metod ortalama ısı, nem, rüzgâr hızı, girişlerini kullanmaktadır. Dalgacık dönüşümü ise verileri ayırabilmek için yüksek frekans kullanır. Bu hibrit model günümüzde yük tahmini için New York ve İran da kullanılmaktadır [23]. Ayrıca kısa dönem yük tahmini çalışmalarında karınca aslanı algoritması kullanarak kısa dönem yük tahmininde düşük hata oranları elde edilmiştir [29].

Kısa dönem yük tahmini için dalgacık dönüşümü ve grey modelleme tabanlı parçacık sürü optimizasyonu (PSO) algoritmasının hibrit modellemesi uygulanmıştır. Bu uygulama 5 aşamada gerçekleştirilmiştir;

- i. Giriş data verilerinin hazırlaması: Elektrik yük verilerinin, hava koşullarının önceki günlere bağlı olarak tespit edilmesi gerçekleştirilir.
- ii. Dalgacık dönüşümü kullanılarak veriler yüksek frekansta filtrelenir.
- iii. Parçacık sürü optimizasyonu algoritması ile veriler eğitilir.
- iv. Elektrik yükü kısa dönem için tahmin edilir.
- v. Önceki evreler değerlendirilir.

Giriş değişkeninin seçimi, tahminin doğruluğunu etkilediğinden, her tahmin yönteminin en önemli

kısımlarından biridir. Önceki günlerin yük verileri, yük tahmini için oldukça bilgilendirici açıklayıcı bir değişkendir. Bu nedenle, grey model için bir girdi olarak kabul edilir. Yük tahmini için diğer oldukça önemli değişkenler sıcaklık, nem ve ülkenin seçilen şehirlerinin rüzgâr hızıdır [30,29].

Orta Dönem Yük Tahmini: Haftalık, aylık ve operasyonel olarak yıllık bazda yük tahminlerinde kullanılır [1]. Orta dönem yük tahminini etkileyen faktörler; yeni yük ekleme, mevsimsel varyasyonlar, büyük tesislerin yük talepleri ve büyük tüketicilerin bakım gereksinimleridir. Dahası bu tür tahminlerde güneşli tepe yük miktarı ve haftalık tepe yük miktarları da kullanılır. Bu edinilen bilgiler ışığında bir tesisin bir süre boyunca bakıma muhtaç olup olmadığına karar verilebilir [14]. Büyük testler ve devreye alma planları yapılır. Tüm bunlara bağlı olarak kesinti süreleri planlanır. Bunun için kullanılan analiz metotları kısa dönem yük tahminiyle de benzerlik taşır. Ama orta dönem yük tahmininin güç sistemi üzerindeki duyarlılığı kısa dönem yük tahmininden daha düşüktür. Çoğu tahmin modeli istatistiksel metotlar ve yapay zekaya dayalı metotlar kullanılarak yapılmaktadır. Hatta orta dönem için bu iki metotların birbiriyle birleştirilerek hibrit modellerde oluşturulmuştur. Son dönemlerde ise ekonometrik yaklaşım orta ve uzun dönem yük tahmini için kullanılmaktadır. Ayrıca, tahmin yöntemleri de iki temel türe ayrılmıştır: nitel ve nicel yöntemler. Niteliksel yöntemler şunlardır; öznel eğri uydurma, Delphi yöntemi ve teknolojik karşılaştırmalardır. Böylece gelecekteki yük öznellik olarak tahmin edilir. Bu, uzman görüşlerini kullanılarak yapılır. Bu yöntemler, tarihsel veriler mevcut olmadığında veya yetersiz olduğunda uygulanır. Diğer taraftan, nicel yöntemler matematiksel formülasyona dayanmaktadır ve bunlara şunlar dahildir: regresyon analizi, ayrıştırma metotları, üstel düzleştirme ve Box-Jenkins metodolojisi. Dragomir ve arkadaşları son birkaç yılda, güç sisteminin güvenli ve güvenilir çalışması için birincil bilgi kaynağı olan orta dönem yük tahmini ile ilgili birkaç model üzerinde durmuştur. Orta dönem yük tahmini, yapay sinir ağları (ANN) kullanılarak gerçekleştirmiş ve sonuçta %5.42'lik ortalama mutlak hata oluşmuştur [14,]. Kısa örnekleme aralığına dayanan bir durum modelini kullanarak uzun menzilli tahminler üretme problemi, haftalık verilere dayanan tahmin modelinin daha uzun zamanlı ölçekli bilgilerin bir araya getirilmesiyle geliştirilebileceğini gösterdi. Yaklaşık %4,5'lik ortalama hata ile öngörme doğruluk oranını %10,20 artırmak için hizmet eden 3 yıllık bir zaman aralığı kullanılmıştır [12]. Al hamadi ve arkadaşları şu şekilde bir çalışma yapmışlardır; günlük ve haftalık yük davranışlarını lineer regresyon modelini kullanarak 1 yıl önceki yükleri tahmin etmeye çalışmışlardır. Elde ettikleri sonuç hata oranının %3,8'den daha az olduğunu göstermişlerdir [14]. Magnano ve Boland ; Fourier serisi ve ARMA prosesini kullanarak yarım saatlik elektrik taleplerinin sentetik dizilerini üretmek için bir model geliştirdiler. Verileri filtrelemek için ARMA modeli kullanıldı. Ortaya çıkan diziler, meydana gelebilecek olası elektrik yüklenmelerini temsil etmiştir. Market simülasyon yazılımında girdi verileri olarak kullanılmak ve olasılık tahminlerini hesaplamak

için çıktıların olasılık dağılımlarını oluşturmak için geliştirildi [11].

Uzun Dönem Yük Tahmini: Önümüzdeki elli yıl için yükü tahmin etmek amacıyla kullanılır [1]. Yeni nesil tesislerin geliştirilmesi, üretim birimlerinin satın alınması, iletim ve dağıtım sistemlerinin geliştirilmesi için uzun vadeli yük tahmini oldukça büyük önem taşır. Uzun vadeli yük tahmininin doğruluğu gelecek nesil ve dağıtım planlamasının geliştirilmesi üzerinde önemli etkiye sahiptir. Yük talebinin tahmininin yapılması, inşaatın yatırımlarının ne şekilde olacağını belirler. Uzun dönem yük tahmini için, yük talebini doğru olarak tahmin etmek zordur. Bu gerçek, tahmin sürecinin belirsiz doğasından kaynaklanıyor. Yük tahminini karakterize eden birçok faktör vardır. Tüm bu faktörler doğru bir tahmin yapmayı oldukça zorlaştırmaktadırlar [14]. Uzun vadeli elektrik yük talebi karmaşık bir yapıya sahiptir. Doğrusal olmayan davranışlara sahiptir. Günlük ve sezonsal hava değişikliği, ulusal ekonomik büyüme ve sosyal alışkanlıklar gibi bir takım karmaşık faktörlere bağlıdır. Tüm bu nedenler doğru tahmin sonuçları elde etmemizi zorlaştırır. Al hamadi ve S.A.Soliman yükün doğrusal olmayan davranışını yakalamak için sorunu birinci mertebeden doğrusal olmayan regresyon modellerine dönüştürmüştür [14,16,17].

Talep tahmini bir güç sisteminin planlanması ve çalıştırılabilmesi için önemli bir parametredir. Şebeke sağlayıcısı için büyük bir tasarruf potansiyeline sahiptir [1,24]. Tahmin modelindeki hata işletme maliyetindeki artışa neden olur. Dolayısıyla doğru bir matematiksel modelin yük ile zaman hava koşulları ile ekonomik faktörler gibi değişkenler arasındaki ilişkiyi doğru kurması gerekir [1,2].

Literatürde çok sayıda tahmin modeli önerilmektedir. Aşağıda en sık kullanılanlar bulunmaktadır:

- Çoklu doğrusal regresyon
- Stokastik zaman serileri
- Genel üstel düzeltme
- Durum uzayı ve kalman filtresi
- Bilgiye dayalı sistem yaklaşımı [25,1]

Bu yük tahmin modellerini iki kategoride sınıflandırabiliriz.

- ✓ İstatiksel Modelleme
- ✓ Yapay Zekâ Tabanlı Modelleme [1,29]
- 2.1.İstatiksel Modelleme

Matematiksel denklemler kullanılarak yapılan modellemedir. Bu modellemede şu yöntemler kullanılır [1,4]:

- Oto Regresif (AR) Modeli
- Hareketli Ortalama (MA) Modeli
- Otoregresif Hareketli Ortalama (ARMA) Modeli
- Otoregresif Bütünleşik Hareketli Ortalama

## (ARIMA)Modeli

Bazı matematiksel teknikler kullanılarak yük tahminin de bulunulabiliyoruz:

- Çoklu Regresyon
- Üstel Yumuşatma
- İnteraktif Ağırlıklı Küçük Kareler
- Adaptif Yük Tahmini [12]

### 2.1.1.Çoklu Regresyon

Bu modelde ağırlıklı en küçük kareler tahmin tekniği kullanılır. Hava durumu, gün tipi ve tüketici sınıfı yük tahminin ilişkilendirilmesinde kullanılır. Matematiksel olarak ifadesi aşağıda verilmiştir [1]:

$$y_t = v_t a_t + e_t \quad (1)$$

$y_t$ : yük miktarı

$v_t$ : çeşitli parametre (hava koşulları gibi)

$a_t$ : sabit

$e_t$ : hata zamanı

Modern zaman araştırması olan Moghram ve Rahman bu modeli onların ihtiyaçlarına göre diğer modellerle karşılaştırmıştır. Bu iki araştırmacı mevsimsel değişimleri regresyon modeli kullanarak değerlendirmişlerdir.

Hyde ve Hodnett İrlanda'da yük talebini tahmin etmek için regresyon tabanlı hava yükü modelini geliştirmişlerdir. Daha sonra bir gün içerisindeki yük tahminini bulabilmek için uyarlanabilir regresyon modelini oluşturmuşlardır.

### 2.1.2.Üstel Düzleştirme Modeli

Klasik bir tahmin modelidir. Gelecekteki yükü tahmin etmek için önceki yükü kullanır. Matematiksel ifadesi aşağıda verilmiştir.

$$Y(t) = \beta(t)^t + e(t) \quad (2)$$

$Y(t)$ : o andaki yük miktarı

$T$  : zaman

$Y(t)$ : Katsayı vektörü

$e(t)$ : beyaz halka

$T$  : transpose operatördür.

Bu model güç spektrumu ve uyarlanabilir otoregresif modelleme ile hibrit model haline getirilebilir. Daha önce böyle bir hibrit modelleme El – Kab tarafından yapılmıştır.

Bu model diğer geleneksel modellere göre kıyaslandığında yaklaşık hata oranı %12' dir [1].

### 2.1.3.Yinelemeli Tekrardan Ağırlıklandırılmış En Küçük Kareler modeli

En küçük kareler algoritması kullanılır. Modelde kullanılan bir defada bir değişkeni kontrol eder ve ayrıca en iyi başlangıç noktasını tanımlar. Lineer denklemi şu şekildedir [1]:

$$Y=X\beta+e \quad (3)$$

Y:  $n \times 1$  gözlem vektörü

X:  $n \times p$  bilinen yardımcı etkinlik matrisi (önceki yük verileri),

$\beta$ :  $p \times 1$  bilinmeyen parametrenin vektörü ve

e:  $n \times 1$  rastgele hata vektörü.

#### 2.1.4.Otoregresif (AR) model

Stokastik bir zaman serisi modelidir. Bu modelde yük önceki yük verilerinin doğrusal bileşimi olarak kabul edilir. Matematiksel olarak Liu tarafından temsil edilir [1,22].

$$L_k = \sum_{i=1}^m a_i L_{(k-1)} + W_k \quad (4)$$

$L_k$ : Tahmin edilen yük miktarı (k zamanda)

$W_k$ : Rastgele yük

$a_i$ : Bilinmeyen etki katsayısı

#### 2.1.5.Hareketli ortalama modeli (MA)

Hareketli ortalama modelinde zaman serilerinin şimdiki değeri Y(t) ile ifade edilir. Bu terim tahmin edilecek serinin lineer kombinasyondur. Ve şu şekilde ifade edilir [1,23].

$$Y(t)=\phi(B)a(t) \quad (5)$$

#### 2.1.6.Otoregresif Hareketli Ortalama Metodu (ARMA)

Bu model, önceki periyot serisi olan (y (t-1), y (t-2) ...) ve beyaz parazitin mevcut ve önceki değerleri (a (t), ...) açısından doğrusal olarak ifade edilen zaman serilerinin Y a (t-1), (a (t-2) ...) bir alt serisidir. Matematiksel modeli ise aşağıdaki gibi temsil edilmektedir [1,28]:

$$Y(t) = a(t) + \phi_1 a(t-1) + \dots + \phi_q a(t-q) \quad (6)$$

Örneğin yeni bir zaman-sıcaklık tabanlı tahmin modeli sunulmuştur. Bu modelde, aylık tepe yükü zaman serisi, daha sonra ARMA modeli ile belirlenen deterministik ve stokastik bileşene ayrılmıştır. Uyarlamalı ARMA modelinin parametrelerini güncellemek için Ağırlıklı Regresif En Küçük Kareler (WRLS) algoritması sunulmuştur. LF için uyarlanabilir ARMA modeli, model parametrelerini güncellemek için mevcut tahmin hatasını kullanılmıştır. Minimum ortalama kareler hatası, hata öğrenme katsayısını güncellemek için kullanılır ve uyarlamalı şema geleneksel ARMA modelinden daha iyi performans gösterir [1,25].

#### 2.1.7.Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA)

Daha önce tanımlanan zaman serileri, yani AR, MA ve ARMA sabit işlemlerdir. İşlem durağan değilse durağan sürece dönüştürülmelidir. Bu görevi gerçekleştirmek için, diferansiyel işleme, denklem için  $\nabla$  işleci getirilerek gerçekleştirilir. Matematiksel olarak ARIMA (p, d ve q) modeli şu şekilde yazılır:

$$\theta(B)\nabla^d y(t)=(B)a(t) \quad (7)$$

Bu model sistemin yükündeki büyümeyi tahmin etmek için kullanılır. Hava koşullarına duyarlı yükü tahmin etmek için hava unsuru ve ARIMA modeli kullanılabilir.

Mevsimsel ARIMA modeli yükteki mevsimsel değişimi tahmin edebilmek için geçmiş verileri kullanmaktadır [1,23].

#### 2.2. Yapay Zekaya Dayalı Modelleme

Bazı yapay zekaya dayalı tahmin modelleri şunlardır:

- Yapay sinir ağları
- Bulanık mantık
- Uzman sistemler

##### 2.2.1.Yapay Sinir Ağı

İnsan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler üretebilme yeni bilgiler keşfedebilme bilgiler arası ilişki kurma gibi yeteneklerin herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. Şu özelliklere sahiptirler [1,26]:

- ✓ Öğrenme
- ✓ İlişkilendirme
- ✓ Sınıflandırma
- ✓ Genelleme
- ✓ Özellik belirleme
- ✓ Optimizasyon

Kıscacası ağ yoluyla bilgi besleyen girdilerin değerlerini hesaplayabilen nöronların birbirine bağlanması yoluyla oluşturulur [29]. Peki yük tahmininde nasıl kullanılır; yük tahmininde kullanılmasını iki grupta inceleyelim. Birinci grup sadece gelecek saat için tahmini düşünüyor. İkinci grup ise radyal temel fonksiyonu ağı ve kendi kendini düzenleyen haritalar ve tekrarlayan sinir ağı kullanarak gelecek yük tahminini yapıyor [1,26,5].

##### 2.2.2.Uzman Sistemler

Yapay zekâ alanındaki ilerlemenin bir sonucu olarak ortaya çıkan yeni bir alandır. Uzman sistemler uzman mühendisler tarafından kurulan bilgisayar programlarıdır.

Özellikle sezgisel optimizasyon algoritmaları yük tahmininde oldukça sık kullanılmaktadır [29]. Birçok hibrit model de kullanılarak yük tahmini yapılabilmektedir. Örneğin bulanık mantık ile uzman sistemler birleştirilerek hibrit bir modeli yük tahmini için kullanabiliriz. Kore elektrik güç şirketi tarafından böyle bir hibrit uygulama yapılmıştır. Koreli mühendisler yapay sinir ağı ile uzman sistemleri birleştirerek yük tahminin de kullanmışlardır [1,2].

##### 2.2.3.Bulanık Mantık

Bulanık mantık bilinmeyen herhangi bir dinamik sistemi yani yükleri tanımlayabilen ve tahmin edebilen merkezi bir sistemidir. Lui bulanık mantığın büyük verilerden benzerlik çekme konusunda bir araştırma yaptı ve matematiksel olarak [1,27]:

$$V_k = \frac{L_k - L_{k-1}}{T}, \quad A_k = \frac{V_k - V_{k-1}}{T} \quad (8)$$

Burada ( $L_{-i} - L_0$ ) benzer giriş verilerini ifade eder.

$V_k$ : Birinci farklılığı ifade eder.

$A_k$ : İkinci farklılığı ifade eder.

Bulanık sistem tahmini gerçekleştirebilmek için iki aşamada çalışır. Bu aşamalar eğitim ve çevrimiçi tahmin şeklindedir. Eğitim aşamasında eski data verileri kullanılır. Mantık tabanlı kurallar kullanılarak giriş değerlerine bağlı çıkış değerleri üretilir. Eğitim aşamasından sonra yükü tahmin etmek denetleyicilere bağlıdır [27].

Bulanık sistemde yük tahmini yapmak için çeşitli bulanık tahmin modelleri kullanılmaktadır. Tayvan güç sistemi yük tahmini için bulanık mantık ile oluşturulmuş sistem modellemesini kullanmaktadır [17]. Bulanık mantık, doğrusal programlama tahmin ve girdi değerlerindeki belirsizliği ortadan kaldırmak için kullanılmaktadır. Model hatasını en aza indirmek için bulanık mantık modellemesi kullanılır. Kısa vadede yük tahmini içinde bulanık mantık modellemesi optimizasyon için gereklidir. Bulanık mantık modellemesini içeren çok karışık hibrit modeller yapılmıştır. Bu modellerden birinde bulanık mantık, yapay sinir ağı ve uzman sistem kullanılmıştır. Bu hibrit sistem üzerinde Srinivasan çalışmıştır. Bu hibrit modelleme ihracat sistemlerinde de kullanılmaktadır [1].

### 3. Akıllı Şebekelerde Yük Sınıflandırılması

Ev tipi, ticari, tarımsal ve endüstriyel kullanıcılar gibi farklı türlerin elektrik tüketimi de oldukça farklıdır. İşte bu yüzden yük sınıflandırılmasının yapılmasına ihtiyaç duyulmaktadır. Aynı tür kullanıcıların bile elektrik tüketimleri birbirinden oldukça farklıdır. Yük veri sınıflandırılması yalnızca üretimle yapılmaz tüketimi de kategorize edip veri tahminini bu şekilde yapmak gerekir [2].

Kümeleme algoritmaları kullanarak yük sınıflandırılması yapılır. Kümeleme metodu nedir kısaca bundan bahsedelim. Kümeleme metodu benzer özelliklerdeki verileri alt kümelerle ayırma işlemi olarak bilinir. Uygulamada çok sayıda kümeleme yöntemi kullanılır. Bu yöntemler değişkenler arası benzerliklerden ya da farklılardan yararlanarak bir kümeyi alt kümelerle ayırmak için kullanılır. Kümeleme metodu çok değişkenli çözümleme metodu olarak karşımıza çıkar [2,28].

Yük sınıflandırılması yük tahminini modellemenin önemli bir kısmını oluşturur. Yükün sınıflandırılması yükün modellenmesinin doğruluğunu etkileyebilir. Bu yüzden yükü modellemeden önce doğru bir şekilde sınıflandırma yapmak gerekir.

Yük sınıflandırılması birçok adımdan oluşan bir süreçtir. Yük sınıflandırılmasının hazırlanması, uygulanması ve kümeleme metotlarının kullanılması gibi süreçlerden geçmektedir. Akıllı şebeke ortamlarında çok fazla yük verisi mevcuttur. Bu verilerin her geçen gün artması öngörülmektedir ve sonuç olarak yapı daha da karmaşık bir hal alacaktır. İlerleyen süreçte akıllı şebekelerde daha fazla veri bulunacaktır. Yani karmaşıklık oranı artacaktır. Dolayısıyla akıllı şebekelerde veri madenciliği önemli bilgileri ortaya çıkarmak için vazgeçilmez bir araştırma biçimi olacaktır.

### Yük Sınıflandırılmasının İşlem Modeli

Akıllı şebekelerdeki elektrik yükü verileri büyüktür. Yük

verilerinin yapısı karmaşık, heterojen ve skalası oldukça büyüktür. Biçimi ise gerçek zamanlı ve dinamiktir. Bu karakteristik özellikler akıllı şebeke için yük sınıflandırılmasını zorlaştırmıştır. Bu nedenle kesin bir yük sınıflandırılması modeli gereklidir. Yük sınıflandırma işlemi 5 aşamada gerçekleştirilir.

Şimdi bu 5 aşamayı tek tek inceleyelim;

1. aşamada yük verileri belirlenir. Zaman boyutlarına, bölgelere ve türlere göre yük koşulları tespit edilir. Sonra örnekleme metodu kullanılarak yük verilerinden numune yükler seçilir. Daha sonra seçilen girdi örnek yük verileri normalleştirilir. Ve aykırı değerler gürültü verilerinde tanımlanarak düzeltilir [2].

2. 'inci aşamada kümelemenin hazırlanması aşamasında sınıflandırma özelliklerinin belirlenmesi uygun kümeleme algoritmalarının seçilmesi ve ilgili parametrelerin belirlenmesi yer alır. Üç çeşit yük karakteristiği vardır. Bunlar; tanımlayıcı, karşılaştırmalı ve kavilidir. Yük sınıflandırması için kullanılan bilinen kümeleme algoritmaları; hiyerarşik kümeleme algoritması, bulanık kümeleme ve k-mean algoritmasıdır. Örneğin bulanık kümeleme algoritmasındaki parametreler başlangıç küme merkezleri, küme sayısı ve bulanıklık parametreleridir [2,3].

3. adımda önceden işlenmiş yük verilerine seçilen sınıflandırma özelliklerine ve kümeleme algoritmalarına buna karşılık gelen parametrelerine göre kümeleme işleminin yapılmasıdır [5].

4. adım olarak yük veri kümelemesinden sonra sınıflandırma sonuçlarını anlamalıyız ve değerlendirme yapmalıyız. Sınıflandırma sonuçları genel olarak belli sayıda yük kümesi grubu ve bunlara karşılık gelen temsili yük kipleri olarak sunulmaktadır. Her bir yük grubu için bilgi ve özellikleri tanımlanmalı ve anlaşılmalıdır. Buna ek olarak genellikle kümeleme sonuçlarının kalitesini doğrulamak için küme geçerlilik indeksleri kullanılır [2].

5. aşamada yük sınıflandırma sürecinin asıl amacı olan güç sistemlerine katılımcıların karar vermesidir. Yük sınıflandırma sürecinde keşfedilen bilgiler ve bu bilgilere dayanarak talep tarafı yönetimi uygulanabilir. Ayrıca uygun tarife ayarı yapılabilir. Kötü verinin bulunması ve düzeltme pratiği de yük sınıflandırması ile daha kolay bir şekilde sonuçlandırılır [9].

Biz bu bölümde kümeleme metotlarından bölme yöntemlerini inceleyeceğiz. Bölme yöntemleri temelde 4 türde gerçekleşmektedir.

Bunlar;

K – means algoritmaları

Bulanık mantık kümeleme

Hiyerarşik kümeleme

Kendi kendine organize haritalamasıdır.

Tüm sayılan metotlar yük sınıflandırması için kullanılır. Yük sınıflandırması için kümeleme metodunu kullanım

amacımız diğerlerine göre daha iyi sonuçlar elde etmemizdir. Şimdi bu 4 kümeleme metodunu kısaca açıklayalım [2,28].

### 3.1.1. K – means algoritmaları

Yük sınıflandırması için kullanılan klasik bir yöntemdir. Bu yöntemin amacı başlangıçtaki belirli sayıdaki küme için toplam hatayı minimize etmektir. Matematiksel olarak ifadesi aşağıda verilmektedir [2,29].

$$E = \sum_{i=1}^k \sum_{j=1}^n \{d(x_j, v_i)\} \quad (9)$$

K means algoritmasının kullanımı basit, verimli ve ölçeklenebilirdir. Dolayısıyla yük sınıflandırılmasında sıkça kullanılan kümeleme yöntemidir. Bunların haricinde bazı eksiklikleri vardır bunları şu şekilde sıralayalım;

Başlangıç küme merkezlerinin seçimi algoritmayı önemli derecede etkiler.

Uygun sayıda kümenin belirlenebilmesi zordur.

Gürültüye ve dışsal verilere duyarlıdır.

Yalnızca özel veri gruplarında kullanılabilir.

Tüm bu sayılan eksiklikler yüzünden k means algoritmaları yük sınıflandırılmasında kullanılırken optimize edilir veya değiştirilir [2,28].

### 3.1.2. Bulanık Kümeleme Metodu

İyi bilinen bir kümeleme metodudur. Veri kümesindeki herhangi bir veri yalnızca kümelemedeki bir gruba aittir. Bulanık kümelemede her veri belirli bir kümeye ait tir ve her grup kümede de üyeliği vardır [2,30].

Bu algoritma başlangıç küme merkezlerini tahmin ederek takip eden küme sayısı belirlenmekle başlar. Ardından her veri nesnesine her bir kümeye üyelik derecesine atanır. Her data hücre si her küme için derecelendirilir [30].

Bulanık kümeleme algoritmasının matematiksel modellenmesi şu şekildedir;

$$j_m(U, V) = \sum_{i=1}^k \sum_{j=1}^n \mu_{ij} d(x_j, v_i) \quad (10)$$

$$\mu_{ij} = 1 / (\sum_{t=1}^k \{d(x_j, v_t) / d(x_j, v_k)\})^{1/(m-1)} \quad (11)$$

### 3.1.3. Hiyerarşik Kümeleme Metodu

Hiyerarşik kümeleme metodunun ana fikri istenilen sınıflandırma sonucu oluşana kadar bir veri setindeki değerleri aşağıdan yukarıya doğru ya da yukarıdan aşağıya doğru birleştirmektir [31]. Veri nesnesindeki her nesne bir grup olarak kabul edilir. Ve daha sonra tüm nesnel tek bir kümede toplanmaya çalışılır. Veya belirli bir kriterde iki grubun birleşmesiyle daha büyük kümeler elde edilebilir. Hiyerarşik kümeleme metodlarının basamakları daha kolaydır. Bu yüzden kümelemede yaygın olarak kullanılır [2,28].

### 3.1.4. Kendi Kendini Düzenleyen Haritalar

Kohonen sinir ağı yöntemi olarak ta bilinir. Bir kontrolsüz sinir ağı yöntemidir. Girdi katmanı ve rekabetçi katmandan oluşur. N tane giriş katmanında, N tane giriş nöronu vardır. M tane çıkış katmanındaysa M tane çıkış nöronu mevcuttur. Giriş ve çıkış katmanları birbirine

bağlıdır. Ve kazanan nöron çıktı katmanında N girdi nöronuna en yakın olanıdır [2].

Değerlendirme işlemi kendi kendine düzenleme haritalarında gerekli değildir. En önemli özelliği kendinden istikrarlı olmasıdır. Güçlü bir gürültü önleme kabiliyetine sahiptir. Tüm bu özellikler bu metodu yük sınıflandırılması kümeleme işleminde yaygın kullanılabilir hale getirmiştir. Yalnız bazı dezavantajları da mevcuttur bunları şu şekilde sıralayalım; öğrenme etkinliği giriş nesnelere sırasına bağlı olması, ağ bağlantısının ağırlığı, öğrenme verimliliğinin ayarlanması, komşu fonksiyonunun seçimi gibi faktörler kendi kendini düzenleme haritasının verimini etkileyebilir [23].

Kümeleme denetimsiz bir süreç olduğu için veri kümelerindeki yük veri nesnelere etiketsizdir. Ve veri kümesiyle ilgili hiçbir yapısal bilgi yoktur. Bu nedenle kümeleme sonuçlarının kalitesinin ölçülmesi ve optimum küme sayısının belirlenmesi zordur. Küme sayısını belirlemek için kullanılan en yaygın metot kümeleme algoritmalarını farklı zamanlarda birkaç kez uygulamaktır. Önceden tanımlanmış kriter işlevini gözlemleyerek en iyi sonucu veren küme sayısı seçilir. Önceden tanımlanan kriter fonksiyonuna küme geçerlilik indeksi denir [2].

Kümeleme sayısı ve kümeleme algoritmalarının diğer parametreleri sabitlendiğinde küme geçerlilik indeksi yük sınıflandırılmasının sonuçlarını değerlendirmek ve doğrulamak için kullanılır. Günümüzde çok sayıda küme geçerlilik indeksi önerilmiş ve gözden geçirilmiştir. Küme geçerlilik indeksiyle yapılan çalışmalar sonucunda diğerlerinden daha iyi performans gösteren tek bir küme geçerlilik indeksinin olmadığını ortaya çıkarmıştır [28].

## 4. SONUÇLAR

Elektrik enerjisi tüketim tahmini çoğunlukla belirli bir sistemde gelecekteki yükü öngörebilmek için kullanılır. Ve fayda planlama başlangıç çalışmalarının yapı taşıdır. Elektrik enerjisi tüketim tahmini (yük tahmini) 3 kategoride incelenmektedir. Bunlar kısa dönem yük tahmini, orta dönem yük tahmini ve uzun dönem yük tahminidir. Bu şekilde 3 kategoride inceleme yapmak yük tahminini gerçekleştirmek için oldukça önemlidir. En sık kullanılan tahmin modelleri ise çoklu doğrusal regresyon, stokastik zaman serileri, genel üstel düzleştirme, durum uzayı ve kalman fitresi, yapay zeka sistemleri ve bilgiye dayalı sistem yaklaşımıdır.

Akıllı şebekelerdeki elektrik yükü verileri büyüktür. Yük verilerinin yapısı karmaşık, heterojen ve skalası oldukça büyüktür. Biçimi ise gerçek zamanlı ve dinamiktir. Bu karakteristik özellikler akıllı şebeke için yük sınıflandırılmasını zorlaştırmıştır. Bu nedenle kesin bir yük sınıflandırılması modeli gereklidir. Kümeleme metodları kullanarak yükün sınıflandırılması gerçekleştirilir. Bu metodlardan en çok kullanılanları ise K means algoritmaları, bulanık mantık kümeleme, hiyerarşik kümeleme ve kendi kendini düzenleyen haritalardır.

Gelecek çalışmalarda bu bahsedilen metotların performansları karşılaştırılacak, literatürden hibrit modeller araştırılacak ve hibrit modeller üzerinde çalışmalar yapılacaktır.

## REFERANSLAR

1. Khan R., Mahmood A., Safdar A., Khan N., "Load forecasting, dynamic pricing and DSM in smart grid: A review" , *Renewable and Sustainable Energy Reviews* , Volume 54, February 2016, Pages 1311–1322
2. Zhou K., Yang S., Shen C., "A review of electric load classification in smart grid environment" , *Renewable and Sustainable Energy Reviews* , Volume 24, August 2013, Pages 103–110
3. Wu YN, Chen J, Liu LR. "Construction of China's smart grid information system analysis", *Renewable and Sustainable Energy Reviews* 2011;15(9):4236–41.
4. Develi I., " Haberleşme sistemler ve kablosuz gezgin haberleşme" , Kayseri 2015
5. Mahmood A, Javaid N, Zafar A, Riaz RA, Ahmed S, Razzaq S. "Pakistan's overall energy potential assessment, comparison of TAPI, IPI and LNG gas projects" ,*Renew Sustain Energy Rev* 2014(31):182–93.
6. Hajian M, Zareipour H, Rosehart W. "Environmental benefits of plug-in hybrid electric vehicles: case of Alberta", In: *Power & Energy Society General Meeting, 2009. PES'09. Calgary, AB: IEEE; 2009.*
7. Usman A, Shami S h. "Evolution of Communication Technologies for Smart Grid Application", Elsevier; 2012. p. 191–9.
8. Li G, Hwang Y, Radermacher R, Chun H-H. "Review of cold storage materials for subzero applications" ,*Energy* 2013;51:1–17
9. Beaudin M, Hamidreza Z. "Home energy management systems: a review of modelling and complexity", *Renew Sustain Energy Rev* 2015;45:318–35.
10. Cappers P, Goldman C, Kathan D. "Demand response in U.S electricity market: empirical evidence", Elsevier; 2009. p. 1526–35.
11. Janacek G, Swift L. "Time series: forecasting, simulation, applications" West Sussex: Ellis Horwood Limited; 1993.
12. Magnano L, Boland JW. "Generation of synthetic sequences of electricity demand: application in South Australia" , *Energy* 2007;32:2230e43.
13. Amjady N. "Short-term hourly load forecasting using time series modeling with peak load estimation capability", *Power Syst IEEE Trans Nov.* 2001;16(4):798e805.
14. Soliman S.A., Al Hamadi H.M., "Long-term/mid-term electric load forecasting based on short-term correlation and annual growth" Power System Research Group, Department of Electrical Engineering, College of Engineering, University of Qatar, P.O. Box 2713, Doha, Qatar Received 3 February 2004; accepted 26 October 2004
15. Chow J, Wu F, Momoh J. "Applied mathematics for restructured electric power systems" , New York: Springer; 2005.
16. V.M. Vlahovic, I.M. Vujosevic, "Long-term forecasting a critical review of direct-trend extrapolation methods", *Electr. Power Energy Syst.* 9 (1) (1987) 2–8.
17. D. Srinivasan, M.A. Lee, Survey of hybrid fuzzy neural approach to electric load forecasting, *IEEE Trans. Power Syst.* (1995) 4004–4008
18. Gillings W, Clark. The concept of demand-side management for electric utilities. *Proc IEEE* 1985:1468–70
19. Communication requirements of smart grid technologies. Department of Energy (DOE); 2010.
20. Nazar N, Abdullah MP, Hassan MY, Hussin. Time-based electricity pricing for Demand Response implementation in monopolized electricity market. In: *2012 IEEE Student Conference on Research and Development (SCORED). Pulau Pinang; 2012*
21. Soliman SA-h, Al-Kandri AM. Electrical load forecasting modeling and model construction. Burlington, USA; Kidlington, UK: Elsevier; 2010
22. Moghram SR Ibrahim. Analysis and evaluation of five short-term load forecasting techniques. *IEEE Trans Power Syst* 1989;4:1484–91
23. Ercan Öztemel, "Yapay sinir ağlar" Üniversite Yayıncılığı, Ekim 2016.
24. Danladi A., Yohanna M., Puwu Markus Ijasini , Garkida M., "Application of fuzzy – Neuro to model weather parameter variability impacts on electrical load based on long-term forecasting" *Alexandria Engineering Journal* Available online 11 January 2017
25. Yalçın Özkan, " Veri madenciliği yöntemleri" Üniversite Yayıncılığı, Ekim 2016. 15-20
26. Macqueen J. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability; 1967.* p. 281–97.
27. Ju P, Jin Y, Wu F, et al. Studies on classification and synthesis of composite dynamic loads. *Automation of Electric Power Systems* 2004;28(1):64–8.
28. Johnson JC. Hierarchical clustering schemes. *Psychometrika* 1967;32 (3):241–54
29. M. Yesilbudak, O. Sagliyan and A. Colak, "Monthly Electrical Energy Consumption Modeling Using Ant Lion Optimizer," 2019 8th International Conference on Renewable Energy Research and Applications (ICRERA), Brasov, Romania, 2019, pp. 977-981, <https://doi.org/10.1109/ICRERA47325.2019.899655>
30. W. J. Ripple, C. Wolf, and T. M. Newsome, "World Scientists ' Warning of a Climate Emergency", *Bioscience. Mag.*, vol. 2000, no. X, pp. 1–20, 2019.

