

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI ŞEBEKE SİSTEMİNDE EVSEL YÜK
PROFİLLERİNİN SINIFLANDIRILMASI

Uğur Buğra ETLİK

YÜKSEK LİSANS TEZİ

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı
Kontrol ve Otomasyon Mühendisliği Programı

Danışman
Dr. Öğr. Üye. Yavuz EREN

January, 2022

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI ŞEBEKE SİSTEMİNDE EVSEL YÜK PROFİLLERİNİN
SINIFLANDIRILMASI

Uğur Buğra ETLİK tarafından hazırlanan tez çalışması 17.01.2022 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Kontrol ve Otomasyon Mühendisliği Anabilim Dalı Kontrol ve Otomasyon Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üye. Yavuz EREN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üye. Yavuz EREN, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Şeref Naci ENGİN, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üye. İlker ÜSTOĞLU, Üye
İstanbul Teknik Üniversitesi

Danışmanım Dr. Öğr. Üye. Yavuz EREN sorumluluğunda tarafımca hazırlanan Akıllı Şebeke Sisteminde Evsel Yük Profillerinin Sınıflandırılması başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Uğur Buğra ETLİK

İmza

*Aileme
ve
sevdiklerime*



TEŐEKKÜR

Bu alıőmanın yűrűtűlmesi sırasında bana yol gűsteren tez danıőmanım Dr. Őđr. Őye. Yavuz EREN'e yardım, destek ve katkılarından dolayı teőekkűrlerimi sunarım. Ayrıca yođun alıőma dűnemimde bana her zaman destek olan aileme teőekkűr ederim. Yűksek lisans eđitimim boyunca yanımda olan Yiđit ARPACIOđLU'na da yardım ve destekleri iin teőekkűr ederim.

Uđur Buđra ETLİK

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	4
1.3 Hipotez	4
2 METODOLOJİ	6
2.1 Bulanık Mantık	6
2.1.1 Giriş	6
2.1.2 Bulanık Mantık Uygulamaları	7
2.1.3 Bulanık Mantık Kümeleri	7
2.1.4 Bulanık Mantık Kümelerinde Operatörler	10
2.1.5 Bulanık Mantık Yapısı	13
2.1.6 Bulanık Mantık Çıkarım Yöntemleri	13
2.2 Yapay Sinir Ağları	15
2.2.1 Giriş	15
2.2.2 YSA Yapısı	16
2.2.3 Yapay Sinir Ağlarının Uygulamaları	19
2.2.4 YSA Türleri	19
2.3 Veri Seti	26
3 SINIFLANDIRMA	28
3.1 Veri Setlerinin Hazırlığı	28

3.2 Sınıflandırma	33
4 SONUÇ VE ÖNERİLER	40
4.1 Sonuç	40
4.2 Öneriler ve Gelecek Çalışmalar	49
KAYNAKÇA	53
TEZDEN ÜRETİLMİŞ YAYINLAR	56



SİMGE LİSTESİ

A	A Bulanık Mantık Kümesi
A_i	A Giriş Üyelik Fonksiyonu
$\mu_A(x)$	A Kümesinde Üyelik Fonksiyonu
$w(t)$	Ağırlık Matrisi
B	B Bulanık Mantık Kümesi
B_i	B Giriş Üyelik Fonksiyonu
$\mu_B(x)$	B Kümesinde Üyelik Fonksiyonu
q_i	Düğüm
η	Öğrenme Katsayısı
p_i	p Giriş Vektörü
a_i^T	Parametre Vektörü
b_i	Sabit Değer
X	Uzay
x	Uzay Elemanı
\tilde{x}	x Dilsel Değişkeni
$X(t)$	X Giriş Vektörü
\tilde{y}	y Dilsel Değişkeni

KISALTMA LİSTESİ

AHHP	Aktif Hane Halkı Profili
ÇÜA	Çekişmeli Üretici Ağ
ESA	Evrişimsel Sinir Ağı
OK	Ortalama Karekökü
ÖDH	Öz Düzenleyici Haritalar
SBM	Sugeno Bulanık Mantık
TC	Talep Cevabı
UKSB	Uzun Kısa Süreli Bellek
YSA	Yapay Sinir Ağı
YP	Yük Profili

ŞEKİL LİSTESİ

Şekil 2.1	Uzunluğa göre keskin kümeler örneği	8
Şekil 2.2	Uzunluğa göre bulanık mantık kümeleri örneği	9
Şekil 2.3	Üyelik fonksiyonu örnekleri	9
Şekil 2.4	Bulanık mantık kümelerinde VE operatörü	10
Şekil 2.5	Bulanık mantık kümelerinde VEYA operatörü	11
Şekil 2.6	Bulanık mantık kümelerinde DEĞİL operatörü	11
Şekil 2.7	Bulanık mantık yapısı	12
Şekil 2.8	Bir yapay sinir ağı modeli	17
Şekil 2.9	ESA temel mimarisi [20]	21
Şekil 2.10	UKSB birimi [21]	22
Şekil 2.11	Klasik ÇÜA mimarisi [23]	23
Şekil 2.12	Merkezdeki birimin komşulukları (0,1 ve 2). Solda altıgen sağda dikdörtgen. En içteki çokgen 0, ortadaki çokgen 1 ve en dışardaki çokgen ise 2 komşuluğuna denk gelmektedir [25]	24
Şekil 3.1	Tip-1 için referans yük profili	29
Şekil 3.2	Tip-2 için referans yük profili	29
Şekil 3.3	Tip-3 için referans yük profili	30
Şekil 3.4	Tip-4 için referans yük profili	30
Şekil 3.5	Tip-1 için referans aktif hane halkı profili	31
Şekil 3.6	Tip-2 için referans aktif hane halkı profili	31
Şekil 3.7	Tip-3 için referans aktif hane halkı profili	32
Şekil 3.8	Tip-4 için referans aktif hane halkı profili	32
Şekil 3.9	Ana veri setinde yük profilleri	34
Şekil 3.10	Ana veri setinde aktif hane halkı profilleri	34
Şekil 4.1	Tip-1 için yük profillerinin sınıflandırılması	41
Şekil 4.2	Tip-2 için yük profillerinin sınıflandırılması	41
Şekil 4.3	Tip-3 için yük profillerinin sınıflandırılması	42
Şekil 4.4	Tip-4 için yük profillerinin sınıflandırılması	42
Şekil 4.5	Tip-1 için aktif hane halkı profillerinin sınıflandırılması	43
Şekil 4.6	Tip-2 için aktif hane halkı profillerinin sınıflandırılması	43
Şekil 4.7	Tip-3 için aktif hane halkı profillerinin sınıflandırılması	44

Şekil 4.8	Tip-4 için aktif hane halkı profillerinin sınıflandırılması	44
Şekil 4.9	Tip-1 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	45
Şekil 4.10	Tip-2 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	45
Şekil 4.11	Tip-3 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	46
Şekil 4.12	Tip-4 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	46
Şekil 4.13	Tip-1 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	47
Şekil 4.14	Tip-2 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	47
Şekil 4.15	Tip-3 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	48
Şekil 4.16	Tip-4 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması	48

TABLO LİSTESİ

Tablo 2.1	Biyolojik sinir yapısı ve yapay sinir ağı karşılıkları	15
Tablo 2.2	Elektrikli cihazlar ve ortalama güç verileri	27
Tablo 3.1	Referans profilleri için OK değerleri	33
Tablo 3.2	Referans profilleri için ortalama değerler	33
Tablo 3.3	SBM tekniđi kuralları	35
Tablo 3.4	Yük profillerinin sınıflandırılması algoritması	39
Tablo 4.1	SBM ve ÖDHSA teknikleriyle sınıflandırılmış yük profilleri	41

Akıllı Şebeke Sisteminde Evsel Yük Profillerinin Sınıflandırılması

Uğur Buğra ETLİK

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üye. Yavuz EREN

Bu tez çalışmasında, son kullanıcı hane halkı yük profili kümeleme sorunu ele alınmaktadır. Yük profili kümeleme analizi, güç sistemlerinin istikrarını korumak için talep veya arz yönetimi stratejileri için tahmin edilen girdi profilleri olarak kullanılmıştır. Yük profillerin tüketim dinamikleri, teknik ve sosyal faktörlerin bir araya gelmesiyle oluşur. Bu nedenle, yük profillerin dinamik modellerini keşfetmek zorlu bir problem olmuştur. Bu problem çözebilmek için Sugeno bulanık mantık (SBM) (Sugeno fuzzy logic) ve öz düzenleyici haritalar (ÖDH) (self-organizing map) sinir ağları tekniklerinin ardışık uygulamaları kullanılmıştır. İlk olarak, hane halkı sayısı göz önünde bulundurularak 2, 3, 4 ve 5 kişilik olmak üzere aile tipleri oluşturulmuştur. Her aile tipi için 100 adet olmak üzere oluşturulan bu veriler referans veri seti olarak kullanılmıştır. Ortalama alınarak ortaya çıkan dört adet referans verisi göz önünde bulundurularak bulanık mantık kuralları belirlenmiştir. Bu kurallar belirlenirken elektrik tüketim verileri ve aktif hane halkı sayıları kullanılmıştır. Her aile tipi için 250 adet olmak üzere oluşturulan ve toplamda 1000 adet veri içeren ana veri seti bulanık mantık kuralları ile kümelenmiştir. Daha sonra, ortaya çıkan bulanık mantık yaklaşımı sonuçları günün sabah, öğle ve akşam saatlerine göre ağırlıklandırılmıştır. Ağırlıklandırılmış bulanık mantık çıkışları ÖDH sinir ağları tekniğinin girdisi olarak kullanılmıştır. Bu teknik sayesinde yük profillerinin aktif hane halkı sayıları da kullanılarak daha doğru şekilde kümelenmesi amaçlanmıştır.

Anahtar Kelimeler: Kümeleme, bulanık mantık, öz düzenleyici haritalar sinir ağları, yük profilleri



**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

Clustering of Household Load Profiles in Smart Grid Systems

Uğur Buğra ETLİK

Department of Control and Automation Engineering
Master of Science Thesis

Supervisor: Asst. Prof. Dr. Yavuz EREN

In this thesis, end-user household load profile (LP) clustering problem is addressed. LP clustering analysis has been utilized by predicting the input profiles for demand or supply management strategies to maintain the stability of the power systems. The consumption dynamics of the LPs are formed by the combinations of technical and social factors. Hence, the discovering the dynamic patterns of the LPs has been a challenging problem. For this problem, we have offered successive applications of Sugeno fuzzy logic (SFL) and self-organizing map (SOM) neural network techniques. Firstly, family types of 2, 3, 4, and 5 are dealt by considering the number of households. The data which include 100 LPs for each family types, are used as the reference dataset. The fuzzy logic rules are determined by considering the four reference sets obtained by taking the average of the corresponding data. To determine the rules, electricity consumption data and the number of active households were referenced. The main data set which include 250 LPs for each family types as well as 1000 LPs in total, have been clustered with fuzzy logic rules. Then, the output LPs classified by fuzzy logic have been weighted according to the morning, noon, and evening hours of the day. Those LPs are assigned as the input of the SOM neural network technique. Then, it is aimed to cluster the LPs more accurately by SOM technique with the weighting factor as well as the active household numbers. The results show that the successive procedure produce more accurate clustering for the household LPs.

Keywords: Clustering, fuzzy logic, self-organizing maps neural network, load profiles



**YILDIZ TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF SCIENCE AND ENGINEERING**

1.1 Literatür Özeti

Kümeleme, bir dizi örüntü, nokta veya nesnenin doğal gruplandırmasını keşfetmek olarak tanımlanabilir. Kümelemenin operasyonel tanımı ise şu şekilde ifade edilebilir: n adet nesnenin olduğu bir veri setinde, aynı gruptaki nesneler arasındaki benzerlikler yüksekken farklı gruplardaki nesneler arasındaki benzerlikler düşük olacak şekilde bir benzerlik ölçüsüne dayalı K adet grup oluşturulması. Kümeler şekil, boyut ve yoğunluk açısından farklılık gösterebilir. Gerçekte bir küme, bakanın gözünde olan ve önemi ve yorumu için alan bilgisi gerektiren öznel bir varlıktır. İnsanlar iki veya bazı alanlarda üç boyutlu verilerde kümeleme işlemi yapabilirken, yüksek boyutlu verilerde kümeleme işlemi yapabilmek için algoritmalara ihtiyaç duymaktadır. Şu ana kadar yayınlanmış ve gelişmeye devam eden binlerce kümeleme algoritmasının ortaya çıkmasına neden olan konu bu zorluktur [1]. Kümeleme, mühendislik problemlerinin yanı sıra sosyal alanlar için de yaygın olarak uygulanabilir bir fikirdir. Ayrıca, bu temel alanların her ikisinin de ele alması gereken bazı problemler, kümeleme problemlerinin çekim merkezi haline gelmektedir. Bu şekilde, elektrik yük profili (YP) kümeleme popüler bir araştırma konusu olmuştur. Bunun sebebi de YP'lerin ortak kalıplarının teknik sınırlamalar ve sosyo-ekonomik faktörler tarafından şekillendirilmesidir. Önceden belirlenmiş veya kendi kendine belirlenen şablonlara göre YP'ler için tüketim dinamiklerini keşfetmek, kabaca son kullanıcı YP kümeleme olarak tanımlanır. YP kümeleme çalışmaları için iki ana yaklaşım ele alınmıştır [2]: Yapısal model (white box) yaklaşımı, binaların fiziksel özelliklerini, kullanıcı davranışını ve elektrikli cihazların periyodik davranışını dikkate alır. İkinci yaklaşım türü olan belirsiz yaklaşım (black box) modeli ise demografi, meteorolojik veri tabanı, fiyatlandırma stratejileri vb. kriterleri kullanarak tahmin yöntemlerine odaklanır. Kümeleme konusu elektrik endüstrisinde fazlaca kullanılmış olmasına rağmen evsel YP'lerin sınıflandırılması biraz daha sınırlı kalmıştır. McLoughlin ve arkadaşları tarafından yapılan çalışmada evsel elektrikselle yükler değişik metodlarla sınıflandırılmıştır ve en iyi performansın değerlendirilmesi için k-ortalama, k-medoid

ve ÖDH sinir ağı gibi yaygın olarak kullanılan yöntemler kullanılmıştır. Bu yöntemlerde veri kirliliklerini en aza indirmek için YP'ler alt bölümlere ayrılarak kullanılmıştır [3].

Talep cevabı (TC) (demand response) uygulamalarında da YP kümelenmesi kullanılmıştır. Burada yapılan kümeleme işlemleri ile talep tarafı yönetimi ve kullanım süresi tarife tasarımı gibi alanlarda daha verimli olunması amaçlanmıştır. Bu uygulamalar, güç şebekesinin operasyonel kalitesini iyileştirmenin yanı sıra yeni güç kaynaklarına yapılan yatırımları azaltmak için sıklıklar ele alınmıştır. Yakın zamanda yapılan kümeleme araştırmaları ile ilgili olarak, TC uygulamaları önermek amacıyla tahmini veya ölçülen YP'lere atıfta bulunulmuştur. TC uygulamaları, arz talep arasındaki dengeyi korumaya yöneliktir. TC uygulamalarında gerçekleştirilen ana hedefler, tepe yük taleplerini yoğun olmayan dönemlere kaydırmak veya sık ani artışlar veya tek tepe talebi içeren YP segmentlerini düzleştirerek enerji tüketim maliyetlerini azaltmaktır. Modifikasyona dayalı bu faaliyetlerle, son kullanıcı tüketimi arz oranına göre manipüle edilmiştir. Kümeleme işlemleri sonrası ortaya çıkan kümelerdeki ideal seçenekler aracılığıyla bireysel YP'leri şekillendirmek amacıyla teşvik tarifeleri oluşturulmuş ve TC stratejileri önerilmiştir. Bu açıdan bakıldığında kümeleme, yeni pazarlama stratejilerinin geliştirilmesine, fiyatlandırma politikasının belirlenmesine ve güncellenmesine de doğrudan yardımcı olmaktadır [4].

Literatür göz önüne alındığında, YP kümeleme analizine yönelik araştırma faaliyetlerinin sayısı artmıştır. Örneğin, Zakaria ve arkadaşları tarafından yapılan çalışmada, yeni pazarlama stratejileri, elektrik fiyatlandırması ve politika yapımında kullanılabilecek yük kullanımı için tüketici davranış analizi yapılmıştır. Çalışmada, minimum sayıda değişkenle yapısal ilişkilerin aranmasında bir araya getirilen iki aşamalı bulanık c-ortalama (c-means) kümeleme teknikleri tartışılmış ve tipik YP'leri belirlemek için yerel, ticari ve küçük ölçekli endüstrilerin bileşik kullanıcıları ile deneyler yapılmıştır. Bunun yanında, kümeleme işlemi öncesi yük eğrisini incelemek için temel bileşen analizi (principal component analysis) adlı bir faktör analizi tekniği kullanılmıştır [5]. Sun ve arkadaşları tarafından yapılan çalışmada, haneler için eş zamanlı bir k-ortalama (k-means) ve spektral kümeleme (spectral clustering) yöntemi önerilmiştir [6]. Söz konusu yöntem ile belirtilen periyot, tarihe göre alt aralıklara bölünmüş ve söz konusu tekniğin hesaplama karmaşıklığı açısından avantajı gösterilerek yük kalıpları kümelenmiştir. Deney hem akıllı saat ölçümleri hem de anket verileri dahil olmak üzere İrlanda açık verileri kullanılarak gerçekleştirilmiştir. Espinoza ve arkadaşları tarafından yapılan çalışmada, kısa süreli yük tahmini (short-term load forecasting) için segmentasyon yaklaşımının ardından, Belçika Ulusal Şebeke Operatörü'nde her biri yaklaşık 40000 veri noktası içeren 245 trafo merkezinin örnekleri ele alınarak birleşik bir metodoloji uygulanmıştır

[7]. İlgili eğriler, periyodik oto regresyon modeli ile sıcaklık ve mevsimsel etkiler hesaba katılarak segmentlere ayrılmıştır. Bunun sonucunda da k-ortalama metodu kullanılarak kümeleme işlemi yapılmıştır. Colley ve arkadaşları tarafından yapılan çalışmada, Queensland/Avustralya'daki 2013 yılına ait farklı aylık ve yıllık YP'ler incelenmiştir [8]. Toptan yük verilerine dayanarak, aylık birincil yük kümeleri oluşturulmuştur. Ardından, oluşturulan bu yük kümelerinin doğruluğu, optimum küme sayısını çıkarmak için kümeleme dağılım göstergesi (clustering dispersion indicator) ile analiz edilmiştir. Ayrıca gün tipine ve hava koşullarına bağlı olarak her bir yük profilinin karakteristik özellikleri de çalışmada analiz edilmiştir. Choksi ve arkadaşları tarafından yapılan çalışmada, akıllı köy projesin için Hindistan'ın Gujarat kentindeki Nana Kajaliyala köyündeki 171 tüketicinin karakteristik YP'leri analiz edilmiştir. Çalışmada boyutsallık azaltma, yük profili karakterizasyonu ve olasılıksal yük değişimi değerlendirilmesini amaçlayan öznitelik tabanlı bir kümeleme algoritması (feature-based clustering algorithm) önerilmiştir. Önerilen algoritma, yüksek boyutluluğa karşı koyan ampirik bir özellik seçiminin yanı sıra klasik k-ortalama metodunu kullanarak profil karakterizasyonu yapmaktadır. Yeni bir bakış açısı olarak, müşteri profilleri yük etiketlerine ayrılmış olarak optimizasyon odaklı gelecek seçim tekniği ele alınmıştır [9]. 120 gün boyunca 25 tüketici YP'sine dayalı olarak kümeleme işlemi yapılmıştır. Karakteristik profiller, coğrafi bilgi ve veri analizine dayalı olarak altı grupta etiketlenmiştir. Tüm bunların yanında, belirsizliğin olumsuz etkilerini araştırmak amacıyla profillere stokastik faktörler dahil edilmiştir. Benzer bir çalışmada, YP'lerin kümelenmesi için optimizasyon tabanlı bir yaklaşım kullanılmış ve profil setini analiz etmek için yerel, ticari, endüstri, oteller/restoranlar ve diğerleri olmak üzere beş farklı küme modeli belirlenmiştir. Çalışmada, ölçümlerde elde edilen gerçek yük diyagramları kullanılmıştır. Çalışmada kullanılan metodoloji, Portekizli dağıtım sistemi operatörü ile geliştirilmiş ve ortaya çıkan profiller otorite tarafından onaylanmıştır. Profiller her yıl güncellenmekte ve sadece piyasa uzlaştırma amacıyla değil, tüketim diyagramlarının tahmininde ve kayıp profillerin belirlenmesinde de kullanılmaktadır [10]. Ma ve arkadaşları tarafından yapılan çalışmada ise, Norveç'teki bazı yüksek eğitim binaları için ısıtma ve iklimlendirme YP'leri ele alınmıştır. Pearson Korelasyon Katsayısı tabanlı farklılık ölçüsü ile büyüklük metriği yük değişimine odaklanan hiyerarşik bir küme analizi sunulmuştur. Önerilen stratejinin performansı, 2011'den 2013'e kadar Norveç'te toplanan 19 yüksek öğretim binasının ısıtma enerjisi kullanım verileri kullanılarak değerlendirilmiştir [11]. Benzer bir şekilde Maderia ve arkadaşları tarafından çalışmada, ısı pompalı Danimarka konutlarının ısıtma yükü talep profilleri sunulmuş ve yerleşim yeri, inşaat yılı gibi bina özellikleri ve bunların yanında çocukların varlığının sosyo-ekonomik değişkeni gibi parametreler göz önünde bulundurulmuştur. Yüksek, orta ve düşük talep dönemlerindeki yük profillerinde farklılıklar bulunduğu

için her bir yük dönemi için hem hafta içi hem de hafta sonu olmak üzere iki ana yük profil kümesi tanımlanmıştır. Ortaya çıkan modeller incelendiğinde, yaygın olan modelde gün boyunca nispeten sabit bir yük profilinin olduğu gözlemlenmiştir. Daha az görülen modelde ise sabah yüksek zirve değerlerinin görüldüğü, gün ortası düşük taleplerin olduğu, öğleden sonra ve akşam saatlerinde ise artan taleplerin olduğu gözlemlenmiştir [12]. Piao ve arkadaşları tarafından yapılan çalışmada, yük şekli değişkenliğini klasik algoritmalarından daha iyi şekilde yakalamaya odaklanan, uygun küme sayısını elde etmek amacıyla müşteri kümesindeki yük eğilimlerini ayırklaştırmak için alt uzay projeksiyon (subspace projection) yöntemi önerilmiştir [13]. Akıllı şebeke kavramının yaygınlaştırılmasıyla birlikte bazı şirketler, elektrik tüketim davranışlarına bağlı olarak teşvik programları geliştirme yönünde önemli adımlar atmışlardır. Bu amaçla Vercamer ve arkadaşları tarafından yapılan çalışmada, Belçika'daki 6000'den fazla müşteriye ait otomatik sayaç cihazı olmayan veriler üzerinde demografik ve kartografik veri türleri ile analizi destekleyen spektral kümeleme (spectral clustering) ele alınmıştır [14]. Bölgesel YP oluşturabilmek için, her bir evden ayrıntılı bilgi toplamak bir probleme sebebiyet vermemiştir.

1.2 Tezin Amacı

Tez çalışmasında evsel yüklerin aile tiplerine göre kümelenmesi problemi ele alınmıştır. Kümeleme işleminde elektrik tüketim verileri ve belirlenen zaman dilimlerindeki aktif hane halkı sayıları göz önünde bulundurulmuştur. Bu girdiler ile aktif hane halkı sayılarına göre kümeleme işlemi yapılmaya çalışılmıştır. Kümeleme sürecinde iki aşamalı olarak farklı metotlar kullanılmıştır. İlk aşamada SBM metodu, ikinci aşamada ise ÖDH sinir ağı tekniği kullanılmıştır. İki aşamalı yaklaşım ile zaman dilimi ağırlıklandırılması yapılarak referans yük tiplerine göre en doğru kümeleme yapılması hedeflenmiştir

1.3 Hipotez

YP'lerin kümelenmesinde sadece elektrik tüketim verileri yeterli değildir. Elektrik tüketim verilerinin yanı sıra belirli zaman aralıklarında aktif hane halkı sayısı göz önünde bulundurulmalı ve bu veriler günün zaman dilimlerine göre bir ağırlıklandırılmalıdır. Bunun yanında evsel verilerin hane halkı sayısındaki birkaç değişiklik ile birbirinden çok ayrışmadığı da bilinen bir durumdur. Dolayısıyla sınıflandırma sürecinde verilerin benzer sınıflara geçmesi çok olası bir durumdur. Kümeleme sürecinde profilleri yüksek hassasiyetle birbirinden ayırmak için çok kademeli yaklaşımlar ileri sürülebilir. Bu bağlamda hane halkı aktif enerji kullanım durumu ve ağırlıklandırılmış zaman dilimleri yaklaşımı göz önüne alınarak bulanık

mantık ve yapay sinir ağlarının kademeli olarak uygulanması evsel yük profillerinin daha doğru sınıflandırılmasını sağlayabileceği düşünülmüştür. Özet olarak, bu tez çalışmasında ilgili kümeleme problemi için ortaya atılan çözüm önerisi bulanık mantık ve yapay sinir ağları tekniklerinin kademeli olarak uygulanmasıdır.



2.1 Bulanık Mantık

2.1.1 Giriş

Bulanık mantık terimi, 1965 yılında Lütfü Aliasker Zade tarafından bulanık kümeler teorisinin geliştirilmesinde ortaya çıkmıştır. Zade makalesinde, nesnelere kesin olmayan sınırlara sahip kümelerden oluşan bir teori ortaya koymuştur. Bulanık kümelerdeki üyelik konusu, bir onaylama veya reddetme konusu değil, bir derece konusudur [15]. Bulanık mantık uygulamaları mutlak doğru, mutlak yanlış gibi doğru sonuçlar yerine insan davranışlarını ve doğanın işleyişini taklit edecek biçimde davranır. Gündelik hayatta çokça kullanılan “çok güzel”, “biraz yavaş” gibi belirsiz ifadelerin bilgisayar ortamında da problemleri çözmekte kullanılmasına olanak sağlamıştır. Bir X kümesinin bir bulanık alt kümesi A , X 'in her bir elemanına, X 'in A 'daki üyelik derecesinin atanmasıyla karakterize edilir. Örneğin X , bir insan grubudur, A , X 'teki bulanık yaşlı insanlar kümesidir. X bir önermeler dizisi ise, öğelerine “mutlak doğru”, “mutlak yanlış” veya bir ara doğruluk derecesi olabilecek doğruluk dereceleri atanabilir. Yani bir önerme başka bir önermeden daha doğru olabilir.

Bulanık mantığın avantajları şu şekilde sıralanabilir.

- Esneklik.
- Kesin olmayan verilere toleranslıdır.
- Kavramsal olarak anlaşılması kolaydır ve karmaşıklıktan uzaktır.
- Uzmanların deneyimi üzerine inşa edilebilir.
- Her türlü probleme kolaylıkla uygulanabilir.
- Doğal dile dayalıdır.

Bulanık mantığın dezavantajları şu şekilde sıralanabilir.

- Kullanılan kurallar fazlasıyla deneyime bağlıdır.
- Problem çözümü için fazlasıyla veri gerekir.
- Üyelik fonksiyon seçiminde belirli bir kural veya yöntem yoktur. Deneme yanılma yoluyla belirlenir.
- Problemin karmaşıklık oranıyla kümelerin ve üyelik fonksiyonlarının belirlenmesi de doğru oranda karmaşıktır.

2.1.2 Bulanık Mantık Uygulamaları

Bulanık mantık sisteminin aşağıdaki gibi kullanıldığı birçok alan vardır.

- Otomatik şanzımanlar, ABS ve hız sabitleyici gibi otomobil ve diğer araç alt sistemleri
- Uzay ve havacılık
- Dijital görüntü işleme
- Asansörler
- Klimalar
- Bulaşık ve çamaşır makineleri
- Aydınlatma sistemleri
- Trafik lambaları
- Dil filtreleri
- Maden yatağı tahminleri

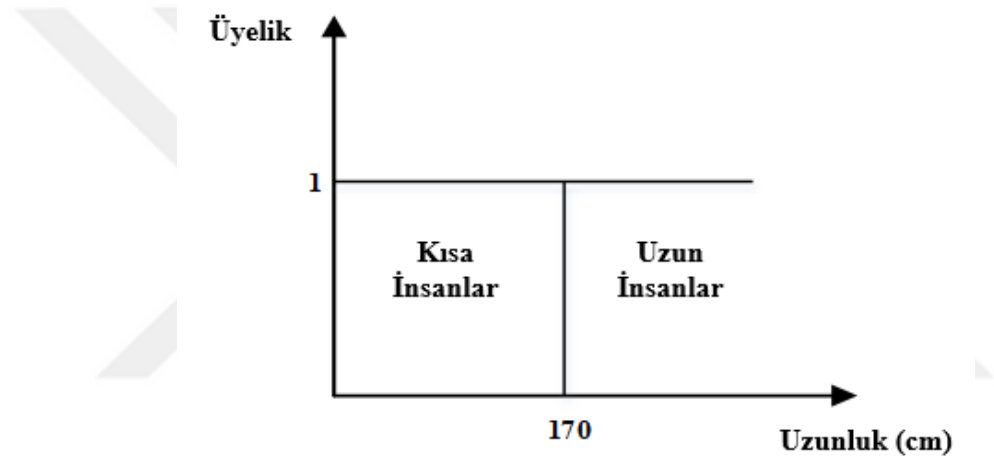
2.1.3 Bulanık Mantık Kümeleri

Bulanık mantık, bulanık küme kavramı ile başlar. Bulanık küme, kesin sınırları olmayan kümelerdir. Sadece kısmi üyelik derecesine sahip elemanlar içerebilir. Yani bir nesne bir kümenin ya elemanı yada elemanı değil olarak tanımlanabilirken, bir bulanık kümenin belirli bir oranda kısmen elemanı olabilir.

Elemanları x olarak gösterilen bir X uzayında bulanık A kümesi aşağıdaki gibi tanımlanabilir:

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (2.1)$$

Burada $\mu_A(x)$, x 'in A 'ya ait derecesini temsil eden A 'daki x 'in üyelik fonksiyonudur. Üyelik fonksiyonu $\mu_A(x)$ X 'teki her bir elemanı $[0, 1]$ birim aralığına eşler. Üyelik fonksiyonunun değeri 0 ise, bu üyeye ait bulanık küme 0'dır, yani bu üye bulanık kümenin tamamen dışındadır. Bir üyenin aitlik derecesi 1 ise, bu üye tamamen bulanık kümenin içindedir. Şekil 2.1'de insan boylarının uzunluk ve kısalığa göre keskin şekilde kümelenmesinin bir örneği verilmiştir.




Şekil 2.1 Uzunluğa göre keskin kümeler örneği

Şekil 2.1'de 170 cm'nin altında olan kişiler kısa, 170 cm'nin üzerinde olan kişiler ise uzun boylu olarak tanımlanmıştır. Bu tanımlama şekli, bulanık kümeler için bir çelişkidir. Bulanık kümelerde keskin ayırmadan uzaklaşılır. 165 cm uzunluğundaki kişiler keskin kümelerde kısa kişiler olarak tanımlanırken, bu kişiler bulanık kümelerde kısa boylu kişiler ve belirli bir aidiyet derecesine sahip uzun boylu kişiler olarak tanımlanabilir.

Şekil 2.2'de 170 cm uzunluğa sahip kişiler 0,5 üyelik dereceli kısa insanlar bulanık küme ve aynı anda 0,5 üyelik dereceli uzun boylu insanlar bulanık küme aittir. Boyları 180 cm'den büyük olanlar 1 üyelik dereceli tamamen uzun insanlar bulanık kümelerine, 160 cm'den kısa olanlar ise 1 üyelik dereceli tamamen kısa insanlar bulanık kümelerine aittir. Boyları 160 ile 180 cm arasında olan kişiler, farklı üyelik derecelerine sahip her iki bulanık küme de aittir.

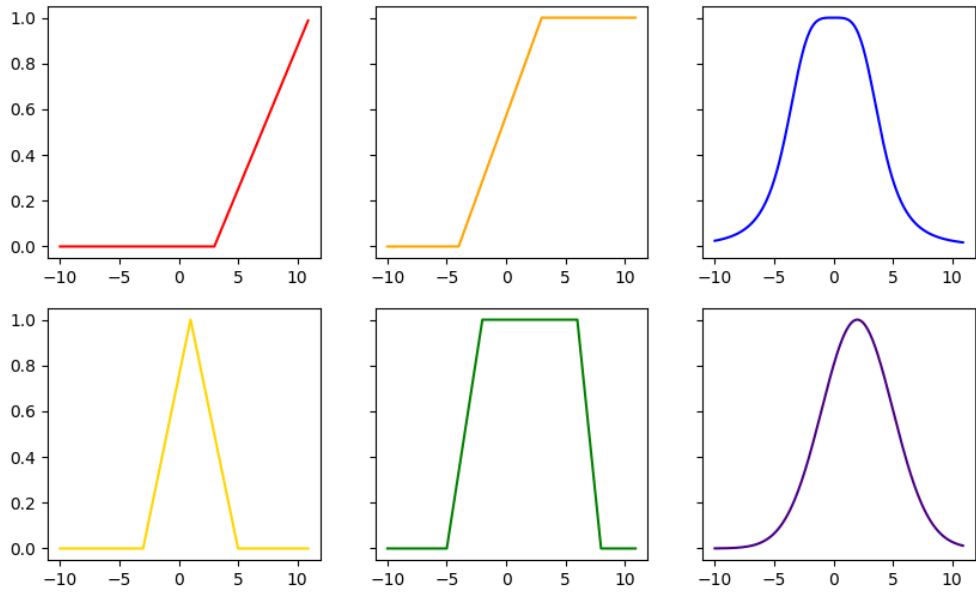
Üyelik fonksiyonu, girdi uzayındaki her noktanın 0 ile 1 arasında bir üyelik



Şekil 2.2 Uzunluğa göre bulanık mantık kümeleri örneği

derecesine nasıl eşlendiğini tanımlayan bir eğridir. Bir üyelik fonksiyonunun gerçekten karşılması gereken tek koşul, 0 ile 1 arasında değişmesi gerektiğidir.

En yaygın olarak kullanılan üyelik fonksiyonları türleri üçgen, yamuk, gauss ve gauss çan fonksiyonlarıdır. Bazı üyelik fonksiyonu örnekleri Şekil 2.3'te gösterilmektedir.



Şekil 2.3 Üyelik fonksiyonu örnekleri

2.1.4 Bulanık Mantık Kümelerinde Operatörler


2.1.4.1 VE Operatörü

VE operatörü için iki farklı yöntem kullanılabilir. Minimum bulma veya kesişim alma yöntemleri vardır. μ_A , A bulanık kümesine ait gerçek sayının üyelik derecesi, μ_B , B bulanık kümesine ait gerçek sayının üyelik derecesidir. VE operatörü için kullanılabilen iki farklı matematiksel yöntem aşağıda verilmiştir.

$$\mu_{A \cap B} = \min(\mu_A, \mu_B) \quad (2.2)$$

$$\mu_{A \cap B} = \mu_A * \mu_B \quad (2.3)$$

Şekil 2.4'te uzunluk örneği için kesişme işlemi gösterilmiştir.



Şekil 2.4 Bulanık mantık kümelerinde VE operatörü


2.1.4.2 VEYA Operatörü

VEYA operatörü için de VE operatörü gibi iki farklı yöntem kullanılabilir. Maksimum bulma veya birleşim yöntemleri vardır. VEYA operatörü için kullanılabilen iki farklı matematiksel yöntem aşağıda verilmiştir.

$$\mu_{A \cup B} = \max(\mu_A, \mu_B) \quad (2.4)$$

$$\mu_{A \cup B} = \mu_A + \mu_B - (\mu_A * \mu_B) \quad (2.5)$$

Şekil 2.5'te uzunluk örneği için birleşim işlemi gösterilmektedir.



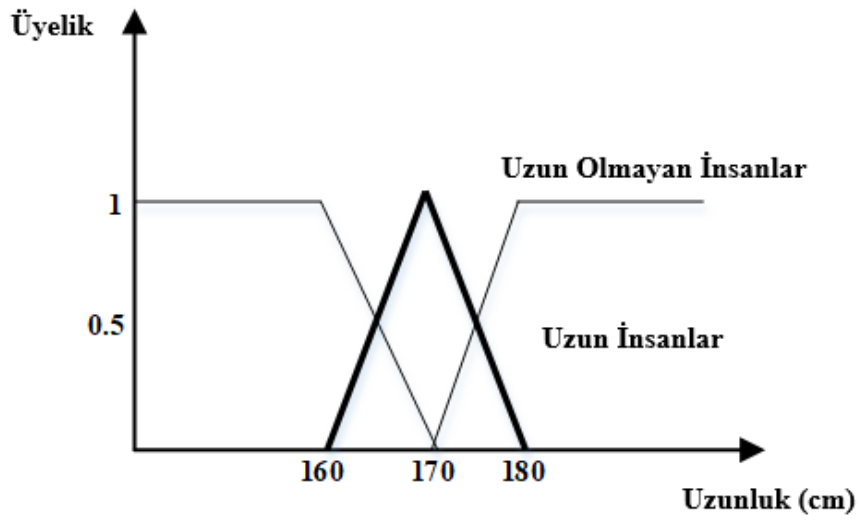
Şekil 2.5 Bulanık mantık kümelerinde VEYA operatörü

2.1.4.3 DEĞİL Operatörü

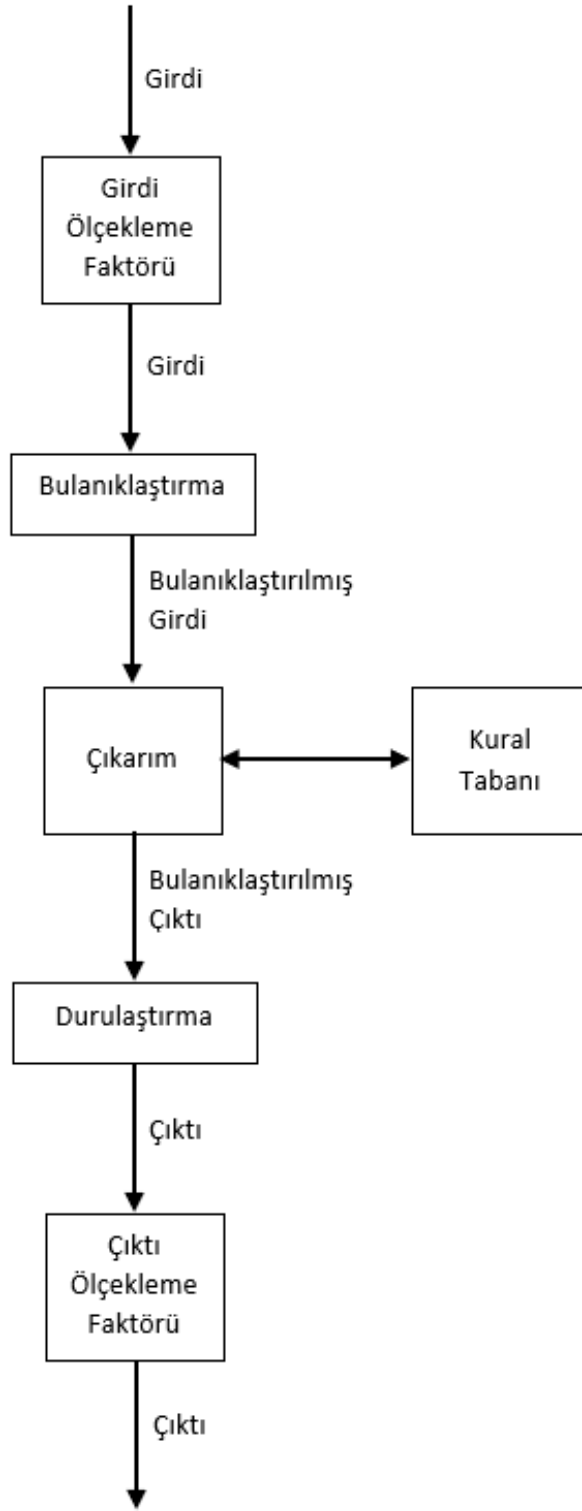
DEĞİL operatörünün matematiksel ifadesi aşağıdaki gibidir.

$$\mu_{\bar{A}} = 1 - \mu_A \quad (2.6)$$

DEĞİL operatörü Şekil 2.6'da gösterilmektedir.



Şekil 2.6 Bulanık mantık kümelerinde DEĞİL operatörü



Şekil 2.7 Bulanık mantık yapısı

2.1.5 Bulanık Mantık Yapısı

Bulanık mantık yapısı Şekil 2.7'de gösterilmektedir.

Bulanıklaştırma: Bulanıklaştırma bloğu, bulanık kümelerin dilsel terimleri için girdi değerlerini üyelik derecelerine dönüştürme sürecini içerir. Yani sisteme yalın haliyle verilmiş olan değerleri, üyelik fonksiyonlarını kullanarak bulanık değerlere dönüştürür. Eğer bir bulanık mantık kurallarının birden fazla öncülü varsa, bir önceki bölümde anlatılan operatörler kullanılır.

Çıkarım: Kural tabanıyla ortak çalışır. Çıkarım bloğunun girdisi öncül tarafından verilen tek bir sayıdır ve çıktısı bir bulanık mantık kümesidir. Çıkarımlar her kural için ayrı ayrı uygulanır.

Kural Tabanı: Bulanık mantık kural setinin tutulduğu kısımdır. Çıkarım bloğuyla ortak çalışır.

Durulaştırıcı: Çıkarım sonucunda ortaya çıkan kararların bir şekilde birleştirilmesi gerektiğinden dolayı durulaştırıcı bloğu kullanılır. Gerçek uygulamalarda kesin bir sayısal çıktıya ihtiyacımız olduğu için durulaştırıcı kullanılır ve kesin çıktılar elde edilir. Bir bulanık kümeyi durulaştırmak için genel olarak beş adet yöntem vardır. Ancak en yaygın olarak kullanılan yöntemler alan merkezi ve maksimum ortalaması yöntemleridir.

Ölçekleme Faktörü: Giriş ve çıkış sistemlerindeki gerçek değerlerin aralığı bulanık sistemlerin aralığından farklıdır. Bu nedenle giriş ve çıkış ölçekleme faktörleri kullanılır.

2.1.6 Bulanık Mantık Çıkarım Yöntemleri

2.1.6.1 Mamdani Çıkarımı

İnsan algısına daha çok hitap etmesi, yorumlanabilir olması ve tasarımının daha kolay olması sebebiyle en çok kullanılan çıkarım yöntemidir. Mamdani bulanık kural tabanında, giriş ve çıkış üyelik fonksiyonları tanımlanarak bir çıktı elde edilir.

EĞER \tilde{x} A_i O HALDE \tilde{y} B_i

Burada \tilde{x} dilsel değişkendir ve A_i giriş üyelik fonksiyonudur. Aynı şekilde, \tilde{y} dilsel değişkendir ve B_i çıkış üyelik fonksiyonudur. Burada tüm dilsel değişkenler ve terimler kendi bölgelerinde tanımlanır ve üyelik fonksiyonları 0 ile 1 arasında tanımlanan bulanık kümelerdir.

Mamdani çıkarımının avantajları şu şekilde sıralanabilir.

- Sezgiseldir.
- İnsan girdisine uygundur.
- Yorumlanabilir.

Mamdani bulanık mantık uygulama alanı olarak tıbbi tanı sistemleri örnek olarak verilebilir.

2.1.6.2 Sugeno Çıkarımı

Özellikle kontrol problemlerinde çokça tercih edilir. Sugeno bulanık kural tabanını Mamdani kural tabanından ayıran en önemli özellik çıkış üyelik fonksiyonlarının fonksiyonlarla tanımlanmasıdır.

EĞER $\tilde{x} \in A_i$ **O HALDE** $y_i = f_i(x), i = 1, 2, \dots, n$

Çıkıştaki doğrusal fonksiyon, kullanım kolaylığı için seçilebilir.

$$f_i(x) = a_i^T(x) + b_i \quad (2.7)$$

Bu denklemde, a_i^T parametre vektörü, b_i ise sabit değerdir.

Sugeno çıkarımının avantajları şu şekilde sıralanabilir.

- PID kontrolü gibi doğrusal tekniklerle iyi çalışır.
- Optimizasyon ve uyarlanabilir tekniklerle iyi çalışır.
- Çıkış yüzeyi süreklidir.
- Matematiksel analiz için uygundur.

Sugeno bulanık mantık uygulama alanı olarak uçak performansının irtifa ile değişiminin takip edilmesi örnek olarak verilebilir.

2.2 Yapay Sinir Ağları

2.2.1 Giriş

Yapay sinir ağları (YSA), insan beyninin işleyişinden ilham alınarak ortaya çıkarılmış yaklaşımlardır. YSA'lar gerçek sinir hücrelerinin simule edilmiş halleri olarak tanımlanabilir. İnsan beynindeki sinir hücrelerinde bulunan nöronlar birbirleri ile bağlanarak sinir ağlarını oluştururlar. Bu ağlar şu andaki veya eski bilgileri hafızaya alma işlevinin yanı sıra yeni bilgileri öğrenme becerisine de sahiptir. İnsanlar bu becerilerini deneme-yanılma yoluyla yani deneyimleyerek veya gözlemleyerek geliştirmektedir. Bu öğrenme süreci insanların doğumlarından itibaren başlar ve ölümlerine kadar devam eder. Bu yaşam süresince insan beyni sürekli olarak gelişme göstermektedir. İşte YSA'lar da insanların bu biyolojik sistemini taklit eder. Örnekler kullanılarak öğrenme gerçekleşir. Giriş/çıkış verilerinin değişik algoritmalarla işlenmesiyle YSA içindeki ağırlıklar tekrar tekrar güncellenir. Ağırlıkların değişimi öğrenme sürecini ifade eder. Ağırlıkların değişimi yani diğer bir deyişle öğrenme süreci yakınsama sağlanana kadar devam eder. Eğer ağırlıklar güncellenmiyorsa artık öğrenme süreci tamamlanmış demektir. YSA'lar öğrenme işleminin yanı sıra ilişkilendirme, değerlendirme, sınıflandırma, genelleme ve optimizasyon gibi işlemleri de gerçekleştirebilmektedir.

Biyolojik sinir hücresinin yapısını incelediğimizde ana elemanları hücre gövdesi, dentrit ve akson olarak görülmektedir. Sinir hücrelerine gelen uyarımlar, dendritler ile hücre gövdesine taşınır ve aksonlar ile diğer hücrelere iletilir. Bu taşıma işlemi sırasında aksonlar ile dendritler arasında yer alan sinapslar rol oynar. Burada bahsedilen biyolojik sinir hücresi elemanları ve yapay zekadaki karşılıkları Tablo 2.1'de verilmiştir.

Tablo 2.1 Biyolojik sinir yapısı ve yapay sinir ağı karşılıkları

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci düğüm
Dentrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Akson	Çıkış düğümü
Sinapslar	Ağırlıklar

YSA'ların avantajları şu şekilde sıralanabilir.

- YSA'lar karmaşık işlemleri gerçekleştirebilir.
- Öğrenme kabiliyeti vardır.
- Öğrenilmemiş çıktılar için de sonuç üretebilir.

- Sınıflandırma ve eksik örüntüleri tamamlama kabiliyeti vardır.
- Hata toleransı vardır.
- Paralel çalışabilir.
- Gerçek zamanlı olarak bilgi işleyebilir.
- Adaptasyon yeteneği vardır.
- Bilgi tüm ağda saklanır.


YSA'ların avantajlarının yanında dezavantajları da mevcuttur. Bu dezavantajlar şu şekilde sıralanabilir.

- YSA'ların işleyiş mekanizması tam olarak açıklanamaz. YSA'lar çıktıları neden ve nasıl ürettiğine dair bir ipucu vermez. Kara kutu gibi çalışırlar.
- Yapıları gereği paralel işlem gücüne sahip işlemcilere ihtiyaç duyarlar. Bu nedenle donanıma bağımlıdır.
- Yapay sinir ağlarının yapısını belirlemek için belirli bir kural yoktur. Uygun ağ yapısı, deneyim ve deneme yanılma yoluyla elde edilir.
- Sayısal bilgilerle çalışabilir. YSA'ya tanıtılmadan önce problemlerin sayısal değerlere çevrilmesi gerekir. Bu çevrimin başarısı da ağın performansını doğrudan etkiler.
- Hatanın belli bir değere indirilmesi eğitimin tamamlandığı anlamına gelir ancak bu değer bize optimum sonuçları vermez. Ayrıca eğitimin ne zaman bitirilmesi gerektiğine dair belirli bir yöntem de yoktur.

2.2.2 YSA Yapısı

YSA'lar, ağırlıklandırılmış şekilde birbirine bağlanmış birçok işlem elemanlarından oluşur. Bir işlem elemanı diğer işlem elemanından veya elemanlarından sinyalleri alır ve bu sinyalleri matematiksel işlemler sonucu sayısal bir sonuca dönüştürür. Bu elemanlar ile bir veya birden fazla katmanlı YSA'lar oluşturulur. Şekil 2.8'de örnek bir YSA görülmektedir.

Giriş Katmanı: YSA'ya girdilerin geldiği katmandır. Bu katmanda, girdi sayısı ile eşit miktarda hücre bulunur ve girdiler herhangi bir işlem yapılmadan ara katmana iletilir.



Şekil 2.8 Bir yapay sinir ağı modeli

Ara Katman: Giriş katmanında alınan veriler bu katmanda işlenerek bir sonraki katmana iletilir. Ara katman sayısı ve bu katmanlarda bulunan işlem elemanı sayısı ağdan ağa farklılık gösterebilir. Burada bulunan işlem elemanı sayısı girdi ve çıktı sayılarından bağımsızdır.

Çıkış Katmanı: Ara katmandan gelen bilgiyi işler ve giriş katmanına gelen girdiye uygun olarak bir çıktı değeri üretir. Çıkış katmanındaki eleman sayısı da farklılık gösterir.

YSA'ların çalışma yapısının genel başlıkları ise aşağıdaki gibi sıralanabilir.

1. Veri seti belirlenir.
2. Girdi ve çıktı sayıları belirlenir.
3. Öğrenme katsayısı ve sabitleri belirlenir.
4. Veri setindeki tüm değerler ağa gönderilir. Bu değerler için hatalar hesaplanır ve bulunan hata değerlerine göre ağırlıklar güncellenir.
5. Çıktı değerleri üretilir.

YSA'larda öğrenme paradigmaları; denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning), yarı denetimli öğrenme (semi-supervised learning) ve pekiştirmeli öğrenme (reinforcement learning) olarak belirtilebilir.

Denetimli Öğrenme: Hedef olarak hareket eden önceden etiketlenmiş girdiler yoluyla öğrenmedir. Her eğitim örneği için, bir dizi girdi değeri ve bir veya daha fazla ilişkili belirlenmiş çıktı değeri olacaktır. Bu eğitim biçiminin amacı, eğitim örneğinin çıktı

değerinin eğitim yoluyla doğru hesaplanması yoluyla modelin genel sınıflandırma hatasını azaltmaktır. En yaygın denetimli öğrenme algoritmaları aşağıdaki gibi sıralanabilir.

- K-en yakın komşu (k-nearest neighbor)
- Karar ağacı (decision tree)
- Naive Bayes
- Doğrusal regresyon (linear regression)
- Destek vektör makineleri (support vector machines)

Denetimsiz Öğrenme: Eğitim setinin herhangi bir etiket içermemesi bakımından farklılık gösterir. Başarı, genellikle ağın ilişkili bir maliyet fonksiyonunu (cost function) azaltıp azaltamayacağına veya artırıp artıramayacağına göre belirlenir. Bununla birlikte, çoğu görüntü odaklı örüntü tanıma görevinin genellikle denetimli öğrenme kullanılarak yapılan sınıflandırmaya bağlı olduğuna dikkat etmek önemlidir [16]. En yaygın denetimsiz öğrenme algoritmaları aşağıdaki gibi sıralanabilir.

- K-ortalama kümeleme (k-means clustering)
- Birliktelik kuralları (association rules)

Yarı Denetimli Öğrenme: Öğrenme sırasında az miktarda etiketlenmiş veriyi büyük miktarda etiketlenmemiş veriyle birleştiren bir öğrenme yaklaşımıdır. Yarı denetimli öğrenme, denetimsiz öğrenme ve denetimli öğrenme arasında yer alır. Yarı denetimli öğrenmenin amacı, etiketli ve etiketsiz verilerin birleştirilmesinin öğrenme davranışını nasıl değiştirebileceğini anlamak ve böyle bir kombinasyondan yararlanan algoritmalar tasarlamaktır [17].

Pekiştirmeli Öğrenme: Sayısal bir ödül sinyalini en üst düzeye çıkarmak için ne yapılacağını, durumları eylemlerle nasıl eşleştireceğinizi öğrenmektir. Bu algoritmada hangi eylemlerin yapılması gerektiği söylenmez, bunun yerine hangi eylemlerin onları deneyerek en fazla ödül verdiğinin keşfedilmesi gerekir. En ilginç ve zorlu durumlarda, eylemler yalnızca anlık ödülü değil, bir sonraki durumu ve bu sayede sonraki tüm ödülleri de etkileyebilir. Deneme-yanılma ve gecikmeli ödül özellikleri pekiştirmeli öğrenmenin en önemli iki ayırt edici özelliğidir [18]. Pekiştirmeli öğrenme adımları aşağıdaki gibidir.

1. Giriş durumu ajan (agent) tarafından gözlemlenir.
2. Karar verme işlevi, ajanın bir eylemi gerçekleştirmesini sağlamak için kullanılır.
3. Eylem gerçekleştirildikten sonra, ajan çevreden bir ödül veya takviye alır.
4. Ödüle ilgili durum-eylem çifti bilgisi saklanır.

En yaygın pekiştirmeli öğrenme algoritmaları aşağıdaki gibi sıralanabilir.

- Q-öğrenme (Q-learning)
- Zamansal fark (temporal difference)

2.2.3 Yapay Sinir Ağlarının Uygulamaları

Hayatımızda büyük yer edinmeye başlamış ve uygulama alanı çok geniş olan YSA'ların aşağıdaki gibi kullanıldığı birçok alan vardır.

- Siber güvenlik
- Savunma sanayi
- E-ticaret
- Sesli asistanlar
- Öneri sistemleri
- Sağlık hizmetleri
- Navigasyon
- Robotik

2.2.4 YSA Türleri

Günümüzde birçok YSA türü bulunmakta ve bunlara yeni türler eklenmeye de devam etmektedir. Bu türler mimari olarak birbirinden ayrılmaktadır. YSA türlerine örnekler aşağıdaki gibidir.

- Algılayıcı (perceptron)
- İleri beslemeli (feed forward)

- Tekrarlayan sinir ađı (recurrent neural network)
- Derin ileri beslemeli (deep feed forward)
- Uzun kısa süreli bellek (long short term memory)
- Yarıçapsal temelli ađ (radial basis network)
- Kapılı tekrarlayan hücre (gated recurrent unit)
- Otomatik kodlayıcı (auto encoder)
- Varyasyonel otomatik kodlayıcı (variational auto encoder)
- Gürültü giderici otomatik kodlayıcı (denoising auto encoder)
- Seyrek otomatik kodlayıcı (sparse auto encoder)
- Markov zinciri (Markov chain)
- Hopfield ađı (Hopfield network)
- Boltzmann makinesi (Boltzmann machine)
- Kısıtlı Boltzmann makinesi (restricted Boltzmann machine)
- Derin inanç ađı (deep belief network)
- Evrişimsel sinir ađı (convolutional neural network)
- Dekonvolüsyonel ađ (deconvolutional network)
- Derin konvolüsyonlu ters grafik ađı (deep convolutional inverse graphics network)
- Çekişmeli üretici ađ (generative adversarial network)
- Sıvı hal makinesi (liquid state machine)
- Aşırı öğrenen makine (extreme learning machine)
- Yankılanan durum ađı (echo state network)
- Derin kalıntı ađı (deep residual network)
- Öz düzenleyici haritalar (self-organizing map)
- Destek vektör makinesi (support vector machine)
- Turing sinir makinesi (neural turing machine)

Bu YSA türlerinden bazıları başlıklar altında açıklanmıştır.

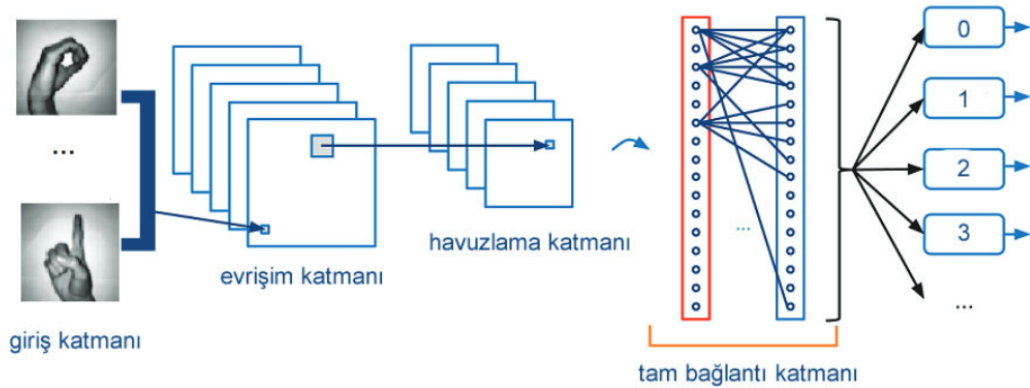
2.2.4.1 Evrişimsel Sinir Ağı

Evrişimsel sinir ağı (ESA), bir görüntüde bulunan çeşitli görüntü veya nesneleri birbirinden ayırt etme gücüne sahip olan bir ağıdır. Başka bir tanım olarak ESA, katmanlarından en az birinde genel matris çarpımı yerine evrişimi kullanan basit sinir ağlarıdır [19].

Bazı kullanım alanları aşağıda listelenmiştir.

- Görüntü sınıflandırma
- Nesne bulma
- Nesne takip etme
- Doğal dil işleme
- Tıbbi görüntü analizi
- Reklam

ESA temel mimarisi Şekil 2.9'da gösterilmektedir. Giriş katmanı, ham verinin ağı girdi olarak verildiği katmandır. Evrişim katmanı, ESA'nın temel katmanıdır. Bu katmanda yer alan filtreler görüntü içerisindeki özellikleri belirlemek için kullanılmaktadır. Havuzlama katmanı, özelliklerin boyutunu azaltıldığı katmandır. Bu katmanda, iki boyutlu özellik dizileri düzleştirilerek tek, sürekli ve doğrusal bir vektöre dönüştürülür. Tam bağlantı katmanı ise ESA'nın son katmanıdır. Burada havuzlama katmanından gelen düzleştirilmiş matris kullanılmakta ve öğrenme gerçekleştirilmektedir.



Şekil 2.9 ESA temel mimarisi [20]

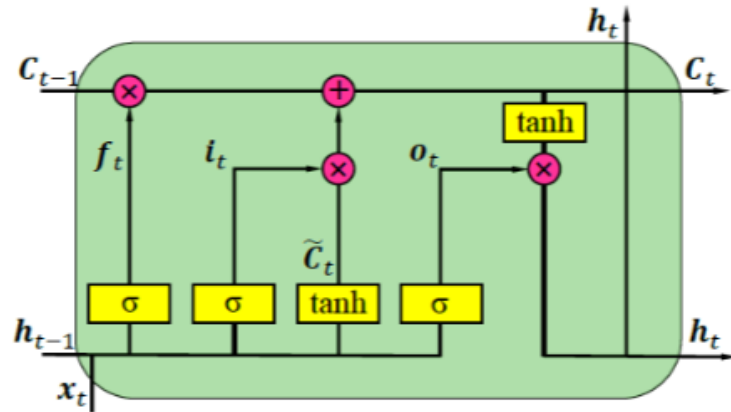
2.2.4.2 Uzun Kısa Süreli Bellek

Uzun kısa süreli bellek (UKSB), sıralı verilerin modellenmesi için uygulanan yinelemeli sinir ağı (recurrent neural network) mimarisidir. Bu mimaride, her bir girdi verisi bir önceki çıktı verisinin değeri de göz önünde bulundurularak tekrarlı olarak incelenir. Geri bildirim bağlantıları olması sebebiyle standart ileri beslemeli sinir ağlarından (feedforward neural network) ayrışır. Yalnızca anlık veriyi değil, veri dizilerini de işleyebilme yeteneğine sahiptir.

Bazı kullanım alanları aşağıda listelenmiştir.

- El yazısı tanıma
- Konuşma tanıma
- Ağ trafiğinde anomali algılama
- Saldırı tespit sistemleri

UKSB mimarisi, birbirini tekrar eden sıralı UKSB birimlerinden oluşur. Sıradan bir UKSB hücresi, giriş kapısı, çıkış kapısı ve unutmaya kapısı olmak üzere üç ana birimden oluşmaktadır. Giriş kapısı, şimdi zamana ait olan girdi verilerini ezberlemek için kullanılır. Çıkış kapısı, çıktıların verilmesi için kullanılır. Unutmaya kapısı ise geçmişe ait olan bazı verileri unutmak amacıyla kullanılır. Bu kapıların bulunduğu UKSB birimi Şekil 2.10'da gösterilmiştir. Buradaki sigmoid işlevi $[0,1]$ aralığına sahiptir ve çarpım işlemi sayesinde ne kadar bilgi iletileceği belirlenir. Çarpım işleminin değeri 0 ise hiçbir bilgi iletilmez. Ancak çarpım işleminin değeri 1 ise tüm bilgiler iletilir.



Şekil 2.10 UKSB birimi [21]


2.2.4.3 Çekişmeli Üretici Ağ

Çekişmeli üretici ağ (ÇÜA), üretici modelleme problemini çözmek için tasarlanmış bir tür yapay zeka algoritmasıdır [22]. Üretken modelleme, girdi verilerindeki kalıpları, orijinal veri kümesinden uygun bir şekilde çıkararak eğitim verilerine benzeyen yeni örnekler oluşturan denetimsiz bir öğrenme algoritmasıdır.

Bazı kullanım alanları aşağıda listelenmiştir.

- Yüksek çözünürlüklü fotoğraf üretimi
- Görüntüden görüntüye çeviri
- Metinden resme çeviri
- Video oyunları
- Siber güvenlik
- Sağlık

Diğer ağ mimarilerinden farklı olarak bir üretici (generative) ve bir ayırıcı (discriminator) olmak üzere iki farklı ağa sahiptir. Bu iki ağ birbiriyle yarışarak öğrenme işlemini gerçekleştirilir. Üretici sinir ağı ayırıcı sinir ağını yanıltmak için çabalar. Bu amaçla sahte örnekler oluşturur. Ayırıcı sinir ağı ise kendisine gelen veri setindeki doğru örnekleri yanlış örneklerden ayırmaya çalışır. Klasik ÇÜA mimarisi Şekil 2.11’de gösterilmektedir.




Şekil 2.11 Klasik ÇÜA mimarisi [23]

2.2.4.4 Öz Düzenleyici Haritalar

1982 yılında Kohonen tarafından geliştirilen ÖDH algoritması, en popüler yapay sinir ağları modellerinden biridir [24]. Tuevo Kohonen tarafından geliştirilmesi sebebiyle Kohonen ağları olarak da isimlendirilmektedir. Denetimsiz bir öğrenme algoritması olan ÖDH, sınıflandırma alanında başarı ile kullanılabilir.

ÖDH rekabetçi öğrenme uygulayarak hata düzeltme işlemini yapar ve bu konuda diğer yapay sinir ağlarından ayrışır. Tek katmanlı bir ağ yapısı olan ÖDH ağları girdi ve çıkış nöronlarından oluşur. Giriş nöronlarının sayısı veri setindeki değişken sayısı tarafından belirlenir. Çıkış nöronlarının her biri ise bir kümeyi temsil eder. ÖDH ağlarının çıkış katmanında sonucu belirleyen en önemli kısım ise nöron dizilimidir. Bu dizilim doğrusal, dikdörtgen, altıgen veya küp şeklinde olabilir. En çok tercih edilen dizilim şekilleri dikdörtgen ve altıgendir. Bu dizilim şekillerinin komşuluktaki etkileri Şekil 2.12'de görülebilir.



Şekil 2.12 Merkezdeki birimin komşulukları (0,1 ve 2). Solda altıgen sağda dikdörtgen. En içteki çokgen 0, ortadaki çokgen 1 ve en dışardaki çokgen ise 2 komşuluğuna denk gelmektedir [25]

ÖDH algoritmasındaki öğrenim süreci şu şekilde tanımlanabilir: Algoritma rastgele bağlantı ağırlıkları (connection weights) ile başlatılır. Referans veri setinden rastgele olarak bir giriş vektörü seçilir. Giriş vektörü, bağlantılara bağlı olarak çıkış düğümlerine gönderilir. Tüm düğümler incelenir ve kazanan hepsini alır (winner takes all) yaklaşımıyla beraber giriş vektörüne en fazla benzerlik gösteren ağırlıklara sahip çıkış düğümü seçilir ve aktif hale getirilir. Bu öğrenim aşamasında ağırlıklar aşağıdaki şekilde güncellenir [26].

$$w(t + 1) = w(t) + \eta[X(t) - w(t)] \quad (2.8)$$

Burada w ağırlık matrisi, X giriş vektörü ve η öğrenme katsayısıdır. Kazanan sinirlerin komşu sinirleri etkileme oranları zaman içerisinde değişiklik gösterir. Başlarda geniş olarak belirlenen bu komşuluk zamanla azalır. Ağırlık güncellemesi de yalnızca

topolojik komşular için oluşur.

Kazanan düğümü seçmek için kullanılan en yaygın algoritma Öklid uzaklığı (Euclidean distance) hesaplamasıdır. Öklid uzaklığı basitçe ifade etmek gerekirse, iki nokta arasındaki doğrusal uzaklıktır. n boyutlu bir uzayda p giriş vektörü ile arasındaki uzaklık en kısa olan yani kazanan düğüm olan q düğümünü bulabilmek için aşağıdaki formül kullanılmaktadır.

$$\sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2.9)$$

Aşağıdaki listede ÖDH'nin bazı kullanım alanları gösterilmektedir [27].

- İstatistiksel yöntemler
- Endüstriyel analizler
- Kontrol
- Telekomünikasyon
- Biyomedikal analizler ve uygulamalar
- Finansal uygulamalar

Bunlara ek olarak, suçluların davranış profillerinin elde edilmesi, galaksilerin kategorize edilmesi ve gayrimenkullerin kategorize edilmesi gibi birkaç özel uygulama alanından daha bahsedilebilir.

ÖDH'lerin birçok avantajı vardır. Bunlardan bir tanesi ifade modellerinin iki boyutlu kolay görselleştirilmesiyle beraber verileri bölümlere ayırmak için kullanılabilmesidir. Ayrıca diğer yöntemlere kıyasla hesaplama gereksinimlerini azaltır [28]. Tüm bu avantajlarının yanı sıra en önemli avantajları muhtemelen yorumlama kolaylığı ve çok çeşitli alanlara uygulanabilmesidir. Çok büyük veri kümelerinin bile üstesinden gelinebilir. Bu durumlarda eğitim yavaş olabilir, ancak bu yapıldıktan sonra yeni veriler ÖDH'ye çok hızlı bir şekilde eşlenebilir. Ancak bunların da bazı dezavantajları vardır. Bunlardan ilki ve en önemlisi, ayarlanması gereken parametre sayısıdır. Haritanın boyutu ve topolojisinin yanı sıra eğitim parametrelerinin değerleri de belirlenmelidir. Genellikle karşılaştırılabilir sonuçlar veren çok çeşitli ayarlar olmasına rağmen, haritalamanın optimizasyonu için zaman harcanmalıdır. Ayrıca, sürecin başlatma, verilerin sunum sırası gibi birkaç rastgele bileşeni olduğundan aynı

topolojiye ve eğitim ayarlarına sahip haritalar oldukça farklı sonuçlar gösterebilir. Ancak birçok durumda, görünüşte farklı olan bu haritalardan çıkarılan sonuçlar yine de benzer olabilir [29].

2.3 Veri Seti

Veri seti hazırlanırken Richardson ve arkadaşları tarafından hazırlanan yüksek çözünürlüklü evsel elektrik enerjisi talep modelinden yararlanılmıştır [30]. Bu modeldeki en önemli kısım zamana bağlı cihaz kullanımı yaklaşımıdır. Model televizyon, çamaşır makinesi veya elektrikli süpürge gibi cihazları yapı taşı olarak alır ve bu cihazların elektrik tüketim verilerini hesaba katarak elektrik yük profilleri ortaya çıkarır.

Bir konut içindeki cihaz kullanımı dolayısıyla da elektrik tüketim miktarı evde bulunan ve uyanık olan insan sayısı ile orantılıdır. Modeldeki her konut için gün boyunca aktif hane halkı sayısı rastgele olarak değişmektedir. Bu sayede günlük yaşamlarını sürdüren insanların doğal davranışları temsil edilir. Gece boyunca düşük kullanım, sabah erken saatlerde artan kullanım gibi gerçekçi tüketim verileri elde edilir. Model içindeki aktif hane halkı sayısı değeri, elektrik tüketim verilerinin oluşturulması için birincil mekanizmadır.

Elektrik tüketim verilerinin modellenmesini iyileştirmek için, hane sakinlerinin faaliyetlerine dayalı ikinci bir mekanizma da kullanılır. İnsanların yemek pişirme eğiliminde oldukları saatlerde veya işe/okula gidiş/geliş saatlerinde tüketimin artması gibi gerçekçi eğilimler mevcuttur. Benzer şekilde insanların akşam saatlerinde televizyon izleme olasılıkları daha fazladır. İşte bu eğilimler daha sonrasında cihazlara bağlanmaktadır. Somut örneklerle devam etmek gerekirse, televizyon izleme eğilimi olan saatlerde televizyon, yemek pişirme eğilimi olan saatlerde fırın, çamaşır yıkama eğilimi olan saatlerde ise çamaşır makinesinin çalışıyor olması gerektiği açıktır. Modeldeki her bir cihaz için bir aktivite profili atanmış ve cihazların gün boyunca değişik olasılıklarla kullanılması hesaba katılmıştır. Bu adımlar sayesinde ayrıntılı cihaz kullanım istatistiklerine ihtiyaç duyulmadan modeldeki cihazların günün uygun saatlerinde etkinleştirilmesi sağlanmıştır.

Modelden veri seti üretirken üç farklı parametre ile veri seti özelleştirilebilmektedir. Bu parametreler; evde yaşayan hane halkı sayısı, üretilmek istenen verinin hafta içi veya hafta sonu mu olduğu ve hangi aya göre elektrik tüketim verilerinin üretilmek istendiği. Bizim çalışmamızda dört farklı aile tipi kullanılmıştır. Bu nedenle hane halkı sayıları 2, 3, 4 ve 5 kişi olarak seçilmiş tüm aile tipleri için ayrı ayrı veriler üretilmiştir. Bunun yanı sıra veriler hafta içi bir güne ve haziran ayına göre üretilmiştir.

Modelde kullanılan bu parametreler dışında evde kullanılan cihazlar ve hane halkı sayıları rastgele olarak seçilerek verinin daha gerçekçi olması sağlanmıştır.

Model oluşturulurken kullanılan bazı cihazlar ve ortalama güç verileri Tablo 2.2'de görülebilir.


Tablo 2.2 Elektrikli cihazlar ve ortalama güç verileri

Cihaz	Güç (W)
Buzdolabı	110
Ütü	1000
Bilgisayar	141
Yazıcı	335
Televizyon	123
Ocak	2400
Fırın	2125
Mikrodalga fırın	1250
Su ısıtıcısı	2000
Bulaşık makinesi	1131
Çamaşır makinesi	406
Çamaşır kurutma makinesi	792


3.1 Veri Setlerinin Hazırlığı

Hane halkı YP'leri [30] referansında sunulan model tarafından oluşturulmuştur. Bu araç, isteğe bağlı tarihe, hane halkına ve aktif hane halkı sayısına göre rastgele gerçekçi elektrik tüketimi verileri sağlamaktadır. Bu çalışmada 2, 3, 4 ve 5 hane halkı sayılarına karşılık gelen Tip-1, Tip-2, Tip-3 ve Tip-4 olmak üzere dört aile tipi belirlenmiştir. İlk olarak referans yük profili veri seti olarak kullanabilmek amacıyla her aile tipine göre 100 farklı rastgele yük oluşturulmuştur. Herhangi bir aile tipinin referans modelini elde etmek için, aile tipindeki her bir YP'nin aktif hane halkı sayısı rastgele seçilmiştir. Bunun yanı sıra, verilerin çözünürlüğü de profillerin dinamik davranışlarını yakalayabilmek için önemli bir başka faktördür. YP'ler belirli bir örnekleme süresi ile ayrıklaştırılır ve örnekleme süresi boyunca karşılık gelen değerin sabit olduğu varsayılır. Bu şekilde, Granell ve arkadaşları YP'lerin varyasyon modelini ayırt etmek için uygun zaman aralıkları üzerinde çalışmışlar ve yük verilerinin en fazla 30 dakikalık aralıklarla örneklenmesi gerektiğini belirtmişlerdir [31]. Bu çalışmaya istinaden, bizim çalışmamızda da profiller günde her 15 dakika için ortalama tüketim veya ortalama aktif hane halkı sayısı verileri alınarak yeniden düzenlenmiştir. Son olarak ilgili aile türlerindeki her 100 YP ve aktif hane halkı profili (AHHP) (occupancy) için, zaman çerçevesi boyunca süperpozisyon teoremine göre ortalama değerleri hesaplanmıştır.


Tüm aile tipleri için referans YP'leri Şekil 3.1, Şekil 3.2, Şekil 3.3 ve Şekil 3.4'te verilmiştir. Referans tiplerinin AHHP'leri ise Şekil 3.5, Şekil 3.6, Şekil 3.7 ve Şekil 3.8'de verilmiştir. Şekillerden de görülebileceği üzere profiller genel olarak sabah ve özellikle akşam saatlerinde yoğun elektrik tüketimi gerçekleştirmişlerdir. Bu tüketim fazlalığının sebebi olarak da aktif hane halkı sayıları bu saatlerde daha yüksek olmuştur. Öğle saatlerinde ise genellikle az tüketim eğilimi gösterilirken, gece saatlerinde elektrik tüketim değerleri minimum seviyelerdedir. Genel elektrik tüketim verileri bu eğilimde olduğu için sınıflandırma algoritmasında da bu eğilim göz önünde bulundurulmuştur.




Şekil 3.1 Tip-1 için referans yük profili




Şekil 3.2 Tip-2 için referans yük profili




Şekil 3.3 Tip-3 için referans yük profili




Şekil 3.4 Tip-4 için referans yük profili




Şekil 3.5 Tip-1 için referans aktif hane halkı profili



Şekil 3.6 Tip-2 için referans aktif hane halkı profili



Şekil 3.7 Tip-3 için referans aktif hane halkı profili



Şekil 3.8 Tip-4 için referans aktif hane halkı profili

Tablo 3.1’de tüm aile tipleri için hesaplanan yük profilleri ve aktif hane halkı sayıları ortalama karekökü (OK) (root mean square) değerleri verilmiştir. Tablo 3.2’de ise tüm aile tipleri için hesaplanan yük profilleri ve aktif hane halkı sayıları ortalama değerleri verilmiştir. Bu değerler hesaplanırken sadece referans profilleri veriseti göz önünde bulundurulmuş ve referans profilleri için OK ve ortalama değerleri hesaplanmıştır.

Tablo 3.1 Referans profilleri için OK değerleri

Aile Tipleri	Yük Profilleri İçin OK Değeri	Aktif Hane Halkı Sayıları İçin OK Değeri
Tip-1	370.9369	0.8655
Tip-2	425.6892	1.0944
Tip-3	463.8757	1.3589
Tip-4	478.1320	1.6072


Tablo 3.2 Referans profilleri için ortalama değerler

Aile Tipleri	Yük Profilleri İçin Ortalama Değeri	Aktif Hane Halkı Sayıları İçin Ortalama Değeri
Tip-1	336.2161	0.7242
Tip-2	375.2784	0.8627
Tip-3	415.4393	1.0699
Tip-4	431.7255	1.2801

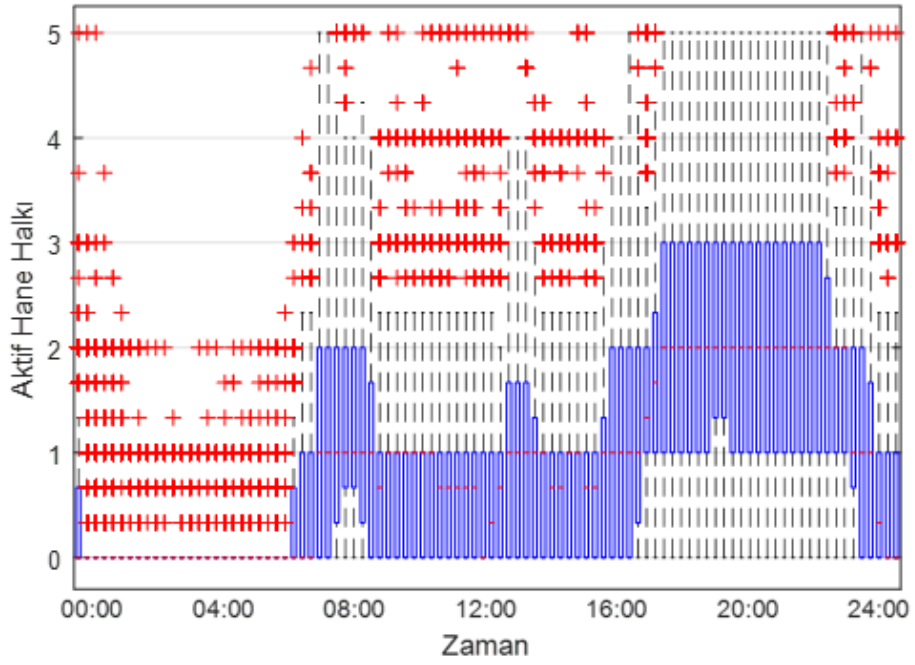
Test verileri üzerindeki benzerlikleri kontrol etmek amacıyla referans veriseti kullanılmıştır. Bu nedenle, kümeleme algoritmasına girdi vermek için test verileri üretmemiz gerekmiştir. Bu amaçla tip-1, tip-2, tip-3 ve tip-4 aile tipleri için 250’şer adet olmak üzere toplamda 1000 adet rastgele YP’ye sahip ana veri seti oluşturulmuştur. Benzer şekilde, profiller ardışık 15 dakikalık aralıklarla ortalama alınarak tekrar düzenlenmiş ve algoritmada kullanılan ana verisetinin son hali elde edilmiştir. Ana veri setinin YP’leri ve AHHP ’leri sırasıyla Şekil 3.9 ve Şekil 3.10’da gösterilmektedir.

3.2 Sınıflandırma

YP’lerin sınıflandırılmasıyla ilgili son araştırmalarda, temel olarak makine öğrenimi, sinir ağları, veri madenciliği, bulanık mantık ve karakter tahmin tekniklerine atıfta bulunulmuştur. Bu perspektiften, hane halkı YP’lerini benzerliklerine göre belirli gruplarda toplamak için SBM ve ÖDH tekniklerinin ardışık kullanıldığı bir yaklaşım benimsenmiştir. Bulanık mantık tekniği, kesin bilgi veya kararlar için belirsizliklerin derecesini temsil eder [32]. Bu nedenle, bu teknik, keskin sınıf atama sonuçlarını esneterek ara sınıflandırma işlemi gerçekleştirmektedir [33]. Böylece üyelik fonksiyonları, daha doğru bir korelasyon yapmak için daha fazla seçenek



Şekil 3.9 Ana veri setinde yük profilleri



Şekil 3.10 Ana veri setinde aktif hane halkı profilleri

aramaya yardımcı olur. Ayrıca ÖDH, yük profillerinin dinamik davranışını tespit etmek ve sınıflandırmak için de uygun bir tekniktir. ÖDH'nin diğer sinir ağlarından farklı bir özelliği olarak girdi ve çıktı katmanları arasında bağlantı kurmak için özel referans vektörü içermesidir.

1000 adet YP'nin kümelenmesi, SBM ve ÖDH ardışık uygulamaları ile gerçekleştirilmiştir. İlk aşamada SBM tekniği uygulanır. Bu şekilde, YP'ler tipik bir gün için 15 dakikalık aralıklarla örneklenmiş ve zamansal enerji tüketim verilerini değerlendirmek için günün 96 farklı periyodu 1000 öge ile ayrıştırılmıştır. Bu nedenle tüm veriler, matrisin her satırı günün farklı 15 dakikalık periyoduna karşılık gelecek şekilde 96x1000 boyutunda bir matris ile temsil edilir. Matrisin her satırı test profillerinin eş zamanlı verilerini içerir, bu nedenle SBM tekniği günün her zaman dilimi için ayrı ayrı uygulanmıştır. 1000 adet rastgele YP'nin her biri ile karşılaştırmak için aile türlerinin referans profilleri kullanılmıştır. Bu işlem Tablo 3.3'te verilen 16 adet kural seti ile gerçekleştirilmiştir.

Tablo 3.3 SBM tekniği kuralları

Aktif Hane Halkı Sayısı / Enerji Tüketimi	2 kişi	3 kişi	4 kişi	5 kişi
Tip-1	0	0.33	0.33	0.66
Tip-2	0	0.33	0.66	0.66
Tip-3	0.33	0.33	0.66	1
Tip-4	0.33	0.66	0.66	1

Bulanık mantık kuralları belirlenirken tip-1 aile tipi için 0, tip-2 aile tipi için 0.33, tip-3 aile tipi için 0.66 ve tip-4 aile tipi için 1 çıkış değerleri belirlenmiştir.

Deneme yanılma yoluyla belirlenen bulanık mantık kuralları ve bu kuralların belirlenme kriterleri aşağıdaki gibidir.

Kural 1: Eğer referans enerji tüketim verisi tip-1 (2 kişilik aile) ve aktif hane halkı sayısı 2 kişi ise çıkış değeri 0'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-1'e uygun olduğu söylenebilir. Bunun yanında aktif hane halkı sayısının da 2 kişi olması sebebiyle bulanık mantık çıkış değeri 0 olarak belirlenmiştir.

Kural 2: Eğer referans enerji tüketim verisi tip-1 (2 kişilik aile) ve aktif hane halkı sayısı 3 kişi ise çıkış değeri 0.33'tür.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-1'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 3 kişi olması sebebiyle

bulanık mantık çıkış değeri bir üst değer olan 0.33 olarak belirlenmiştir.

Kural 3: Eğer referans enerji tüketim verisi tip-1 (2 kişilik aile) ve aktif hane halkı sayısı 4 kişi ise çıkış değeri 0.33'tür.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-1'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 4 kişi olması sebebiyle bulanık mantık çıkış değeri bir üst değer olan 0.33 olarak belirlenmiştir.

Kural 4: Eğer referans enerji tüketim verisi tip-1 (2 kişilik aile) ve aktif hane halkı sayısı 5 kişi ise çıkış değeri 0.66 'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-1'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 5 kişi olması sebebiyle bulanık mantık çıkış değeri iki üst değer olan 0.66 olarak belirlenmiştir.

Kural 5: Eğer referans enerji tüketim verisi tip-2 (3 kişilik aile) ve aktif hane halkı sayısı 2 kişi ise çıkış değeri 0'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-2'ye uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 2 kişi olması sebebiyle bulanık mantık çıkış değeri bir alt değer olan 0 olarak belirlenmiştir.

Kural 6: Eğer referans enerji tüketim verisi tip-2 (3 kişilik aile) ve aktif hane halkı sayısı 3 kişi ise çıkış değeri 0.33'tür.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-2'ye uygun olduğu söylenebilir. Bunun yanında aktif hane halkı sayısının da 3 kişi olması sebebiyle bulanık mantık çıkış değeri 0.33 olarak belirlenmiştir.

Kural 7: Eğer referans enerji tüketim verisi tip-2 (3 kişilik aile) ve aktif hane halkı sayısı 4 kişi ise çıkış değeri 0.66'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-2'ye uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 4 kişi olması sebebiyle bulanık mantık çıkış değeri bir üst değer olan 0.66 olarak belirlenmiştir.

Kural 8: Eğer referans enerji tüketim verisi tip-2 (3 kişilik aile) ve aktif hane halkı sayısı 5 kişi ise çıkış değeri 0.66'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-2'ye uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 5 kişi olması sebebiyle bulanık mantık çıkış değeri bir üst değer olan 0.66 olarak belirlenmiştir.

Kural 9: Eğer referans enerji tüketim verisi tip-3 (4 kişilik aile) ve aktif hane halkı sayısı 2 kişi ise çıkış değeri 0.33'tür.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-3'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 2 kişi olması sebebiyle bulanık mantık çıkış değeri bir alt değer olan 0.33 olarak belirlenmiştir.

Kural 10: Eğer referans enerji tüketim verisi tip-3 (4 kişilik aile) ve aktif hane halkı sayısı 3 kişi ise çıkış değeri 0.33'tür.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-3'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 3 kişi olması sebebiyle bulanık mantık çıkış değeri bir alt değer olan 0.33 olarak belirlenmiştir.

Kural 11: Eğer referans enerji tüketim verisi tip-3 (4 kişilik aile) ve aktif hane halkı sayısı 4 kişi ise çıkış değeri 0.66'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-3'e uygun olduğu söylenebilir. Bunun yanında aktif hane halkı sayısının da 4 kişi olması sebebiyle bulanık mantık çıkış değeri 0.66 olarak belirlenmiştir.

Kural 12: Eğer referans enerji tüketim verisi tip-3 (4 kişilik aile) ve aktif hane halkı sayısı 5 kişi ise çıkış değeri 1'dir.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-3'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 5 kişi olması sebebiyle bulanık mantık çıkış değeri bir üst değer olan 1 olarak belirlenmiştir.

Kural 13: Eğer referans enerji tüketim verisi tip-4 (5 kişilik aile) ve aktif hane halkı sayısı 2 kişi ise çıkış değeri 0.33'tür.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-4'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 2 kişi olması sebebiyle bulanık mantık çıkış değeri iki alt değer olan 0.33 olarak belirlenmiştir.

Kural 14: Eğer referans enerji tüketim verisi tip-4 (5 kişilik aile) ve aktif hane halkı sayısı 3 kişi ise çıkış değeri 0.66'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-4'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 3 kişi olması sebebiyle bulanık mantık çıkış değeri bir alt değer olan 0.66 olarak belirlenmiştir.

Kural 15: Eğer referans enerji tüketim verisi tip-4 (5 kişilik aile) ve aktif hane halkı

sayısı 4 kişi ise çıkış değeri 0.66'dır.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-4'e uygun olduğu söylenebilir. Ancak bunun yanında aktif hane halkı sayısının da 4 kişi olması sebebiyle bulanık mantık çıkış değeri bir alt değer olan 0.66 olarak belirlenmiştir.

Kural 16: Eğer referans enerji tüketim verisi tip-4 (5 kişilik aile) ve aktif hane halkı sayısı 5 kişi ise çıkış değeri 1'dir.

Enerji tüketim verisi göz önünde bulundurulduğunda tip-4'e uygun olduğu söylenebilir. Bunun yanında aktif hane halkı sayısının da 5 kişi olması sebebiyle bulanık mantık çıkış değeri 1 olarak belirlenmiştir.

Bu çalışmada, hanelerin aktif hane halkı sayıları da dikkate alınarak kümeleme analizi yapılmıştır. Daha önce de belirtildiği gibi, hane halkı sayısı elektrik tüketimi üzerinde nispeten daha az etkiye sahip olsa da hanelerin AHHP'leri büyük etkiye sahiptir. Bu durum, ev aletlerinin çokluğu veya aydınlatma, ısıtma, havalandırma gibi genel enerji kaynaklarının aynı anda kullanıcılar tarafından kullanılması olarak açıklanmaktadır. Bu nedenle, elektrik tüketimindeki en önemli faktör hanelerin AHHP'leridir. AHHP'lerini kümeleme analizine dahil etmek için ÖDH tekniğine atıfta bulunulmuştur. Bu amaçla, hane halklarının zamansal faaliyetlerinden yola çıkarak SBM yöntemiyle elde edilen mevcut çıktı kümelerine ağırlık verilmiştir. Profiller 22:00-06:00, 06:00-14:00 ve 14:00-22:00 saat dilimleri için sırasıyla 0,05, 0,15 ve 0,8 parametreleriyle ağırlıklandırılmıştır. Bu nedenle, aktif hane halkı sayıları nispeten daha yüksek olduğu saat dilimine öncelik verilmiştir. Daha sonrasında ortaya çıkan bu profiller ÖDH tekniğine girdi olarak verilmiştir.

Genel kümeleme işleminin tüm adımları Tablo 3.4'te verilmiştir.

Tablo 3.4 Yük profillerinin sınıflandırılması algoritması

Algoritma: Yük profillerini sınıflandırılması	
Aşama 1	Tüm aile tipleri için 100'er adet yük ve aktif hane halkı referans profili elde et.
Aşama 2	Referans profillerde ortalama enerji tüketimini ve ortalama aktif hane halkı sayılarını hesapla.
Aşama 3	Tüm aile tipleri için 250'şer adet yük ve aktif hane halkı test profili elde et.
Aşama 4	Döngü 1: Günün her 15 dakikalık periyodu için
Aşama 5	Ortalaması alınmış referans profillerini zaman bazlı olarak normalize et.
Aşama 6	Normalize edilmiş her referans profili için 4 adet üyelik fonksiyonu tanımla.
Aşama 7	Her üyelik fonksiyonu için $4 * 4 = 16$ bulanık mantık kuralı tanımla.
Aşama 8	Test profillerini zaman bazlı olarak normalize et.
Aşama 9	Döngü 2: Her test profili için
Aşama 10	Bulanık mantık karar verme sürecini çalıştır.
	Döngü 2 sonu
	Döngü 1 sonu
Aşama 11	Döngü 3: Her bulanık mantık çıkış profili için
Aşama 12	ÖDH sinir ağları karar verme sürecini çalıştır.
	Döngü 3 sonu

4

SONUÇ VE ÖNERİLER


4.1 Sonuç

Bu çalışmada, elektrik tüketim ve aktif hane halkı sayıları kullanılarak bulanık mantık ve yapay sinir ağları algoritmalarının hibrit bir şekilde kullanılmasını gösterilmektedir. Önerilen algoritma rastgele üretilen bir veri setinde haneleri kümelemek amacıyla kullanılmıştır. Sonuçlar, önerilen algoritmanın akıllı şebeke sistemlerinde haneleri sınıflandırmak için uygun olacağını göstermektedir.


Kullanılan algoritma sonucu ulaşılan kümeleme sonuçları Tablo 4.1'de sunulmuştur. Bu çalışmada nispeten birbirine benzer olarak nitelendirilebilecek hane halkı sayılarına sahip 4 aile tipi ele alınmıştır. Hane halkı YP'leri göz önüne alındığında, elektrik tüketimi verileri, hane halkı sayılarına birkaç kişi eklemek veya çıkarmak kadar büyük bir fark yaratmamaktadır. Veri setinde herhangi bir aile tipini ele aldığımızda, hane halkı sayısındaki değişimin en yakın türlere kıyasla sadece bir kişi olduğu görülmektedir. Bu nedenle, kümedeki herhangi bir tür, en yakın tür profillere benzer özelliklere sahiptir. Dolayısıyla bu durum, çalışmada yapılan kümeleme prosedürünü nispeten zorlaştırmıştır. Tablo 3.1'de, her referans türü için yük ve aktif hane halkı sayılarının OK değerleri sunulmuştur. Bu tablodan da görüldüğü gibi enerji tüketim miktarları birbirlerine yakındır. Bu nedenle, oluşturulan kümeler komşu kümelerle de eşleştirilmelidir. Yani çalışma sonunda ortaya çıkan kümeler benzerliklerinden dolayı kendilerine en yakın olan kümeyle de eşleştirilerek doğru olarak kabul edilebilir. Bu açıdan bakıldığında önerilen kümeleme yaklaşımı Tablo 4.1'de görüldüğü gibi %90 başarı sağlamıştır. Profillerin önemli ölçüde benzerliği göz önüne alındığında, bu kabul edilebilir bir performanstır. Başarı performansı hesabı yan komşulara atılan sonuçlar da doğru olarak kabul edildiğinde aşağıdaki gibi gösterilmiştir.

Tablo 4.1 SBM ve ÖDHSA teknikleriyle sınıflandırılmış yük profilleri


Sınıflandırma Sonuçları / Referans Tipler	Tip-1	Tip-2	Tip-3	Tip-4
Tip-1	165	81	4	0
Tip-2	60	120	66	4
Tip-3	36	76	111	27
Tip-4	11	50	90	99



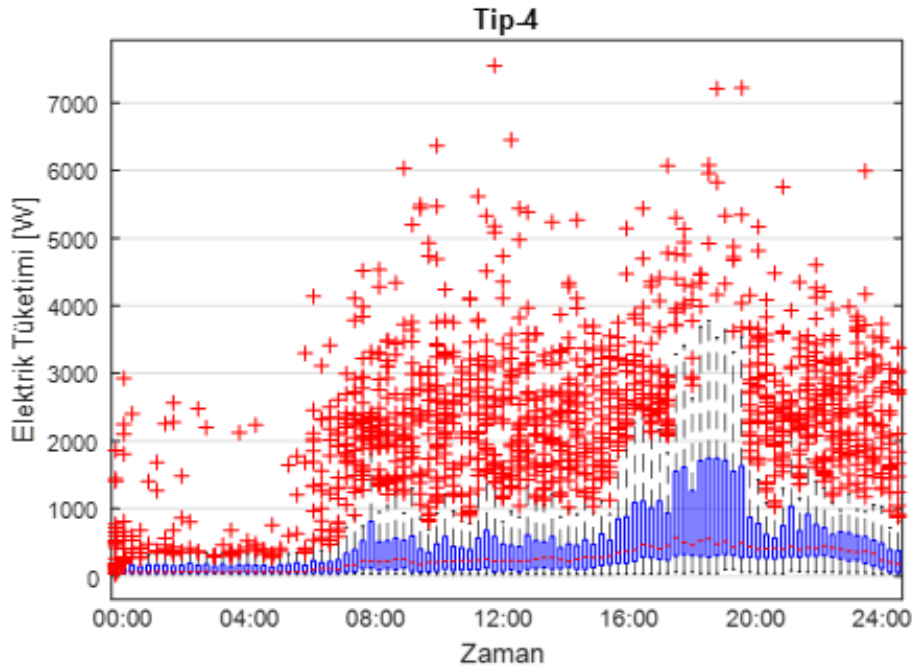
Şekil 4.1 Tip-1 için yük profillerinin sınıflandırılması



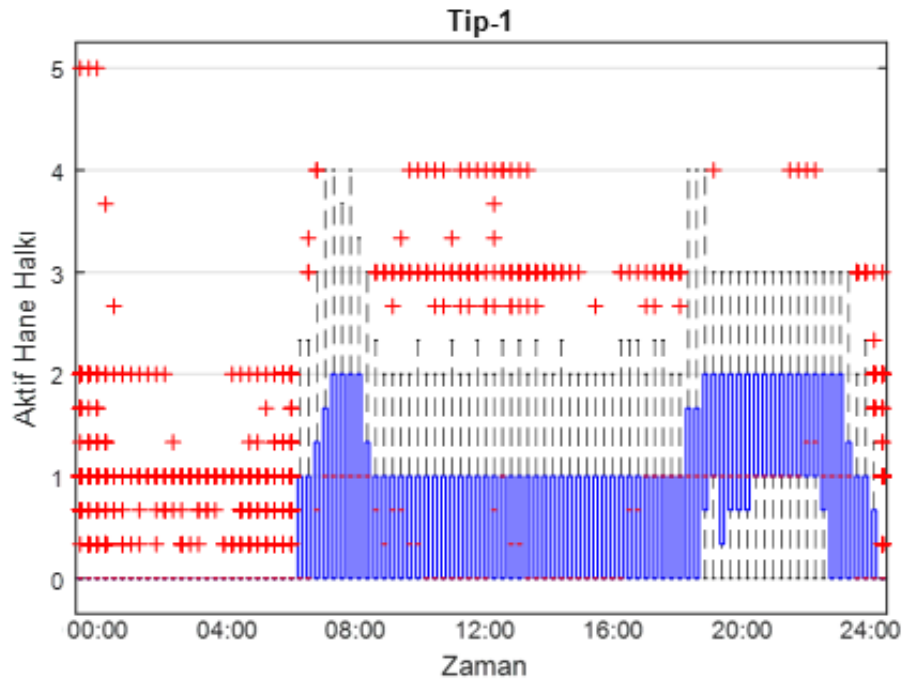
Şekil 4.2 Tip-2 için yük profillerinin sınıflandırılması



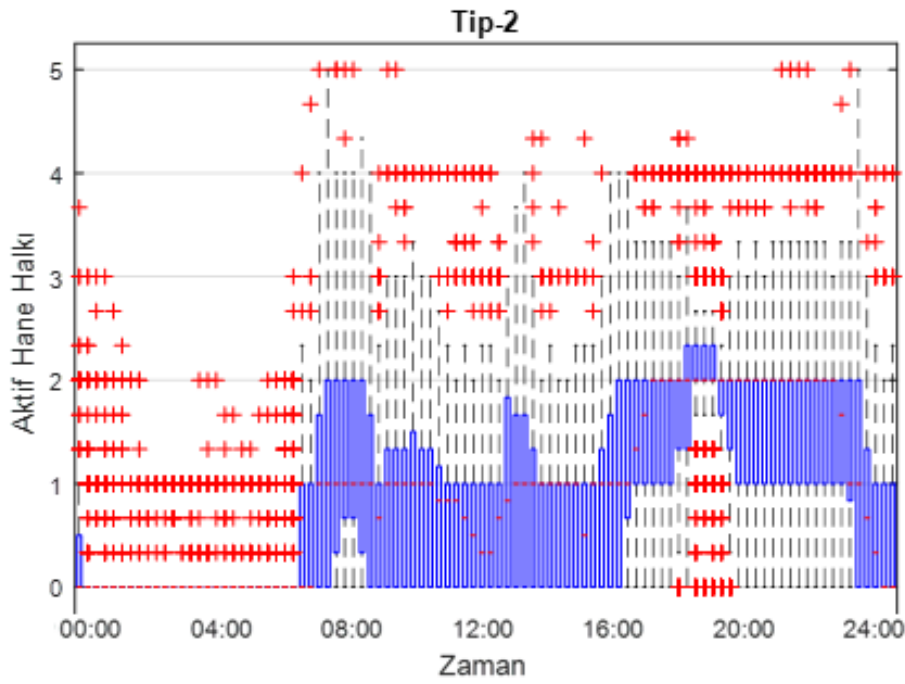
Şekil 4.3 Tip-3 için yük profillerinin sınıflandırılması




Şekil 4.4 Tip-4 için yük profillerinin sınıflandırılması



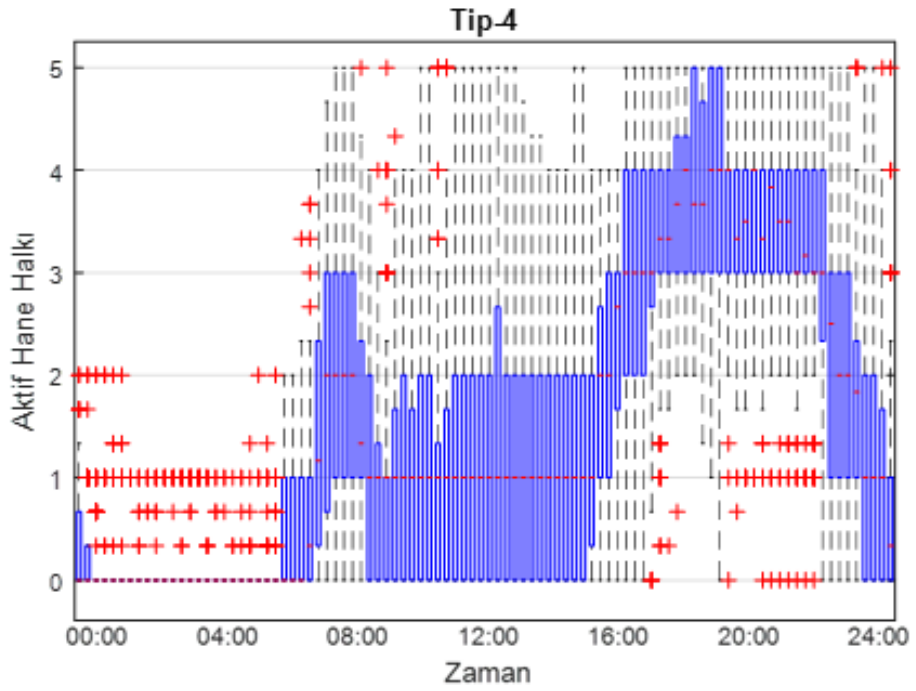
Şekil 4.5 Tip-1 için aktif hane halkı profillerinin sınıflandırılması




Şekil 4.6 Tip-2 için aktif hane halkı profillerinin sınıflandırılması



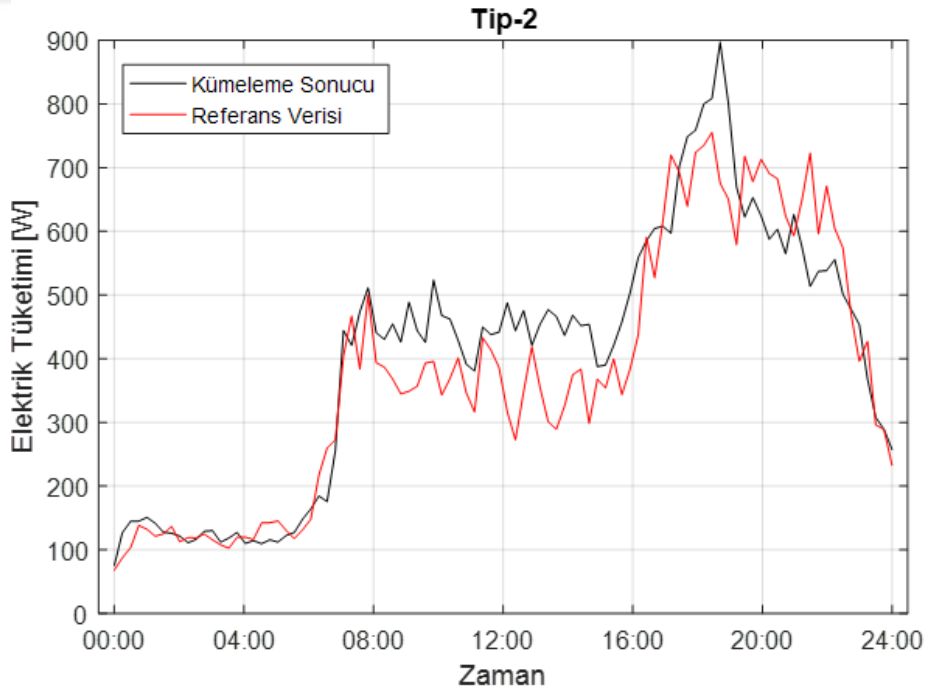
Şekil 4.7 Tip-3 için aktif hane halkı profillerinin sınıflandırılması



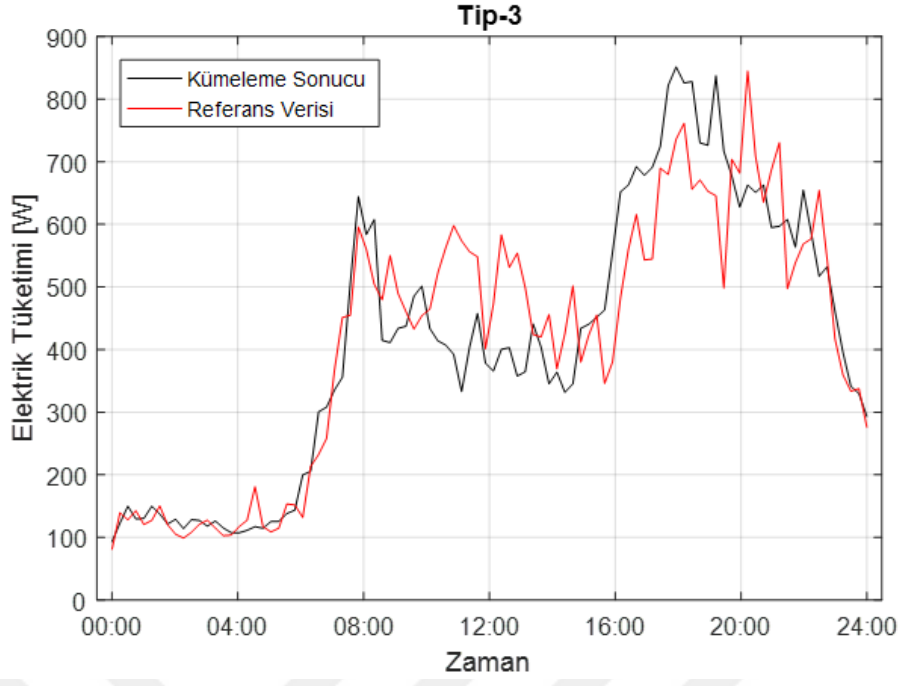
Şekil 4.8 Tip-4 için aktif hane halkı profillerinin sınıflandırılması




Şekil 4.9 Tip-1 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması




Şekil 4.10 Tip-2 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması



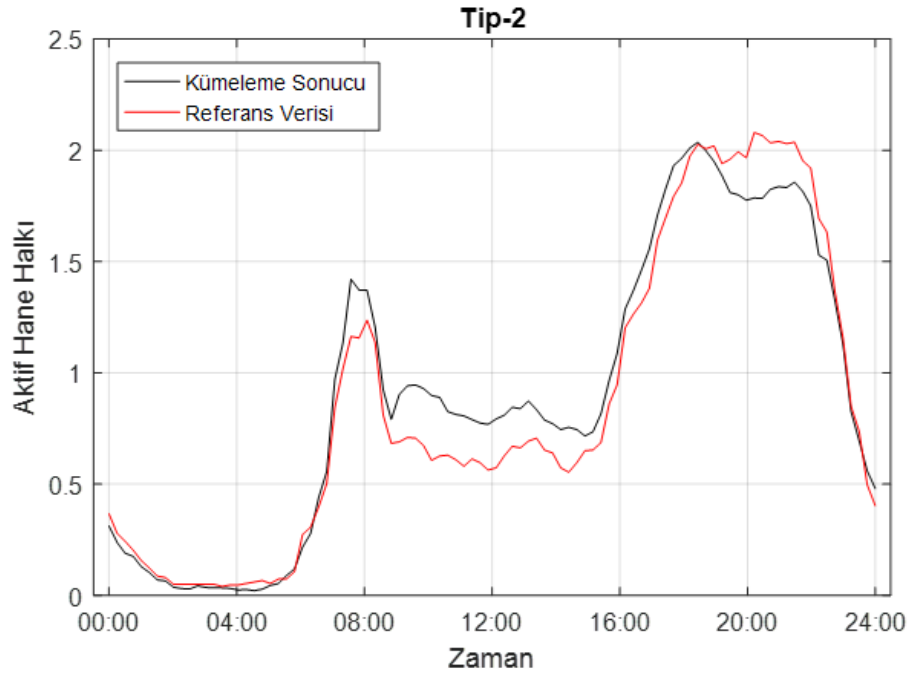
Şekil 4.11 Tip-3 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması




Şekil 4.12 Tip-4 için referans yük profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması




Şekil 4.13 Tip-1 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması



Şekil 4.14 Tip-2 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması



Şekil 4.15 Tip-3 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması



Şekil 4.16 Tip-4 için referans aktif hane halkı profil tipleri ile sınıfların ortalama verilerinin karşılaştırılması

4.2 Öneriler ve Gelecek Çalışmalar

Elektrikli araçların kullanımının yaygınlaşması ve kripto para madenciliği gibi değişen elektrik tüketim alışkanlıkları sonucu enerji ihtiyacı da artmıştır. Artan enerji ihtiyacıyla beraber ise mevcut tesislerdeki üretim yetersiz kalmış ve bu da yeni enerji üretim şekillerinin ortaya çıkmasına sebep olmuştur. Burada belirtildiği gibi artan enerji ihtiyacı, mevcut sistemlerdeki enerji üretiminin yetersiz kalması ve büyük miktarlardaki enerji kayıpları gibi sebeplerle klasik şebeke sistemlerinden akıllı şebeke sistemlerine geçiş ihtiyacı oluşmuştur. Akıllı şebeke sistemleri, güvenilirliği artıran ve güç üretimi ve dağıtımıyla ilgili maliyetleri azaltan bir dizi yeni teknoloji, kavram ve fikir sunar. Bu sistemler dağıtılmış yenilenebilir enerji üretimi, depolama ekipmanı ve elektrikli araçların toplu kullanımının entegrasyonunu sağlar ve bu da elektrik şebekesinin verimli çalışmasına daha fazla zorluk çıkarır [34]. Ayrıca, TC algoritmaları aracılığıyla elektrik tüketiminin optimizasyonuna son kullanıcıların da katılımı sağlanır.

Bir elektrik şebekesinde elektrik tüketimi ve üretimi her zaman dengede olmalıdır. Şebekede yaşanacak önemli bir dengesizlik, şebeke kararsızlığına veya ciddi voltaj dalgalanmalarına neden olabilir. Bunların sonucu olarak da şebeke içerisinde arızalar meydana gelebilir. Bu nedenle toplam üretim kapasitesi, bir miktar hata payı ve herhangi bir santralin devre dışı kalması gibi beklenmedik durumlar için tolerans ile toplam tepe talebine karşılık gelecek şekilde boyutlandırılır. Operatörler genellikle en ucuz üretim kapasitesini kullanmayı ve talep arttıkça daha pahalı tesislerden ek kapasite kullanmayı planlar. Çoğu durumda TC, potansiyel bozulma riskini azaltmak, ek tesisler için ek sermaye maliyeti gereksinimlerinden kaçınmak ve daha pahalı veya daha az verimli çalışan tesislerin kullanılmasından kaçınmak için tepe talebini düşürmeyi hedefler.

TC, tüketicilere zamana dayalı oranlara veya diğer finansal teşvik biçimlerine yanıt olarak yoğun dönemlerde elektrik kullanımlarını azaltarak veya değiştirerek elektrik şebekesinin işleyişinde önemli bir rol oynama fırsatı sağlar. TC programları, elektrik sistemi planlayıcıları ve operatörleri tarafından arz ve talebi dengelemek için kaynak seçenekleri olarak kullanılır. Bu programlarda kullanım süresi fiyatlandırması, kritik tepe fiyatlandırması, değişken tepe fiyatlandırması, gerçek zamanlı fiyatlandırma ve kritik tepe indirimleri gibi uygulamalar gerçekleştirilerek enerji tüketiminde verim elde edilmeye çalışılır. Tüketicilerin ve tüketici cihazların yoğun dönemlerde elektrik kullanıldığında yüksek maliyetlere sebep olacağından haberdar olması mümkün olursa, tüketicilerin ve işletmelerin yüksek talep dönemlerinde daha az elektrik tüketme eğiliminde olacağı düşünülmektedir. İşletmeler ve tüketiciler, yoğun olmayan zamanlarda enerji kullanmanın doğrudan bir ekonomik faydası olduğunu gördükleri

zaman teori başarılı olacak ve enerji kullanımı daha verimli hale gelecektir. Bu programlar aynı zamanda elektrik sağlayıcılarının, yoğun talepteki azalmalar ve yeni enerji santrallerinin ve enerji dağıtım sistemlerinin, özellikle de yoğun zamanlarda kullanılmak üzere ayrılanların inşasını erteleme yoluyla paradan tasarruf etmelerine yardımcı olma potansiyeline sahiptir.

TC'nin temel amacı, ekonomik teşvikler sağlayarak kullanıcıları yüksek güçlü cihaz kullanımlarını yoğun olmayan saatlere kaydırmaya teşvik etmektir [35]. Diğer bir ifadeyle belirtmek gerekirse TC programlarının amacı, tüketici fiyat sinyalleri veya kontrolleri aracılığıyla arz beklentilerini yansıtmak ve fiyata göre tüketimde dinamik değişiklikler sağlamaktır şeklinde tanımlanabilir [36]. Mevcut TC planları, konutların yanı sıra büyük ve küçük boyutlardaki ticari işletmelere de uygulanmaktadır. Kritik zaman dilimleri göz önünde bulundurularak ışıklandırma ve elektrikli cihazlar gibi işlevler azaltılır. Bu sayede yük talebi azaltılmış olur. Yük talebinin azaltılmasının diğer bir yolu da iş yerleri veya hanelerde alternatif yollar ile elektrik üretimi yapılmasıdır. Sıkı elektrik arzı koşulları altında tepe fiyatı ve genel elektrik fiyatı değişkenliği önemli ölçüde azaltılabilir.

Şebekelerdeki enerji tüketim verilerine bakıldığında iş yerleri ve sanayi kuruluşlarının yanı sıra evlerin de tüketimde ciddi derecede payı olduğu gözlemlenmiştir. Bu sebeple sadece yüksek enerji tüketimi sağlayan sanayi ve iş yerlerinin yanında evler için de enerji optimizasyonu ve tasarrufu kaçınılmaz olmuştur. Artan teknolojik imkanlar ve yaygınlaşan sensörlerle beraber evlerden toplanan veriler de hem miktar hem de çeşit olarak fazlalaşmıştır. Bunların yanında akıllı ev aletlerinden toplanan veriler de bizim için önemli kaynaklar sağlamaktadır.

TC uygulamalarında kritik noktalardan biri de izleme sistemleridir. Bu sistemler sayesinde elektrik tüketim verilerinde doğru ölçümler yapılır ve fiyatlandırma politikaları daha sağlıklı şekilde oluşturulabilir. İzleme sistemleri akıllı sayaçlar, gelişmiş ölçüm altyapısı, enerji yönetim sistemleri ve enerji bilgi sistemlerinden oluşmaktadır [37]. Yüksek fiyatlı birçok parçadan oluşan bu izleme sistemleri maddi olarak çok büyük bir yük getirisi manasına gelmektedir. Aynı zamanda bakım gerektiren bu cihazlar maddi yükün yanında zamansal ve fiziksel iş gücü kayıplarına da yol açmaktadır. Bu nedenle her haneye özel izleme sistemlerinin kurulması yerine kümeleme işlemleri tercih edilebilir.

İzleme sistemi verilerinin yanında tüketicilerle yapılan anketler kullanılarak elektrik tüketim alışkanlıkları ortaya çıkarılabilir ve bu alışkanlıklara uygun profiller elde edilebilir. Daha sonrasında bu verilere uygun olarak gerçekçi elektrik tüketim verileri elde edilebilir. Bu çalışmada da elektrik şebekesinden alınan gerçek veriler

kullanılmamış, onun yerine gerçekçi olarak elektrik tüketim verileri üreten bir araç kullanılmıştır. Bu gerçekçi veriler üretilirken en önemli noktalardan biri de hem günlük hem de mevsimsel olarak değişikliklerin göz önünde bulundurulmasıdır. Tüketim alışkanlıkları mevsimsel olarak büyük değişiklikler gösterir. Bunun yanında hafta içi ve hafta sonu da elektrik tüketim alışkanlıkları farklı olmaktadır. Bu çalışmada hafta içi elektrik tüketim verileri üretilmiş ve bu veriler kullanılarak bir kümeleme işlemi gerçekleştirilmiştir.

Çeşitli kaynaklardan toplanan veriler kullanılarak talep veya arz yönlü enerji yönetimi politikaları için kümeleme teknikleri geliştirilebilir. Bu sayede enerji piyasasının her bölümü için daha uygun elektrik tarifeleri elde edilebilir. Ayrıca son kullanıcılar, ekonomik tarifeler yoluyla tüketim modellerinde değişiklikler yapmaya teşvik edilebilir. Bu amaçla SBM ve ÖDHSA teknikleri ile iki aşamalı bir yaklaşım sağladık. Bu iki aşamalı yaklaşımla, veri kümesindeki profilleri karşılık gelen referans profillerle eşleştirmek için makul kümeleme başarısı elde edilmiştir. Bu sayede dar referans model setleri ile %90 eşleşme oranına ulaşılmıştır. Ayrıca referans modelleri ayrı ayrı ele alındığında başarı oranı %50 civarındadır. Şu gerçek de göz önünde bulundurulmalıdır ki her aile tipi için hane halkı sayısı bir kişi artırılarak veya azaltılarak referans kümeleri önemli ölçüde farklılaşmamaktadır. Bu nedenle dar kümeli referans modelleri türleri, profil dinamikleri yakın benzerliklere sahip olduğu için sorunu zorlaştırmaktadır.

Bu çalışmadaki önemli noktalardan biri de profillerin daha öncesinde bilinmesidir. Bu amaçla bir referans veri seti oluşturulmuş ve test amacıyla oluşturulan ana veri seti de bu referans veri setine uygun olacak şekilde kümelendirilmiştir. Referans veri setine sahip olmamız yani diğer bir şekilde belirtmek gerekirse profilleri bilmek bizim için kritik bir konudur. Akıllı şebeke sistemlerinde denetimsiz öğrenme algoritmaları ile haneleri kümelendirmek çok verimli sonuçlar vermemektedir. Ancak bu çalışmada olduğu gibi denetimsiz öğrenme algoritmaları, öncesinde referans verilerine uygun şekilde belirlenen çıktılarla beraber kümelendirme işlemi daha verimli sonuçlar vermektedir. Bunun sebebi de ana veri setinde ortaya çıkan kümelerin bizim için hangi hane tipine karşılık geldiğini bilmek ve ona göre TC programlarını şekillendirme ihtiyacıdır.

Gelecekteki çalışmalar için farklı YP türleri ele alınarak kümeleme işlemi gerçekleştirilebilir. Bu çalışmada haziran ayına ait hafta içi bir günün elektrik tüketim verileri oluşturularak bir çalışma yapılmıştır. Ancak ilerleyen çalışmalarda hafta içi ve hafta sonu tüketim verileri de dikkate alınarak bir çalışma yapılabilir. Hatta tüm yıla ait veriler alınabilir ve bu sayede hava sıcaklığı, yağış gibi mevsimsel etkenler de hesaba katılarak bir çalışma yapılabilir. Bu çalışmada her ne kadar gerçekçi veriler kullanılmış olsa da sonraki çalışmalarda direkt olarak akıllı şebeke sistemlerinde

bulunan gerek hanelerden elektrik tüketime verileri alınabilir ve bu verilerle bir alıřma yapılabilir. Bu sayede algoritmanın gerek hayattaki başarısı da görülebilir ve daha sonrasında algoritmada gerekli iyileřtirmeler yapılarak daha saėlıklı sonuçlara ulařılabilir. Tüm bunların yanı sıra, kümeleme analizi sonucu ortaya ıkan kümeleme verileri kullanarak ve analiz edilerek TC programı uygulamaları gerekleřtirilebilir. Bu uygulamaların gerek sistemlere uygulanması ve karřılařılabilecek muhtemel problemleri özöbilmek için gerekli algoritmik veya veri toplanması ve ön hazırlığı gibi işlemler sonraki alıřmalara bırakılmıřtır.

Gelecekteki alıřmalar sadece hanelerdeki YP'ler ile sınırlı kalmayabilir. İş yerleri ve sanayi kuruluşlarındaki YP'ler kullanarak da kümeleme işlemi yapılabilir. Bu sayede bu profiller için daha verimli TC programları oluşturulabilir. Tüm bunların yanı sıra ısıtma, havalandırma, iklimlendirme sistemi olan HVAC (heating ventilating and air conditioning) sistemlerinde de kümeleme işlemleri yapılarak daha verimli elektrik tüketimi sağlanabilir.

-
- [1] A. K. Jain, "Data clustering: 50 years beyond k-means," *Pattern recognition letters*, vol. 31, no. 8, pp. 651–666, 2010.
- [2] Z. Wang, T. Hong, "Generating realistic building electrical load profiles through the generative adversarial network (gan)," *Energy and Buildings*, vol. 224, p. 110 299, 2020.
- [3] F. McLoughlin, A. Duffy, M. Conlon, "A clustering approach to domestic electricity load profile characterisation using smart metering data," *Applied energy*, vol. 141, pp. 190–199, 2015.
- [4] J. Aghaei, M.-I. Alizadeh, "Demand response in smart electricity grids equipped with renewable energy sources: A review," *Renewable and Sustainable Energy Reviews*, vol. 18, pp. 64–72, 2013.
- [5] Z. Zakaria, K. Lo, "Two-stage fuzzy clustering approach for load profiling," in *2009 44th international universities power engineering conference (UPEC)*, IEEE, 2009, pp. 1–5.
- [6] L. Sun, K. Zhou, S. Yang, "An ensemble clustering based framework for household load profiling and driven factors identification," *Sustainable Cities and Society*, vol. 53, p. 101 958, 2020.
- [7] M. Espinoza, C. Joye, R. Belmans, B. De Moor, "Short-term load forecasting, profile identification, and customer segmentation: A methodology based on periodic time series," *IEEE Transactions on Power Systems*, vol. 20, no. 3, pp. 1622–1630, 2005.
- [8] D. Colley, N. Mahmoudi, D. Eghbal, T. K. Saha, "Queensland load profiling by using clustering techniques," in *2014 Australasian Universities Power Engineering Conference (AUPEC)*, IEEE, 2014, pp. 1–6.
- [9] K. A. Choksi, S. Jain, N. M. Pindoriya, "Feature based clustering technique for investigation of domestic load profiles and probabilistic variation assessment: Smart meter dataset," *Sustainable Energy, Grids and Networks*, vol. 22, p. 100 346, 2020.
- [10] J. N. Fidalgo, M. A. Matos, L. Ribeiro, "A new clustering algorithm for load profiling based on billing data," *Electric Power Systems Research*, vol. 82, no. 1, pp. 27–33, 2012.
- [11] Z. Ma, R. Yan, N. Nord, "A variation focused cluster analysis strategy to identify typical daily heating load profiles of higher education buildings," *Energy*, vol. 134, pp. 90–102, 2017.

- [12] C. M. R. do Carmo, T. H. Christensen, “Cluster analysis of residential heat load profiles and the role of technical and household characteristics,” *Energy and Buildings*, vol. 125, pp. 171–180, 2016.
- [13] M. Piao, H. S. Shon, J. Y. Lee, K. H. Ryu, “Subspace projection method based clustering analysis in load profiling,” *IEEE Transactions on Power Systems*, vol. 29, no. 6, pp. 2628–2635, 2014.
- [14] D. Vercamer, B. Steurtewagen, D. Van den Poel, F. Vermeulen, “Predicting consumer load profiles using commercial and open data,” *IEEE Transactions on Power Systems*, vol. 31, no. 5, pp. 3693–3701, 2015.
- [15] G. Klir, B. Yuan, *Fuzzy sets and fuzzy logic*. Prentice hall New Jersey, 1995, vol. 4.
- [16] K. O’Shea, R. Nash, “An introduction to convolutional neural networks,” *arXiv preprint arXiv:1511.08458*, 2015.
- [17] X. Zhu, A. B. Goldberg, “Introduction to semi-supervised learning,” *Synthesis lectures on artificial intelligence and machine learning*, vol. 3, no. 1, pp. 1–130, 2009.
- [18] R. S. Sutton, A. G. Barto, *Reinforcement learning: An introduction*. MIT press, 2018.
- [19] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*. MIT Press, 2016, <http://www.deeplearningbook.org>. (visited on 11/11/2021).
- [20] N. Kemaloglu, O. Sevli, “Evrimsel sinir ağı ile İşaret dili tanıma,” in *Proceedings on 2nd International Conference on Technology and Science*, 2019.
- [21] Y. Xiao, Y. Yin, “Hybrid lstm neural network for short-term traffic flow prediction,” *Information*, vol. 10, no. 3, p. 105, 2019.
- [22] I. Goodfellow *et al.*, “Generative adversarial networks,” *Communications of the ACM*, vol. 63, no. 11, pp. 139–144, 2020.
- [23] K. FIRILDAK, M. F. TALU, G. ÇELİK, “Transfer öğrenme ve çekişmeli üretici ağ yaklaşımlarını kullanarak cilt lezyonu sınıflandırma doğruluğunu iyileştirilmesi,” *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 32, no. 2, pp. 491–498, 2020.
- [24] T. Kohonen, “Self-organized formation of topologically correct feature maps,” *Biological cybernetics*, vol. 43, no. 1, pp. 59–69, 1982.
- [25] A. Oğuzlar, “Kümeleme analizinde yeni bir yaklaşım: Kendini düzenleyen haritalar (kohonen ağları),” *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, vol. 19, no. 2, pp. 93–107, 2005.
- [26] J. Vesanto, J. Himberg, E. Alhoniemi, J. Parhankangas, *et al.*, “Self-organizing map in matlab: The som toolbox,” in *Proceedings of the Matlab DSP conference*, vol. 99, 1999, pp. 16–17.
- [27] T. Kohonen, “Essentials of the self-organizing map,” *Neural networks*, vol. 37, pp. 52–65, 2013.
- [28] H. Y. Chang, J. A. Thomson, X. Chen, “Microarray analysis of stem cells and differentiation,” *Methods in enzymology*, vol. 420, pp. 225–254, 2006.
- [29] H. Wehrens, “Data mapping: Linear methods versus nonlinear techniques,” *Comprehensive Chemometrics*; 2, pp. 619–633, 2009.

- [30] I. Richardson, M. Thomson, D. Infield, C. Clifford, “Domestic electricity use: A high-resolution energy demand model,” *Energy and buildings*, vol. 42, no. 10, pp. 1878–1887, 2010.
- [31] R. Granell, C. J. Axon, D. C. Wallom, “Impacts of raw data temporal resolution using selected clustering methods on residential electricity load profiles,” *IEEE Transactions on Power Systems*, vol. 30, no. 6, pp. 3217–3224, 2014.
- [32] L. A. Zadeh, “Fuzzy sets,” in *Fuzzy sets, fuzzy logic, and fuzzy systems: selected papers by Lotfi A Zadeh*, World Scientific, 1996, pp. 394–432.
- [33] R. Xu, D. C. Wunsch, “Ii, clustering. hoboken,” *NJ: Wiley/IEEE Press*, vol. 6, pp. 583–617, 2009.
- [34] Y. Yamagata, H. Seya, S. Kuroda, “Smart community clustering for sharing local green energy,” in *2014 International Conference and Utility Exhibition on Green Energy for Sustainable Development (ICUE)*, IEEE, 2014, pp. 1–7.
- [35] P. Samadi, H. Mohsenian-Rad, V. W. Wong, R. Schober, “Tackling the load uncertainty challenges for energy consumption scheduling in smart grid,” *IEEE Transactions on Smart Grid*, vol. 4, no. 2, pp. 1007–1016, 2013.
- [36] O. A. Sianaki, O. Hussain, T. Dillon, A. R. Tabesh, “Intelligent decision support system for including consumers’ preferences in residential energy consumption in smart grid,” in *2010 Second International Conference on Computational Intelligence, Modelling and Simulation*, IEEE, 2010, pp. 154–159.
- [37] P. Siano, “Demand response and smart grids—a survey,” *Renewable and sustainable energy reviews*, vol. 30, pp. 461–478, 2014.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. U. B. Etlik, Y. Eren, “Two-stage clustering approach for the household electricity load profiles by fuzzy logic and neural network techniques,” Düzce Üniversitesi Bilim ve Teknoloji Dergisi, Publication phase, Approve date: Dec. 14, 2021.

