



**ÇOK BOYUTLU HİBRİT CNN-LSTM
MODELİ KULLANARAK ELEKTRİK
TÜKETİM VERİLERİNDEN TARİFE
GRUBU SINIFLANDIRMASI**

YÜKSEK LİSANS TEZİ

Zümera ÜSTÜNDAĞ

Danışman

Dr. Öğr. Üyesi Fatih SERTTAŞ

YENİLENEBİLİR ENERJİ SİSTEMLERİ

Aralık 2024

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

ÇOK BOYUTLU HİBRİT CNN-LSTM MODELİ KULLANARAK
ELEKTRİK TÜKETİMİ VERİLERİNDEN TARİFE GRUBU
SINIFLANDIRMASI

Zümerya ÜSTÜNDAĞ

Danışman

Dr. Öğr. Üyesi Fatih SERTTAŞ

YENİLENEBİLİR ENERJİ SİSTEMLERİ

Aralık 2024

TEZ ONAY SAYFASI

Zümyerya ÜSTÜNDAĞ tarafından hazırlanan “Tez Onay Sayfası” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 18/12/2024 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Yenilenebilir Enerji Sistemleri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Fatih SERTTAŞ

Başkan : Prof. Dr. Fatih Onur HOCAOĞLU
Afyon Kocatepe Üniversitesi, Müh. Fakültesi İmza

Üye : Doç. Dr. Emrah DOKUR
Bilecik Şeyh Edebali Üniversitesi, Müh. Fakültesi..... İmza

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....

Prof. Dr. Bekir YALÇIN

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

18/12/2024

İmza

Zümerya ÜSTÜNDAĞ

ÖZET
Yüksek Lisans Tezi

**ÇOK BOYUTLU HİBRİT CNN-LSTM MODELİ KULLANARAK ELEKTRİK
TÜKETİMİ VERİLERİNDEN TARİFE GRUBU TAHMİNİ**

Zümerya ÜSTÜNDAĞ
Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü
Yenilenebilir Enerji Sistemleri Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Fatih SERTTAŞ

Bu tez çalışmasında, elektrik tüketim verilerinden yola çıkarak tüketicilerin ait oldukları tarife grubunu tahmin eden bir model geliştirmeyi hedeflenmiştir. Akıllı şebekelerin yaygınlaşması sonucunda, enerji arz ve talebinin dengelenmesinde, maliyet etkinliğinin sağlanmasında ve tüketici davranışlarını yönlendirmede, şebeke unsurlarının doğru şekilde analiz edilmesi gerekmektedir. Bu analizler Talep Tarafı Yönetimi (DSM) gibi akıllı şebeke bileşenlerinin doğru çalışması hususunda önemlidir. Tezin başlangıç bölümlerinde enerji tüketiminin genel bir çerçevesi çizilmiş, modern toplumların ekonomik büyüme ve sürdürülebilir kalkınmasındaki önemi vurgulanmıştır. Çalışmada, yenilikçi bir yaklaşımla derin öğrenme yöntemleri ile tüketim verileri sınıflandırma yapmak amacı ile Konvolüsyonel Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) modelleri önerilmektedir. CNN sayesinde zaman serilerine iki boyutlu bakış açısı ile ilişkisel özellikler artırılmış, LSTM ile uzun dönemli bağımlılıkları öğrenme yeteneği sayesinde verinin zamansal özellikler çıkarılmıştır. İki yöntem bir araya getirilerek karmaşık zaman serisi verileri analiz edilmiştir. Bu hibrit model, elektrik tüketiminde farklı tarifeler arasındaki sınıflandırmayı daha hassas ve doğru bir şekilde yapabilmektedir.

Çalışmada kullanılan veri seti, Afyonkarahisar ilinden beş farklı tarife grubuna ait yıllık tüketim verilerini içermekte ve zamana bağlı olarak aktif, indüktif ve kapasitif tüketim ölçümlerini kapsamaktadır. Verilerin işlenmesi sürecinde, aykırı değerleri gidermek için z-skoru gibi istatistiksel teknikler ve eksik değerleri tamamlamak için lineer interpolasyon yöntemi kullanılarak zaman serileri belirli bir boyuta getirilmiştir. Önerilen

yöntem ile CNN-1D, LSTM gibi diğer derin öğrenme modelleri karşılaştırma yapıldığında önerilen modelin %87,83 eğitim, %82,37 test doğruluğu değerleri ile daha iyi sonuç verdiği çıkarılmıştır. Sonuç olarak, tezin bulguları, elektrik tüketimi verilerinden elde edilen sınıflandırmaların, kullanıcı davranışlarının analizinde ve tarife tahmininde yüksek doğruluk sağladığını ortaya koymuştur. Bu modelin, enerji dağıtım şirketlerinin müşteri segmentasyonu, talep tahmini ve talep tarafı yönetimi (DSM) gibi stratejik alanlarda kullanılabileceği ve akıllı şebeke uygulamalarına katkı sağlayabileceği belirtilmiştir. Tez, ayrıca, enerji planlamasının ve arz-talep dengesinin sürdürülebilir şekilde yönetilmesinde önemli bir araç olarak değerlendirilmektedir.

2024, xi + 58 sayfa

Anahtar Kelimeler: Elektrik Tüketim Tarifeleri, Zaman Serisi Analizi, CNN, LSTM, Sınıflandırma.

ABSTRACT
M.Sc. Thesis

**TARIFF CLASSIFICATION WITH MULTI-DIMENSIONAL DEEP LEARNING
USING TIME SERIES LOAD DATA**

Zümerya ÜSTÜNDAĞ

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Renewable Energy Systems

Supervisor: Asst. Prof Fatih SERTTAŞ

In this research, it is aimed to develop a novel model that predicts the tariff group of consumers, based on electricity consumption data. After becoming widespread of Smart Grids, network elements need to be analyzed correctly in balancing energy supply and demand, ensuring cost efficiency and managing consumer behavior. These analyzes is very important for the correct operation of smart grids components such as Demand Side Management (DSM). In the initial chapters of the thesis, a general framework of energy consumption is drawn and its importance in the economic growth and sustainable development of modern societies is emphasized. In this study, a novel Convolutional Neural Networks (CNN) and Long-Short Term Memory (LSTM) model is proposed to classify electricity consumption data with deep learning methods. Relational features have been increased by CNN with 2D perspective on time series data and temporal features have been extracted by LSTM talent that is learning long term independence. Complex time series data is analyzed by combining two methods. This hybrid model can classify the tariff in electricity consumption more precisely and accurately.

The data set used in this study includes annual consumption data of 5 different tariff groups of Afyonkarahisar province and includes active, inductive and capacitive measurements. During the data pre-processing, statistical methods such as z-score were applied to eliminate anomalies. These values and the missing values in data were determined by linear interpolation. So, time series are set on a same size. When the proposed model was compared with other deep learning models such as CNN-1D, LSTM, it was observed that the proposed model has better results with %87,83 training accuracy

and %82,37 test accuracy. As a result, the findings of the thesis revealed that the classifications obtained from electricity consumption data provide high accuracy in the analysis of user behavior and tariff prediction. It has been stated that, this model can be used in strategic fields such as consumers segmentation, demand forecasting and demand side management of energy distribution companies and can contribute smart grids applications. The thesis is also considered an important tool in sustainable management of energy planning and supply-demand balance.

2024, xi + 58 pages

Keywords: Electricity Load Tariffs, Time Series Analysis, CNN, LSTM, Classification

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Fatih SERTTAŞ'a her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteğini benden esirgemeyen sevgili eşim Emrah ÜSTÜNDAĞ'a teşekkür ederim.

Zümera ÜSTÜNDAĞ

Afyonkarahisar 2024

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ	1
2. ELEKTRİK PİYASASINDA TARİFELER	3
3. PROBLEMİN ANALİZİ	5
3.1. Usulsüz Elektrik	5
3.2. Otomatik Sayaç Okuma Sistemi (OSOS)	6
3.3. Elektrik Enerjisinde Aktif-Reaktif Enerji	8
4. MATERYAL METOT	10
4.1. Zaman Serilerinin Sınıflandırılması	15
4.2. Derin Öğrenme	18
4.2.1. Uzun Kısa Süreli Bellek (LSTM)	19
4.2.2. Konvolüsyonel Sinir Ağları (CNN)	24
4.3. Sınıflandırma Değerlendirme Kriterleri	28
4.3.1. Karışıklık Matrisi (Confusion Matrix)	28
4.3.2. Doğruluk (Accuracy)	29
4.3.3. Kesinlik (Precision)	29
4.3.4. Duyarlılık (Recall) veya Hassasiyet (Sensitivity)	29
4.3.5. F1 Skoru	30
4.3.6. ROC Eğrisi ve AUC (Area Under Curve)	30
4.3.7. Özgüllük (Specificity)	31
4.3.8. Log-Kayıp (Logarithmic Loss veya Log-Loss)	31
4.3.9. Cohen's Kappa Katsayısı	31
4.4. Verinin Hazırlanışı	32
4.5. Önerilen Model	42
5. TARTIŞMA ve SONUÇ	48



SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

P	Aktif güç
S	Görünür güç
Q	Reaktif güç
σ	Sigmoid fonksiyonu
z	Standart değer
x	Gözlemlenen değer
μ	Örneklemin ortalaması
σ	Örneklemin standart sapması

Kısaltmalar

ANN	Yapay Sinir Ağları (Artificial Neural Network)
AUC	Area Under Curve
CNN	Konvolüsyonel Sinir Ağları (Convolutional Neural Networkten)
DBSCAN	Gürültülü Uygulamaların Yoğunluk Tabanlı Mekansal Kümelemesi (Desty-Based Spatial Clustering of Applications With Noise)
DSM	Talep Tarafı Yönetimi (Demand Side Managment)
EEG	Elektroensefalografi
EPDK	Enerji Piyassası Denetleme Kurumu
FCN	Fully Convolutional Networks
GA	Genetik Algoritma
GSM	Global System for Mobile Communications
GPRS	General Packet Radio Service
GPU	Graphics Processing Unit
KNN	K-En Yakın Komşu (K-Nearest Neighbor)
LSTM	Uzun Kısa Süreli Bellek (Long Short Term Memory)
MACNN	Multi-stage Attention Convolutional Neural Networks
NPL	Doğal Dil İşleme (Neuro Linguistic Programming)
RGB	Red Green Blue
PLS	Programlanabilir Mantıksal Denetleyici (Programmable Logic Controller)
ReLU	Rectified Linear Unit
ROC	Receiver Operating Characteristic
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SVM	Destek Vektör Makinesi (Support Vector Machine)
SVR	Destek Vektör Regresyonu (Support Vektor Regression)
OSOS	Otomatik Sayaç Okuma Sistemi
TEDAŞ	Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Güç faktörü	9
Şekil 4.1 İçme suyu sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi	10
Şekil 4.2 İçme suyu sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi	11
Şekil 4.3 Mesken sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi	11
Şekil 4.4 Mesken sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi	12
Şekil 4.5 Sanayi sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi	12
Şekil 4.6 Sanayi sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi	13
Şekil 4.7 Tarımsal sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi	13
Şekil 4.8 Tarımsal sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi	14
Şekil 4.9 Ticarethane sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi.	14
Şekil 4.10 Ticarethane sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi	15
Şekil 4.11 Zaman serisi sınıflandırma blok diyagramı	16
Şekil 4.12 LSTM Modeli	20
Şekil 4.13 LSTM Modeli Hücre Bilgisi Aktarımı.....	20

Şekil 4.14 LSTM Unutma Kapısı.....	21
Şekil 4.15 LSTM Giriş Kapısı.....	22
Şekil 4.16 LSTM Hücre Durumunun Güncellenmesi	23
Şekil 4.17 LSTM Gizli Durum Bilgisi Güncelleme ve Çıkış Kapısı	23
Şekil 4.18 CNN Modeli.....	25
Şekil 4.19 CNN Filtreleme İşlemi.....	26
Şekil 4.20 İçme suyu sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi	34
Şekil 4.21 Mesken sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi	34
Şekil 4.22 Sanayi sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi	35
Şekil 4.23 Tarımsal sulama sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi.....	35
Şekil 4.24 Ticarethane sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi	36
Şekil 4.25 Sınıfların dağılımı	36
Şekil 4.26 Mesken tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB)).....	37
Şekil 4.27 İçme suyu tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB)).....	38
Şekil 4.28 Sanayi tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))	39
Şekil 4.29 Ticari tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))	39

Şekil 4.30 Tarımsal tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB)).....	40
Şekil 4.31 İçme suyu sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri	40
Şekil 4.32 Mesken sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri	41
Şekil 4.33 Sanayi sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri	41
Şekil 4.34 Tarımsal sulama sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri.....	41
Şekil 4.35 Ticarethane sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri	42
Şekil 4.36 Önerilen modelin blok diyagramı	43
Şekil 4.37 İçme suyu aktivasyon Haritası	44
Şekil 4.38 Mesken aktivasyon haritası	45
Şekil 4.39 Sanayi aktivasyon haritası.....	45
Şekil 4.40 Tarımsal aktivasyon haritası	46
Şekil 4.41 Karışıklık matrisi.....	46
Şekil 5.1 Model Özeti.....	48

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Kullanım Alanına Göre Vergi ve Fonlar Dahil Elektrik Birim Fiyatları (Eylül 2024).....	4
Çizelge 4.1 Sınıflara göre aktif tüketimin istatistikleri (min.-ort.-maks.).....	33
Çizelge 5.1 Farklı modellerin 25 tur eğitim sonucu doğruluk değerleri karşılaştırması	49



1. GİRİŞ

Enerji tüketimi, modern toplumların sürdürülebilir kalkınması ve ekonomik büyümesi için hayati öneme sahiptir. Gittikçe büyüyen dünya ve ekonomi altyapısında enerji tüketimi talebi de artmaktadır. Bu kapsamda yük tahmini uygulamaları talebin tahmin edilerek sistemlerin daha doğru yönetilmesi hususunda önemlidir (Singh 2001, Amyady 2002). Konvansiyonel enerji kaynaklarının yerini yenilenebilir enerji kaynaklarına bırakması ve bu kaynakların dağıtım seviyesinde dağıtık şekilde konumlandırılması sonucunda Akıllı Şebeke kavramları ortaya çıkmakta hem üretim hem de tüketim tarafında tahmin uygulamalarının başarısı talep tarafı yönetimini doğrudan etkilemektedir (TSKB 2021). Farklı tüketici gruplarına yönelik çeşitli elektrik tarifeleri, elektrik enerjisinin fiyatlandırılmasında tüketim alışkanlıkları, kullanım süreleri ve bölgesel farklılıklar gibi faktörler dikkate alınarak düzenlenir. Bu kapsamda elektrik tarifeleri, enerji arz ve talep dengesinin korunması, enerji verimliliğinin teşvik edilmesi ve elektrik piyasalarının sürdürülebilir şekilde işlemesi açısından da önemli bir role sahiptir.

Üretim kaynaklarından nihai tüketicilere enerjinin ulaştırılması ülke içerisinde belirli kurum ve kuruluşlar tarafından yapılmaktadır. Ülkemizde enerjinin yüksek gerilim çıkışlı üretim kaynaklarından orta gerilim seviyesinde dağıtım sistemine iletimi Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) tarafından, dağıtım seviyesinden nihai kullanıcılara elektriğin dağıtılması Türkiye Elektrik Dağıtım Anonim Şirketi (TEDAŞ)' ne bağlı olarak 21 dağıtım bölgesinde özel şirketler tarafından yapılmaktadır (İnt. Kyn. 1).

Elektrik tarifeleri, hem elektrik üretim ve dağıtım süreçlerinin maliyet etkinliğini sağlamak hem de tüketicilerin enerji kullanımını düzenlemek için kullanılan bir fiyatlandırma mekanizması olarak enerji piyasalarında önemli bir yere sahip olup, enerji tüketicileri ile enerji üreticileri arasındaki ekonomik ilişkiyi belirleyen kritik bir unsurdur.

Türkiye'de elektrik enerjisi tüketimi için uygulanan tarifeler, tüketici gruplarının enerji ihtiyaçları ve kullanım alışkanlıklarına göre çeşitlenmiştir. Elektrik tarifelerinin belirlenmesi, düzenlenmesi ve denetlenmesi süreçleri ise Enerji Piyasası Düzenleme Kurumu (EPDK) tarafından gerçekleştirilir (İnt. Kyn. 2). EPDK, Türkiye'de enerji piyasasının düzenleyici kurumu olarak, enerji arz güvenliği, şeffaflık, rekabet ve tüketici haklarının korunması gibi temel ilkeler çerçevesinde faaliyet gösterir. Elektrik

piyasaının düzenlenmesi ve denetlenmesi, Elektrik Piyasası Kanunu ve bu kanuna dayalı olarak çıkarılan çeşitli yönetmeliklerle yürütülür. EPDK, piyasa katılımcılarının uyum sağlaması gereken kuralları belirleyerek, tarifelerin adil ve şeffaf bir şekilde uygulanmasını sağlar. Bu hususların düzenlenmesi ve yürütülmesini sağlayan ilgili yönetmelikler Elektrik Piyasası Tarifeler Yönetmeliği, Elektrik Piyasası Serbest Tüketici Yönetmeliği, Dağıtım ve Perakende Satış Faaliyetlerinin Düzenlenmesi Hakkında Yönetmelik şeklindedir.

TEDAŞ 2023 yılı elektrik dağıtım sektör raporuna göre 2022 yılında ülkemizde enerji tüketiminin %21,5'i konutlar oluştururken, %46,5'i sanayi alanında kullanılmaktadır. Aynı rapora göre dünyada 2021 yılı toplam elektrik tüketiminin %26,9'u konutlarda kullanılırken %42,6'sı sanayide kullanılmıştır. 2022 yılında ülkemizde toplam 287 TWh'lık elektrik tüketimi yaşanmıştır (TEDAŞ 2024). Tüketicilerin kullanım miktarlarına göre farklılaşan tarifeler hem enerji maliyetlerinin hem de tüketici davranışlarının yönetilmesinde etkili bir araç olarak kullanılmaktadır. Ayrıca, yenilenebilir enerji kaynaklarının entegrasyonu ve enerji geçiş süreci, elektrik tarifelerinde yenilikçi yaklaşımları da beraberinde getirmiştir.

Türkiye'de uygulanan elektrik tarifeleri, enerji verimliliği ve enerji piyasalarının liberalleşmesi gibi temel enerji politikalarıyla doğrudan ilişkilidir. Örneğin, serbest tüketici uygulaması, piyasada rekabeti artırarak tüketicilere daha uygun fiyat seçenekleri sunmayı hedefler. Aynı zamanda, üç zamanlı tarifeler gibi uygulamalar, elektrik talebinin yoğun olduğu saatlerde tüketimi azaltmayı teşvik ederek, şebeke üzerindeki yükü dengeler ve enerji arz güvenliğini destekler.

Bu tez kapsamında elektrik tüketimi verilerinden yararlanarak, kullanıcıların hangi tarife grubuna ait olduğunu tahmin etmek için bir yöntem önerilmektedir. Bu yöntem, tüketim kalıplarını analiz ederek, kullanıcıların hangi tarife aralığında olabileceğine ilişkin tahminlerde bulunmaktadır. Önerilen yöntemin, enerji sektöründe kullanıcı davranışlarının ve tarife gruplarının analizinde yeni bir perspektif sunabileceği düşünülmektedir. Bu sonuçlar, enerji şirketlerinin müşteri segmentasyonu ve talep tahmini gibi stratejik karar alma süreçlerinde değerli bir araç olabilir.

2. ELEKTRİK PİYASASINDA TARİFELER

Türkiye'de elektrik tarifeleri, farklı tüketici gruplarına yönelik olarak çeşitli kategorilerde sunulmaktadır. Günün her saatinde aynı birim fiyatı uygulayan tek zamanlı tarife gündüz, puant (yoğun saatler) ve gece olmak üzere günü üç ayrı zaman dilimine bölerek her zaman dilimine farklı birim fiyat uygulayan üç zamanlı tarife, gün içi kullanım aralığına bağlı kullanıcıların seçebileceği tarifelerdir. Tüketiciler, enerji tüketimlerini düşük fiyatlı saat dilimlerine kaydırarak enerji maliyetlerini optimize edebilirler. Belirli bir elektrik tüketimini aşarak elektrik tedarikçisini kendisi seçme hakkına sahip olan serbest tüketiciler tarifesi gibi farklı tarifeler bulunmaktadır. Bunların yanında elektrik tüketiminde tüketicilerin faaliyet alanına göre belirlenen tarifeler de mevcuttur. Sanayi, ticarethane, mesken, tarımsal sulama ve aydınlatma gibi farklı kullanıma uygun tarifeler bulunur (EPDK 2015, İnt. Kyn. 3). Konut kullanıcıları için genellikle sabit bir fiyat politikası izlenirken, ticarethane ve sanayi kullanıcıları için üç zamanlı tarifeler veya özelleşmiş tarifeler daha yaygın olarak tercih edilmektedir. Çizelge 2.1’de 2024 yılındaki kullanım alanına göre vergi ve fonlar dahil elektrik birim fiyatları görülmektedir.

Konuya ilişkin uluslararası literatür incelendiğinde, çok çeşitli ülkelerde elektrik piyasasında günlük fiyat değişimlerinin yaşandığı görülmektedir. Bunun yanı sıra, çevre koruma amaçlı tüketicileri yönlendirici elektrik tarifeleri de bulunmaktadır (Bevk vd. 2013, Grzanic vd. 2021, Cejka vd. 2021). Nakai vd. (2024) Almanya ve Japonya’da ev halkının bu ekseninde elektrik tarifesi seçenekleri hakkında anket çalışması yapmış, elektrik tarifelerinin gün içinde değişimlerine (dinamik elektrik tarifesi) karşı isteksiz oldukları ancak çevre korunması amacı ile tasarlanan tarifelere daha kayıtlı olduklarını belirtmektedir. Lee (2024) Bayesian optimizasyon tekniği ile enerji tüketim değerine göre en uygun tarifenin belirlenmesini sağlamıştır. Diğer bir çalışmada Almanya konut abonelerinin dinamik elektrik tarifeleri seçiminde yenilenebilir enerji sistemlerinin entegrasyonu amacı ile %74 civarında gerçekleştirilebileceğini belirtilmiştir. Ancak bu işlemin dağıtım şebekesinde ilave yatırımlar gerektirdiği sonucuna varılmıştır (Stute J., Klobasa M 2024). Birçok çalışmada da enerji arz-talep dengesi elektrik tariflerinin kontrol edilmesi ile sağlanmıştır (Tao vd. 2020, Chen vd. 2021, Théatec vd. 2023).

Çizelge 2.1 Kullanım Alanına Göre Vergi ve Fonlar Dahil Elektrik Birim Fiyatları (Eylül 2024)

Tarife Tipi	Aktif Enerji (TL/kWh)	Dağıtım Bedeli (TL/kWh)	KDV	Tüm Vergi ve Fonlar Dahil Son Fiyat (TL/kWh)
Konut (240 kWh tüketime kadar)	0,494065	1,365179	0,08	2,00798352
Konut (240 kWh tüketimden sonra)	1,391181	1,365179	0,08	2,9768688
Ticarethane (900 kWh tüketime kadar)	2,463661	1,395844	0,18	4,5542159
Ticarethane (900 kWh üstü tüketim)	3,068350	1,395844	0,18	5,26774892
Sanayi	2,675627	1,029981	0,18	4,37261744
Şehit Aileleri ve Muharip Malul Gaziler	0,061590	0,828453	0,18	1,05025074
Tarımsal Sulama	1,950087	1,146937	0,08	3,34478592
Genel Aydınlatma	3,890440	0,841099	0,08	5,11006212

*Tüm değerler tek zamanlı tarifeler üzerinden hazırlanmıştır.

Kullanım amaçlarına göre elektrik tarifeleri fiyatlandırılması ülkemizde; mesken, ticarethane, sanayi, tarımsal sulama, şehit aileleri ve muharip malul gaziler ve genel aydınlatma gibi tüketim amaçlarına göre farklı kategorilerde değerlendirilerek belirlenir (Ceylan 2004, EPDK 2015). EPDK tarafından yayımlanan elektrik tarifeleri tablosundan alınan verilere göre farklı tarifelere farkı ücretlendirmeler yapıldığı görülmektedir. Konut, Ticarethane, Sanayi ve Tarımsal sulama tarifeleri kullanım yerinin amacına göre belirlenmektedir. Şehit Aileleri ve Muharip Malul Gaziler tarifesi, kullanıcının kullanım amacının yanında ekstra indirim sağlanması amacı ile bu özelliğe sahip olması sonucu etiketlenir. İçme suyu abone grubuna sahip kullanıcıların fiyatlandırması mesken tarifesinden yapılmaktadır.

Enerji yönetim sistemlerinde tarife dendiğinde EPDK tarafından sektör bazında farklı tanımlamalar yapılmış olsa da bu çalışma kapsamında incelenecek tarifeler dağıtım sektörü bazında belirlenmiş en çok tercih edilen kullanım amacı ekseninde belirlenen mesken, ticarethane, sanayi, içme suyu, tarımsal sulama tarifeleridir. Genel aydınlatma abone grubunda tüketim şekli standart olması ve kullanıcı sayısı bakımından diğer gruplara göre daha az örnek içermesinden dolayı bu gruba ait aboneler çalışmaya dahil edilmemiştir. Böylelikle kullanılacak modellerde hesaplama maliyeti de daha az olacaktır.

3. PROBLEMİN ANALİZİ

Farklı tarife gruplarına ait elektrik tüketim verilerden özellik çıkarılarak hangi tarife grubuna ait olduğu bulunabilir mi? sorusundan yola çıkılarak bu sorunun cevabının bulunması ile tarifesine uygun olmayan aboneliklerin kolay ve hatasız şekilde tespit edilebilmesi amaçlanmıştır. Tarifenin kullanım amacı dışında elektrik kullanımı Tüketici Hizmetleri Yönetmeliği'ne göre “Usulsüz Elektrik” şeklinde tabir edilmektedir ve tespiti halinde yaptırımlar uygulanabilmektedir. Çalışma kapsamında elektrik sayaçlarından elde edilen yıllık tüketim verileri, uzaktan okuma aracı olan OSOS (Otomatik Sayaç Okuma Sistemi) aracılığı ile toplanarak sınıflandırma problemi olarak ele alınmıştır.

3.1. Usulsüz Elektrik

Türkiye elektrik dağıtım sektöründe Tüketici Hizmetleri Yönetmeliği'ne göre dağıtım şirketine kayıtlı tarife dışında elektrik tüketimi “Usulsüz Elektrik” tüketimi kapsamına girmekte, bu kullanıcıların tespiti empirik veya fiziksel olarak yapılabilmektedir. Usulsüz elektrik kullanımı, elektrik enerjisinin yasal düzenlemelere ve sözleşmelere aykırı bir şekilde tüketilmesi durumunu ifade eder. Bu, elektrik piyasalarında büyük bir sorun olup hem enerji dağıtım şirketleri hem de yasal düzenleyici kurumlar için önemli kayıplara ve sorunlara yol açmaktadır. Usulsüz kullanım, sadece mali kayıplara neden olmakla kalmaz, aynı zamanda planlamaları ve elektrik şebekesi üzerinde uygulanacak yönetim sistemlerini de olumsuz etkileyecektir. Ayrıca elektrik altyapısında teknik dengesizliklere yol açabilir ve şebeke üzerinde aşırı yüklenmelere sebep olabilir. Bu durum, elektrik kesintilerine ve şebeke arızalarına neden olabilir.

Ek olarak, usulsüz elektrik kullanımı, enerji tüketiminin doğru bir şekilde ölçülmesini engelleyerek enerji planlamasını ve arz-talep dengesini olumsuz etkiler. Bu, özellikle enerji üretim ve dağıtım planlaması yapan kurumlar için zorluklar yaratabilir ve tüketiciler arasında adaletsizliğe yol açabilir.

Usulsüz elektrik kullanımının önlenmesi amacıyla çeşitli yasal düzenlemeler yürürlüğe konulmuştur (EPDK 2018, İnt.Kyn. 4). Bu düzenlemeler, EPDK tarafından belirlenen ve

elektrik dağıtım şirketlerinin uyguladığı yaptırımları içerir. Usulsüz elektrik kullanımı tespit edildiğinde, bu kullanıma yönelik cezai yaptırımlar ve idari para cezaları uygulanmaktadır. Bu süreç, Elektrik Piyasası Kanunu ve ilgili yönetmeliklere dayanmaktadır.

EPDK, usulsüz kullanım tespit edildiğinde elektrik hizmetinin kesilmesi, idari para cezaları ve geriye dönük faturalandırma gibi önlemler alabilir. Kaçak kullanımın tespiti durumunda, kullanıcının haksız kazancı belirlenerek geçmiş döneme yönelik faturalandırma yapılır. Ayrıca, kaçak kullanımın sistemde yaratacağı kayıpların azaltılması için, kaçak tespiti ve önlemleri konusunda teknoloji kullanımı teşvik edilmektedir. Akıllı sayaçlar ve uzaktan izleme sistemleri, kaçak elektrik kullanımını tespit etmede etkili araçlar olarak kullanılmaktadır.

3.2. Otomatik Sayaç Okuma Sistemi (OSOS)

Elektrik sayaçları, tükettiğimiz ya da kullandığımız elektrik enerji miktarını görmemizi sağlayan ve harcanan enerji miktarını bize doğrudan kWh ya da MWh olarak gösteren elektrikli bir ölçü aletidir . Elektronik Sayaç veya Akıllı Sayaç diye tanımlanan sayaçlar ise genel olarak çoklu tarifeye uygun olan sayaçlardır (Kocaman 2012). Akıllı sayaçlar Otomatik Sayaç Okuma Sistemi (OSOS) ile dağıtım şirketlerinin elektrik tüketimini anlık olarak izleyebilmelerine ve tüketici verilerini merkezi bir sisteme otomatik olarak aktarabilmelerine olanak tanır. Bu, dağıtım şirketleri için operasyonel verimliliği artırırken, enerji kayıplarını azaltmak ve tüketici memnuniyetini sağlamak açısından da önemli faydalar sunar.

OSOS, dijital sayaçlar, veri toplama sistemleri ve iletişim altyapısı gibi temel bileşenlerden oluşur. Elektrik tüketimini ölçen dijital sayaçlar, tüketilen enerjiyi belirli zaman dilimlerinde kaydeder. Bu sayaçlar, tüketim miktarını ve sayaç üzerindeki diğer verileri kaydeder ve saklar. Sayaçlardan alınan veriler, çeşitli iletişim teknolojileri kullanılarak (örneğin, GSM, GPRS, PLC - Güç Hatları İletişimi, radyo frekansı) merkezi veri toplama sistemine iletilir. Bu veri iletişimi sayesinde sayaçların manuel olarak okunmasına gerek kalmadan otomatik veri aktarımı sağlanır. OSOS ile toplanan veriler,

merkezi bir veri tabanında saklanır ve işlenir. Bu veriler, elektrik dağıtım şirketleri tarafından analiz edilerek faturalandırma süreçlerine ve enerji yönetimine dahil edilir.

Türkiye'de OSOS kullanımı, EPDK tarafından düzenlenmekte ve denetlenmektedir. EPDK, 2012 yılında yaptığı düzenlemelerle, belirli bir tüketim miktarını aşan kullanıcılar için OSOS sisteminin kullanılmasını zorunlu hale getirmiştir (EPDK 2011). Bazı dağıtım firmaları son yıllarda izlenebilirlik kapsamında belli bir tüketim miktarını aşan kullanıcıların yanında diğer kullanıcılarda da OSOS kullanılmasına yönelik çalışmalar yapmıştır. Bu düzenleme, elektrik dağıtım şirketlerinin sayaç okuma süreçlerini dijitalleştirerek operasyonel verimliliği artırmayı ve enerji kayıplarını azaltmayı hedeflemektedir.

OSOS'un sağladığı avantajlar incelenecek olursa, dağıtım şirketlerine tüketicilerin enerji kullanım verilerini anlık ve doğru bir şekilde toplama, kullanarak kaçak veya usulsüz elektrik kullanımlarını daha hızlı ve etkin bir şekilde tespit ederek anlık veri akışı sayesinde, tüketim miktarlarında beklenmeyen artışlar veya anormal dalgalanmaların hızla tespiti ile enerji kayıplarının kontrol altına alınması, faturalandırma süreçlerini daha şeffaf ve sayaçlardan otomatik olarak alınan verilerle tüketim miktarları net bir şekilde hesaplama ve tüketicilere doğru faturalandırma yapılması gibi kolaylıklar sağlar. Geleneksel yöntemlerde sayaçların manuel olarak okunması, zaman ve insan kaynağı gerektiren bir süreçtir. OSOS ile bu süreçler otomatik hale gelerek sayaçların düzenli bir şekilde okunması sağlanır. Bu durum, operasyonel maliyetlerin azalmasına ve verimliliğin artmasına katkıda bulunur. Bu sistem ile toplanan veriler, dağıtım şirketlerinin enerji arz ve talep dengesini daha etkili bir şekilde yönetmesine yardımcı olur. Tüketicilerin hangi saatlerde daha fazla enerji tükettiği, hangi bölgelerde yoğun tüketim olduğu gibi veriler analiz edilerek enerji dağıtımı optimize edilebilir. Bu, şebekenin aşırı yüklenmesini önleyerek enerji arz güvenliğini artırır. Dağıtım şirketleri, OSOS aracılığıyla tüketicilere daha iyi hizmet sunabilir. Örneğin, tüketicilerin yüksek enerji tüketimi durumunda bilgilendirilmesi, tüketimlerini optimize etmelerine yardımcı olabilir. Ayrıca, aboneler kendi tüketim verilerini çevrimiçi platformlar üzerinden görebilir ve bu da tüketici memnuniyetini artırır. Tüketicilerin geçmiş tüketim verilerini izleyebilmesi de enerji kullanımını daha bilinçli yönetmelerini sağlar.

3.3. Elektrik Enerjisinde Aktif-Reaktif Enerji

Elektrik enerjisi kullanımında iki ana enerji türü vardır: aktif enerji ve reaktif enerji. Bunlar, elektrik enerjisinin nasıl tüketildiğini ve cihazların enerji tüketim karakteristiklerini anlamak için önemlidir.

Aktif enerji, elektrik devrelerinde gerçek güç olarak tüketilen enerjidir. Elektriksel cihazların iş yapabilmesi için harcadığı enerjiyi ifade eder ve genellikle kilovat-saat (kWh) birimiyle ölçülür. Cihazların elektrik motorları, aydınlatma sistemleri ve ısıtıcılar gibi cihazlar aktif enerji tüketir. Bu tür enerji, iş yapma kapasitesine sahiptir, yani aydınlatma sağlar, ısıtma yapar veya cihazların mekanik hareketini sağlar.

Reaktif enerji, bazı cihazların manyetik alan oluşturmak için tükettiği enerjidir. Bu enerji, özellikle elektrik motorları, transformatörler ve floresan lambalar gibi endüktif (manyetik) bileşenlere sahip cihazlarda görülür. İş yapma kapasitesine sahip değildir; sadece manyetik alan oluşturur ve genellikle kiloVAR-saat (kVARh) birimiyle ölçülür. Reaktif enerjinin endüktif ve kapasitif olmak üzere iki farklı bileşeni vardır. Bu iki enerji türü, elektrik devrelerinin özelliklerinden kaynaklanır ve reaktif enerjiyi oluşturan ana unsurlardır.

Mesken tarifesine bağlı aboneler reaktif enerji kullanımı için ayrıca ücret ödemezler. Ancak sanayi ve ticari işletmelerde, reaktif enerji sınırlarının aşılması durumunda ekstra ceza bedelleri yansıtılabilir. Bu, işletmelerin kompanzasyon sistemleri kullanarak reaktif enerji tüketimini dengelemelerini teşvik eder.

Elektrik enerjisi tüketen bir cihaz bir kaynaktan toplam olarak görünür güç (S) çeker. Şekil 3.1 de gösterilmiştir. İşe dönüşen (iş yapan) enerji olarak tanımlanan aktif güç (P);


$$P = S \times \cos(\theta) \quad (3.1)$$

şeklinde ifade edilir. Burada θ tüketim noktasındaki akım ve gerilim arasındaki açısal farktır.

Reaktif güç ise aktif güce benzer şekilde;

$$Q = S \times \sin(\theta) \quad (3.2)$$

şeklinde hesaplanır. Elektrik sayaçları bu değerleri ayrı ayrı ölçebilecek karakterde üretilmelidir ki bu değerlere göre faturalandırmalar yapılabilir. Öncelikle tüketicilerde aktif güç değeri tarifenin birim fiyat bedeli ile çarpılır. Mesken harici abonelerde reaktif kullanımı sınırlayıcı önlem için reaktif tüketim değeri aktif değerine oranlanmasıyla belirlenen değeri aşması durumunda, ceza amaçlı bu tüketim de faturalandırılır.




Şekil 3.1 Güç faktörü


Reaktif tüketimin hem pozitif kısmı hem de negatif kısmı anlık olarak ayrı ayrı ölçülür ve kaydedilir. Reaktif tüketimin pozitif kısmı indüktif tüketim (E) olarak ölçülür ve aktif güce oranının %20 değerini aşmaması istenir. ($\theta > 0$) Reaktif tüketimin negatif kısmı (C) ise kapasitif tüketim olarak ölçülür ve aktif güce oranının %33 değerinden fazla olmaması gereklidir. ($\theta < 0$) Bu değerlerin aşılması durumunda faturalarda bu değerler ceza bedeli olarak miktarına göre tahakkuk edilir (EPDK 2015, İnt. Kyn. 5) Genellikle kullanılan cihazların motor içeren kısımlarında bulunan indüktanstan dolayı indüktif akım, doğrultucu-dönüştürücü gibi cihazlar içeren kısımlarında bulunan kapasitanstan dolayı kapasitif akım oluşur. Bu değerlerin oluşmayarak görünür gücün (S) aktif güce oranının 1'e yakın olması için kompanzasyon sistemlerinin kullanılması gereklidir ($\cos(\theta) = 1$) (Mahmoud ve Emam 2022). Kompanzasyon sistemlerinin kurulum ve bakım maliyetleri kullanıcıların elektrik tüketimi davranışlarını değiştirebilmektedir.

4. MATERYAL METOT


Tez kapsamında OSOS ile Afyonkarahisar iline ait beş farklı tarifieden alınan kullanıcıların belli zaman aralığındaki aktif tüketim (A), indüktif tüketim (E), kapasitif tüketimden (C) oluşan veriler 3 kanallı zaman serileri şeklinde kullanılarak tarife gruplarının sınıflandırılması üzerine çalışılmıştır. Elektrik kullanıcılarının sayaçlarından elde edilen tüketim verileri zaman serileri olarak şekil 4.1-4.10'daki gibi oluşturulmuştur. Tarife grupları sınıflarının spesifik özellikleri çıkartılarak sonradan verilen verilerin hangi tarife grubunda olduğu sınıflandırılmaya çalışılmıştır. Verilerde empirik olarak yapılan incelemede mesken tüketicilerinin reaktif kullanım kuralına uymadıkları söylenebilir. Diğer yandan sanayi sertifikası ile çalışan tüketicilerin yüksek değerlerde tüketim yaptıkları ve tüketimlerinin neredeyse günün tüm saatlerine yayıldığı, diğer yandan ticarethane tarifesini kullanan tüketicilerin sanayi tüketicilerine oranla kısmen daha düşük tüketime sahip olduğu diğer yandan kullanımlarının yoğun mesai saatlerinde (08:00-18:00) yaşandığı gözlemlenmiştir. İçme suyu tüketicilerinde ise bir otomasyon ile belirli saat aralıklarında kendini tekrar eden tüketim alışkanlığının olduğu şekil 4.1'de gözlemlenmiştir. Bu tespitlerden yola çıkarak bu özelliklerin derin ağlar yardımı ile çıkarılması hedeflenmiştir.




Şekil 4.1 İçme suyu sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi




Şekil 4.2 İçme suyu sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi




Şekil 4.3 Mesken sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi




Şekil 4.4 Mesken sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi




Şekil 4.5 Sanayi sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi




Şekil 4.6 Sanayi sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi




Şekil 4.7 Tarımsal sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi



Şekil 4.8 Tarımsal sınıftan rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi



Şekil 4.9 Ticarethane sınıftan rastgele seçilmiş tüketicilerin elektrik tüketiminin 3 kanallı zaman serisi olarak gösterimi.



Şekil 4.10 Ticarethane sınıfından rastgele seçilmiş tüketicilerin elektrik tüketiminin aktif-endüktif ve kapasitif olarak ayrı ayrı zaman serisi olarak gösterimi

4.1. Zaman Serilerinin Sınıflandırılması

Zaman serisi şeklindeki veriler, her alanda karşımıza çıkmaktadır. Finans verisi, sensör verileri, titreşim verileri, hava durumu verileri gibi farklı problem verileri zamana bağlı olarak değişim göstermektedirler. Zamana bağlı değişim gösteren verilere, zaman serisi verileri denilmektedir (Güdelek 2019). Zamana bağlı olarak kaydedilen verilerin (örneğin sıcaklık ölçümleri, borsa fiyatları, hastane hasta kayıtları) belirli sınıflara veya kategorilere ayrılmasına zaman serisi sınıflandırması denir. Bu tür sınıflandırma işlemleri, geçmiş verilerin gelecekteki durumları nasıl etkilediğini anlamamıza ve belirli örüntülerle ilişkili kategorilere ayırmamıza olanak sağlar. Şekil 4.11’de zaman serilerinin sınıflandırılmasına ilişkin blok şeması görülmektedir. Veriler zamana göre sıralı ve ardışık olduğu için, bir veri noktası yalnızca kendi değerine değil, önceki veya sonraki veri noktalarına da bağlıdır. Zaman serilerinde belli örüntüler, trendler ve dönemsel değişimler görülebilir; bu örüntüler sınıflandırmayı etkileyebilir. Klasik sınıflandırma yöntemlerinden farklı olarak, zaman serisindeki özelliklerin otomatik olarak çıkarılması ve işlenmesi gerekebilir.



Şekil 4.11 Zaman serisi sınıflandırma blok diyagramı

Veri analitiği ve makine öğrenmesi süreçlerinde önemli bir yere sahip olan sınıflandırma yöntemlerinde kullanılan istatistiksel yaklaşımlarda zaman serisindeki özelliklerin manuel veya otomatik olarak çıkarılarak klasik sınıflandırma algoritmalarına (K-NN, SVM, lojistik regresyon) uygulanması gibi özellik tabanlı yöntemler ve zaman serisindeki örüntüleri tanımlamaya dayalı örüntü tabanlı yöntemler vardır. Lojistik regresyon, Naive Bayes Sınıflandırıcı, K-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Karar Ağaçları ve Rassal yaygın olarak kullanılan yöntemlerdendir (LeCun vd. 2012, Pal vd. 2016). İstatistiksel yöntemler, sınıflandırma işlemi desteklemek ve verilerdeki örüntüleri ortaya çıkarmak için uygun çerçeveler sunar. Ayrıca zaman serisi verilerini otomatik olarak sınıflandırmak için konvolüsyonel sinir ağları ve yinelemeli sinir ağları (RNN ve LSTM) gibi derin öğrenme yöntemleri de kullanılır. Bu yöntemler, zaman serisindeki karmaşık örüntüleri ve zamansal bağımlılıkları daha iyi öğrenebilir. Birden fazla sınıflandırma algoritmasını birleştirerek zaman serisi sınıflandırma işlemi daha doğru hale getiren ensemble yöntemlerinde (topluluk öğrenmesi) Random Forest veya Gradient Boosting gibi topluluk öğrenmesi yöntemleri ile zaman serisi sınıflandırmasında güçlü performans elde edilebilir.

Zaman serilerini temelde çok boyutlu bir vektör olarak değerlendirildiğinde uzaklık veya benzerlik tabanlı (Lines ve Bagnall 2014) k-en yakın komşuluk temelli (Bagnall vd. 2016) yaklaşımlar ile sınıflandırılabilir. Bu yöntemlerde serinin birbirinden uzaklıklarına bakılarak oldukça yüksek doğruluk değerleri elde edilse de veri vektörünün farklı ortalamalara sahip olması durumunda vektör yönü belirleyici olabilir. Uzun süren eğitim süreçlerine çözüm zaman serilerinden özellik çıkararak daha kısa boyutlu vektörler elde etmek olabilir. Bu şekilde Discrete Wavelet, Fourier Dönüşümü (Mörchen 2003) gibi taban dönüşümleri ile ya da trend, mevsimsellik, korelasyon (wang v.d 2007) ortalama

(Deng vd. 2013) gibi istatistiksel değerlerin belirlenerek özellik çıkarımlı sınıflandırmalar yapılabilmektedir. Hesaplama zamanının uzun olduğu, iki zaman serisi arasındaki benzerliğin uzaklık hesabına dayalı sınıf seçimi (Jeong vd. 2011, Rakthanmanon vd. 2013) yapılabildiği gibi nispeten daha hızlı çalışabilen Hidden Markov Model (HMM) ile de zaman serileri üzerinde sınıflandırma yapılabileceği belirtilmiştir (Antonucci vd. 2015).

Zaman serisi olarak kaydedilmiş veriler, genellikle sonraki zamanda oluşacak değerin tahmin edilmesi amacı ile kullanılsa da minör ve majör özellikleri çıkartılarak sınıflandırma problemlerinde de giriş verisi olarak kullanılabilir. Farklı nesnelerden elde edilen zaman serileri ile insan aktivitelerinden konuşma tanıma (Sadouk vd. 2018), tıpta EEG sinyallerinden hastalık teşhisinde (Özbay vd. 2005, Wang vd. 2013, Wei vd. 2018) ve astronomi (Kaya ve Gündüz 2015) gibi birçok alanda sınıflandırma yapılarak farklı yöntemlerle başarılı sonuçlar alınabilmiştir.

Literatürde enerji tüketim verisini analiz ederek akıllı sistemlerde kullanmak için önerilen modeller bulunmaktadır. Geçmiş çalışmalar, bu çalışmaya paralel ancak aynı amaçla olmayıp genellikle sonraki verinin tahmini veya bina içi çalışan cihazın elektrik tüketim verisine bakılarak tahmin edilmesine dayanmaktadır. Bir evin enerji tüketim verisi üzerinde danışmasız öğrenme ve veri madenciliği teknikleri kullanılarak belirlenen zamanda hangi cihazın çalıştığını Bayes ağı ile tahmin edilmiştir (Singh ve Yassine 2018). Bir başka çalışmada ise DBSCAN (density-based spatial clustering of applications with noise) adapte edilerek hane elektrik tüketim verilerine uygulanarak bu verilerin kategorik ayrıştırılması sağlanmıştır (Wang vd. 2018).

Burada, elektrik tüketimi verilerinden yararlanarak, kullanıcıların hangi tarife grubuna ait olduğunu tahmin etmek için bir yöntem önerilmektedir. Bu amaçla, , Konvolüsyonel Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) gibi derin öğrenme modelleri bir araya getirilerek kullanılmış ve elde edilen sonuçlar değerlendirilmiştir. Önerilen yöntemin, enerji sektöründe kullanıcı davranışlarının ve tarife gruplarının analizinde yeni bir perspektif sunabileceği düşünülmektedir. Bu sonuçlar, enerji şirketlerinin müşteri segmentasyonu ve talep tahmini gibi stratejik karar alma süreçlerinde değerli bir araç olabilir. Çalışmalardan çıkarılacak sonuçlar enerji tüketim değerlerinden faydalanarak

yenilikçi elektrik dağıtımında akıllı şebekelerin bir bileşeni olan DSM (Demand Side Management)'de kullanılabilecektir.

4.2. Derin Öğrenme

Derin öğrenme (Deep Learning), yapay sinir ağlarına dayalı olarak geliştirilen ve özellikle büyük veri setleri üzerinde çalışarak karmaşık görevleri yerine getirebilen bir makine öğrenimi türüdür. Derin öğrenme, çok katmanlı yapısı sayesinde verilerdeki gizli özellikleri öğrenebilir ve bu sayede görüntü tanıma, doğal dil işleme, ses tanıma, oyun oynamak ve daha pek çok alanda etkili sonuçlar üretebilir. Derin öğrenme, makine öğreniminin bir alt alanıdır ve yapay zekâ (AI) uygulamalarının önemli bir parçasını oluşturur.

Derin öğrenme, çeşitli mimariler ve modeller içerir. Görüntü işlemede CNN, zaman serilerinin analizinde LSTM, Yapay Sinir Ağı (ANN) modelleri ile entegre edilerek yaygın olarak kullanılır. Gerek sırada karşılaştığımız verinin temininde gerekse görüntü işlemede nesnelerin tespitinde ve sınıflandırmasında tercih edilen sinir ağlarıdır.

ANN, basit ve düz yapıdaki sinir ağlarıdır. Bu ağlar birden fazla gizli katmana sahip olabilir ve genellikle temel sınıflandırma ya da regresyon problemlerinde kullanılır. CNN ise özellikle görüntü verileri üzerinde çalışmak için geliştirilmiş bir mimaridir. Zaman serisi ile çok iyi çalışmadığı düşünülse de çeşitli dönüşümlerle kullanılabilen ve görüntü tanıma, görüntü ayıklama gibi problemlerde oldukça etkilidir (Vargas vd. 2017, Gudelek vd. 2017, Sezer vs. 2018) . Bu model, görsel verilerdeki kenar, köşe ve şekil gibi özellikleri tespit etmek amacıyla kullanılır ve görüntü tanıma, nesne algılama, yüz tanıma gibi alanlarda oldukça etkilidir.

Tekrarlayan sinir ağları (RNN), zaman serisi verilerini işlemek ve sıralı veri analizleri yapmak için kullanılır. Bu model, belleğe sahip olduğundan önceki girdilerden öğrendiklerini hatırlayabilir. Bu sayede doğal dil işleme, ses tanıma ve zaman serisi tahmini gibi alanlarda başarılı sonuçlar verir. LSTM ise RNN'in bir türüdür ve uzun dönemli bağımlılıkları öğrenmek amacıyla geliştirilmiştir. Veri dizilerinde uzun vadeli

ilişkileri yakalayabilen bu model, dil çevirisi, metin özetleme ve dil modellemesi gibi görevlerde yaygın olarak kullanılmaktadır.


Elektrik tüketimine dayalı veriler gelecek verinin tahmininde ve elektrik tüketiminin sınıflandırmasında ANN, Support Vektor Machine (SVM), Genetik algoritma (GA) gibi algoritmalar kullanılmaktadır (Zhou ve Chan 2018). Elektrik tüketim verileri ile imalathanede işleme safhalarının enerji tüketiminin sınıflandırması yapılmıştır (Zhao vd. 2017). Gelecek verinin tahmininde ise makine öğrenmesi algoritmaları elektrik tüketim verilerine uygulanarak hata değerlendirme belirsizlik katsayısı ile yapılmış, oldukça yüksek değerde sonuçlar alınmıştır (Reddy vd. 2023). Makine öğrenmesi algoritmaları olarak doğrusal regresyon, KNN, XGBoost, ANN, Random Forest, Support Vektör Regresssion (SVR) ve LSTM modelleri aynı veri üzerinde denenmiş en iyi sonucun KNN algoritması ile alındığı belirtilmiştir.

Geleneksel enerji tüketimi tahmin modelleri genellikle istatistiksel yöntemlere dayanmaktadır ve genellikle geniş zaman aralıklarında makro seviyede tahminler yapmaya odaklanmaktadır. Ancak, son yıllarda derin öğrenme yöntemlerinin gelişimiyle birlikte, zaman serisi verilerinden daha detaylı ve hızlı tahminler yapmak mümkün hale gelmiştir (Karim vd. 2017, Saduok 2019, Zhao vd. 2019, Güneş vd. 2021, Aadhitya vd. 2023, Zhang 2023). Özellikle, CNN ve LSTM gibi derin öğrenme modelleri, zaman serileri analizinde başarılı sonuçlar elde etmiştir.


4.2.1. Uzun Kısa Süreli Bellek (LSTM)

LSTM (Long Short-Term Memory), uzun süreli bağımlılıkları öğrenme kabiliyeti olan özel bir tekrarlayan sinir ağı (RNN) mimarisidir. 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından geliştirilmiştir (Hochreiter ve Schmidhuber 1997). LSTM, özellikle dizesel verilerde geçmişteki bilgiyi hafızasında tutarak uzun süreli bağımlılıkları yakalamak için idealdir. Bu nedenle, doğal dil işleme (NLP), zaman serisi tahmini, dil çevirisi, konuşma tanıma ve biyomedikal veri analizi gibi pek çok uygulamada sıklıkla tercih edilir.

LSTM ağırları, RNN'lerin uzun süreli bağımlılıkları öğrenmedeki zayıflıklarını gidermek için geliştirilmiştir. RNN'ler, kısa dönemli bağımlılıkları iyi öğrenebilmesine rağmen, uzun dönemli ilişkileri öğrenme konusunda sorunlar yaşar; çünkü zamanla geçmiş bilgiyi unutarak “gradyan sönmesi” problemi ortaya çıkar. LSTM bu problemi çözmek için, bilgiyi uzun süre hatırlayabilen ve gereksiz bilgiyi unutabilen hücre (cell) yapılarını kullanır.



Şekil 4.12 LSTM Modeli (Olah 2015, İnt. Kyn. 6)



Şekil 4.13 LSTM Modeli Hücre Bilgisi Aktarımı

Bir LSTM hücresi, üç ana kapıya (gate) ve bir hücre durumuna (cell state) sahiptir. Bu kapılar ve hücre durumu, LSTM'nin veriyi nasıl işlediğini ve depoladığını belirler. LSTM hücresinin bilgiyi hafızasında tuttuğu ana yol Hücre Durumu (Cell State)' dur. Uzun vadeli bilgileri taşır ve bu bilgiyi koruma veya güncelleme yeteneğine sahiptir. Hücre durumu, gerektiğinde değiştirilebilir ve düzenlenebilir. Giriş Kapısı (Input Gate) hücre durumuna hangi yeni bilgilerin eklenmesi gerektiğini belirler. Giriş kapısı, mevcut


girişten hangi bilginin hücre durumuna ekleneceğini seçer ve bu bilgiler hücre durumuna eklenir. Hücre durumundaki hangi bilgilerin unutulması gerektiğini Unutma Kapısı (Forget Gate) belirler. Örneğin, bir LSTM modeli bir kelime dizisini analiz ediyorsa, unutma kapısı dizinin eski ve artık gereksiz olan bilgilerini unutmaya yardımcı olur. Hücre durumundan hangi bilginin çıktı olarak aktarılması gerektiğini ise Çıkış Kapısı (Output Gate) belirler. LSTM hücresinde işlenen bilgiyi belirleyerek, sonraki adımlar için çıktı sağlar.

Bu kapılar, veri üzerinde işlemler yapmak için sigmoid ve tanh gibi aktivasyon fonksiyonlarını kullanır. Sigmoid fonksiyonu, bilginin hangi oranda geçiş yapacağını belirler ve 0-1 aralığında sonuç verir. 0 çıktısı "hiçbir veri geçişine izin verme", 1 çıktısını ise "her veri geçişine izin ver" demektir. Tanh fonksiyonu ise hücre durumunun değerini -1 ile 1 arasında tutar ve verinin daha fazla veya daha az geçiş yapmasına olanak tanır.

Unutma Kapısı ilk adımda, hangi bilginin korunacağına veya unutulacağına karar verir. Bu kapı, bunun için giriş verisi ve önceki durum bilgisi üzerinde sigmoid fonksiyonu uygular. Şekil 4.14'te gösterilen aktivasyon fonksiyonu sigmoid olan sinir ağı, t anındaki girdi ve $t-1$ anındaki gizli hali girdi olarak alır ve hücre halinin ne kadar bilgiyi unutup unutmayacağına karar verir. Buradaki f_t , 1'e yaklaştıkça $t-1$ anındaki hücre hali t anına aktarılır. Aynı şekilde 0'a yaklaştıkça $t-1$ anındaki hücre hali unutulur ve sonraki sinir ağlarından gelen bilgiler bir sonraki t anına aktarılır. Bu işlem denklem 4.1 ile gösterilmektedir.

σ = sigmoid fonksiyonu

$$f_t = \sigma(W_f.[h_{t-1}, x_t] + b_f) \quad (4.1)$$




Şekil 4.14 LSTM Unutma Kapısı

Giriş kapısı, hücre durumuna eklenmesi gereken yeni bilgiyi belirler. Burada yine giriş ve önceki çıkış değerleri, sigmoid ve tanh fonksiyonlarından geçirilerek hangi yeni bilgilerin hücre durumuna ekleneceği belirlenir. Denklem 4.2 ile matematiksel olarak ifade edilmektedir. Şekil 4.15'te gösterilen aktivasyon fonksiyonu sigmoid olan sinir ağı, t anındaki girdi ve $t-1$ anındaki gizli hali girdi olarak alır ve çıktı olarak verdiği i_t de -1 ile 1 arasına sıkıştırılmış (tanh fonksiyonu sayesinde) olan kısmi yeni hücre bilgisinin ne kadarının eski hücre bilgisine ekleneceğine karar verir. Matematiksel ifadesi denklem 4.3'te görülmektedir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4.2.)$$


$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4.3.)$$



Şekil 4.15 LSTM Giriş Kapısı

Unutma kapısından elde edilen bilgiler, önceki hücre durumu ile çarpılır ve giriş kapısından elde edilen bilgiler eklenerek yeni hücre durumu oluşturulur ve hücre durumu güncellenir. Bu, LSTM'nin yeni bilgileri hafızasına eklemesini ve eski bilgileri gerektiğinde unutturmasını sağlar. Şekil 4.16'da unut kapısının verdiği karar $t-1$ anındaki hücre bilgisiyle çarpılıp, giriş kapısının ne kadar yeni hücre bilgisinin sisteme dahil edileceğine karar verdiği vektör ile toplanarak t anındaki (bir sonraki nörona aktarılacak ya da özyinelemeli şekilde kendisine tekrar girecek olan) hücre bilgisi elde edilmiş olur. Denklem 4.4'te görülmektedir.

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (4.4)$$




Şekil 4.16 LSTM Hücre Durumunun Güncellenmesi

Son olarak, hücre durumu, çıkış kapısından geçerek LSTM'nin bir sonraki adımda kullanacağı çıktı üretilir. Bu işlem, LSTM'nin hafızasını bir sonraki zaman dilimine taşımasını sağlar. Denklem 4.5'te gösterilmektedir. Şekil 4.17'de -1 ile 1 arasına sıkıştırılmış (tanh) t anındaki hücre bilgisi, t -1 anından gelen gizli hal bilgisi ile çarpılarak t anındaki (bir sonraki nörona aktarılacak ya da özyinelemeli şekilde kendisine tekrar girecek olan) gizli hal bilgisi elde edilmiş olur. Denklem 4.6'da gösterilmektedir.

$$o_t = \sigma (W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4.5)$$

$$h_t = o_t * \tanh (C_t) \quad (4.6)$$



Şekil 4.17 LSTM Gizli Durum Bilgisi Güncelleme ve Çıkış Kapısı


LSTM'nin uzun süreli bağımlılıkları öğrenme becerisi, onu sıralı veri ile ilgili birçok görevde kullanıma uygun hale getirir. Dil modelleri, metin özetleme, dil çevirisi ve duygu analizi gibi doğal dil işleme görevlerinde sıklıkla kullanılır. Uzun metinlerdeki anlam ilişkilerini koruma yeteneği, dil modellerinde LSTM'nin tercih edilmesini sağlar. LSTM, önceki verilerdeki uzun vadeli trendlere bakarak gelecekteki değerleri tahmin edebildiği için hisse senedi fiyatları, hava durumu verileri veya enerji tüketimi gibi zaman serisi verilerini analiz etmek için idealdir. Videoların zamana bağlı ilişkilerini analiz edilmesinde, biyomedikal sinyallerinin (örneğin, kalp ritmi veya EEG verileri) analizinde kullanılır. Uzun vadeli kalp ritmi verileri gibi biyomedikal sinyallerde anomalileri tespit edebilir.

Uzun süreli bağımlılıkları öğrenme yeteneği sayesinde zaman serisi verilerinde oldukça başarılıdır. Geri yayılım sürecinde gradyan sönmesi sorununu azaltır ve bu sayede daha derin ağların eğitiminde kullanımı kolaylaşır. Birçok farklı yapı ile çalışabilmesi, onu çok yönlü bir araç haline getirir. CNN ve LSTM birleşimi gibi farklı yapılarla entegre edilebilir. Fakat diğer ağ yapılarına göre daha karmaşık bir yapıya sahiptir ve bu nedenle yüksek hesaplama gücü gerektirir. Bu, eğitim süresinin uzun olmasına yol açabilir. LSTM'nin etkili çalışabilmesi için hiperparametrelerin doğru ayarlanması gerekir, bu da deneyim ve ince ayar gerektirir. LSTM ağları, yüksek doğrulukla çalışabilmek için büyük veri setlerine ihtiyaç duyar. Veri eksikliği, model performansını düşürebilir.

4.2.2. Konvolüsyonel Sinir Ağları (CNN)

Konvolüsyonel Sinir Ağları (CNN – Convolutional Neural Networks), derin öğrenme modelleri arasında özellikle görsel veriler üzerinde yüksek performans sağlayan bir mimaridir. Görüntü tanıma, nesne algılama, yüz tanıma, tıbbi görüntü analizi gibi pek çok alanda yaygın olarak kullanılan CNN, görüntülerdeki özellikleri (kenar, köşe, doku, desen gibi) otomatik olarak çıkararak karmaşık veri yapılarında güçlü analizler yapar. 2012 yılındaki ImageNet yarışmasındaki üstün başarısından (Krizhevsky vd. 2012) sonra hemen hemen her yerde kullanılan CNN ilk olarak Fukushima (1980) ve Waibel vd. (1989)'ın yayınlarında çalışılmış ve modern anlamda bildiğimiz yapıya Lecun vd. (1989)'ın yaptığı çalışmada kavuşmuştur.

CNN, veriyi katmanlar halinde işler ve her katmanda farklı özellikleri çıkararak sonuca ulaşır. CNN yapısında en önemli bileşenler evrişim katmanları (convolutional layers), havuzlama katmanları (pooling layers) ve tam bağlı katmanlar (fully connected layers) olarak adlandırılır. Bu yapılar, CNN'in girdi verisindeki özellikleri öğrenmesini ve çıktıyı doğru şekilde sınıflandırmasını sağlar.




Şekil 4.18 CNN Modeli

Bir CNN modeli Şekil 4.18’de görülmektedir. Genellikle aşağıdaki adımları takip ederek görüntüyü işler:

- Girdi Verisinin Alınması: Girdi olarak bir görüntü (örneğin, 28x28 piksel boyutunda bir siyah-beyaz resim) modele verilir. Eğer görüntü renkli ise her renk kanalına (RGB) ayrı bir boyut olarak eklenir.
- Konvolüsyon Katmanının Uygulanması: İlk konvolüsyon katmanında çeşitli filtreler kullanılarak görüntüdeki temel özellikler (kenar, köşe, doku gibi) çıkarılır. Bu filtreler görüntüye kaydırılarak, aktivasyon haritaları oluşturulur.
- Havuzlama Katmanının Uygulanması: Aktivasyon haritasının boyutunu küçültmek için havuzlama uygulanır. Bu, görüntüdeki özelliklerin daha özet bir şekilde temsil edilmesini sağlar ve modeli aşırı öğrenmeye karşı korur.

- **Tekrar Eden Katmanlar:** Birden fazla konvolüsyon ve havuzlama katmanını ardışık olarak uygulanarak, modelin daha yüksek seviyeli özellikleri öğrenmesi sağlanır. Modelin derinliğine göre bu katman sayısı değişir.
- **Tam Bağlı Katmanlara Geçiş:** Son havuzlama katmanından elde edilen aktivasyon haritası düzleştirilerek tam bağlı katmanlara aktarılır. Burada sınıflandırma işlemi gerçekleştirilir.
- **Çıktı Üretimi:** Son olarak, softmax fonksiyonu kullanılarak her sınıfa bir olasılık değeri atanır ve görüntünün hangi sınıfa ait olduğu belirlenir.



Şekil 4.19 CNN Filtreleme İşlemi

Konvolüsyon katmanları (Convolutional Layers) , CNN'in temel yapı taşlarından biridir ve görüntü üzerinde belirli özellikleri çıkarmak için filtreler (kernels) kullanır. Bu filtreler şekil 4.19'daki gibi, girdiye (örneğin, bir görüntüye) kaydırılarak (slide) uygulanır ve her bölgedeki küçük özellikler çıkarılır. Evrişim işlemi sayesinde, CNN modelinin görüntüdeki kenarlar, köşeler veya dokular gibi düşük seviyeli özellikleri öğrenmesi sağlanır.

Belirli bir özelliği algılamak üzere öğrenilen ağırlıklardan oluşan filtreler (Kernels) vardır. Örneğin, bir filtre kenarları tanımlarken, bir diğeri köşeleri algılayabilir. Filtrenin girdi verisi üzerinde kaydırılmasıyla oluşan çıktı Aktivasyon Haritası (Feature Map) olarak adlandırılır. Bu harita, filtrelerin belirlediği özellikleri içerir ve her evrişim

katmanında yeni bir harita ortaya çıkar. Aktivasyon Fonksiyonu negatif değerleri sıfıra indirerek modelin doğrusal olmayan özellikleri öğrenmesine olanak tanır. Çoğunlukla ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılır.

Havuzlama katmanları (Pooling Layers), aktivasyon haritasının boyutunu küçültmek için kullanılır. Bu işlem, modelin hesaplama yükünü azaltır ve görüntünün farklı bölgelerinde bulunan özellikleri özetleyerek modelin daha genelleştirilmiş bir öğrenme yapmasını sağlar. Havuzlama yöntemlerinden en yaygın olanı maksimum havuzlama (Max Pooling), filtre penceresindeki en büyük değeri seçerek aktivasyon haritasını küçültür. Bu işlem, önemli özelliklerin korunmasını sağlarken, detayları daha az önemli hale getirir. Ortalama Havuzlama (Average Pooling) ise Maksimum havuzlama yerine filtre penceresindeki tüm değerlerin ortalaması alınır. Bu, özelliklerin ortalama değerini alarak boyutları küçültür, ancak görüntüdeki önemli kenar veya köşe bilgilerini korumakta maksimum havuzlama kadar etkili değildir.

Tam bağlı katmanlar (Fully Connected Layers), CNN'in son katmanıdır ve bu katman, sınıflandırma işleminin gerçekleştirildiği yerdir. Evrişim ve havuzlama katmanlarında çıkarılan özellikler, düzleştirilerek (flatten) tam bağlı katmanlara gönderilir (İnt. Kyn 7). Bu düzleştirilmiş veriler, çıktı katmanında sınıflandırıcı bir işlev görür. Son katmanda, her bir sınıfın olasılığını belirleyen bir softmax fonksiyonu kullanılarak görüntü belirli bir sınıfa atanır.

CNN'ler, özellikle görsel ve uzamsal veri üzerinde yüksek performans göstermeleri nedeniyle birçok alanda yaygın olarak kullanılmaktadır. Görüntü tanıma ve kategorilendirme, yüz tanıma ile yüz özelliklerini öğrenen CNN modelleri, kimlik doğrulama ve güvenlik sistemlerinde geniş çapta kullanılır. Nesne algılama ve konum belirleme gibi alanlarda CNN tabanlı modeller, görüntüdeki nesneleri tanıyarak her nesnenin pozisyonunu tespit edebilir. Bu, sürücüsüz araçlar veya güvenlik sistemleri gibi uygulamalarda kullanılır. MRI, röntgen gibi tıbbi görüntülerdeki anormallikleri tespit etmek için CNN'ler yaygın olarak kullanılmaktadır. Hastalık tanısı ve tedavi planlaması gibi kritik alanlarda büyük başarı sağlar.

CNN' in avantajlarından bazıları görüntülerdeki özellikleri otomatik olarak çıkararak analiz eder, bu da manuel özellik çıkarma ihtiyacını ortadan kaldırır. Filtreler sayesinde

görüntüdeki belirli bölgeleri tanıyabilir ve her bir özelliğin yerini öğrenir, bu da daha doğru analiz yapılmasını sağlar ve filtrelerin aynı görüntü üzerinde tekrar tekrar kullanılması yoluyla parametre paylaşımı yapar. Bu da daha az hafıza kullanımı ve daha hızlı işlem gücü anlamına gelir.

Fakat CNN'ler, büyük veri setleri ve karmaşık modeller gerektirdiğinden güçlü donanımlar (örneğin, GPU) gerektirir. Bu da eğitim süresini uzatabilir ve maliyetleri artırabilir. CNN modelleri, çok katmanlı yapısı nedeniyle büyük veri gerektirdiği için veri yetersizliği durumunda aşırı öğrenme (Overfitting) riski artar ve modelin performansı düşebilir. Özellikle nadir özellikleri tanımlamak için yeterli veri bulunamaması performansı da etkileyebilmektedir.

4.3. Sınıflandırma Değerlendirme Kriterleri

Sınıflandırma değerlendirme kriterleri, bir sınıflandırma modelinin doğruluğunu, güvenilirliğini ve genel performansını ölçmek için kullanılan metriklerdir. Bu kriterler, modelin hangi oranlarda doğru veya yanlış tahminlerde bulunduğunu analiz etmeyi sağlar (Güdelek 2019). İşte sınıflandırmada yaygın olarak kullanılan başlıca değerlendirme kriterleri:

4.3.1. Karışıklık Matrisi (Confusion Matrix)

Karışıklık matrisi, modelin doğru ve yanlış sınıflandırma sayısını ayrıntılı olarak gösteren bir tablodur. Modelin hangi tür hatalar yaptığını ve hangi sınıfları daha başarılı tahmin ettiğini analiz etmeye yardımcı olur. Karışıklık matrisi dört ana bileşenden oluşur:

- **Doğru Pozitif** : Gerçek pozitif örneklerin doğru tahmin edilmesi.
- **Yanlış Pozitif**: Gerçek negatif örneklerin yanlışlıkla pozitif tahmin edilmesi.
- **Yanlış Negatif**: Gerçek pozitif örneklerin yanlışlıkla negatif tahmin edilmesi.
- **Doğru Negatif**: Gerçek negatif örneklerin doğru tahmin edilmesi.

Karışıklık matrisi, modelin her bir sınıf için başarı ve hata oranlarını anlamaya yardımcı olur. Hangi hataların düzeltilebileceğini görmek için önemli bir analiz aracıdır.

4.3.2. Doğruluk (Accuracy)

Doğruluk, modelin doğru sınıflandırdığı veri sayısının toplam veri sayısına oranıdır. Tüm sınıflar için geçerli bir ölçüt olarak kullanılır, ancak dengesiz veri kümelerinde yanıltıcı olabilir.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Toplam Örnek Sayısı}} \quad (4.7)$$

4.3.3. Kesinlik (Precision)

Kesinlik, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Yanlış pozitif sayısının yüksek olduğu durumlarda önemlidir. (Yanlış Pozitifler: Modelin pozitif olarak tahmin ettiği, ancak gerçekte negatif olan örnekler.)

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \quad (4.8)$$

Yanlış pozitiflerin önemli olduğu durumlarda, örneğin e-posta spam filtrelemede (yanlışlıkla önemli bir e-postayı spam olarak sınıflandırma) kesinlik önemlidir. Kesinliği artırmak, yanlış pozitif sayısını azaltarak modelin yalnızca gerçekten pozitif olan örnekleri pozitif olarak tahmin etmesini sağlar.

4.3.4. Duyarlılık (Recall) veya Hassasiyet (Sensitivity)

Duyarlılık, gerçek pozitiflerin ne kadarının model tarafından doğru tahmin edildiğini ölçer. Özellikle yanlış negatiflerin minimum olması gerektiğinde önemlidir, örneğin tıbbi teşhislerde.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (4.9)$$

Yanlış negatiflerin sorun oluşturduğu durumlarda, örneğin hastalık teşhisi veya dolandırıcılık tespitinde, duyarlılık daha önemlidir. Modelin pozitif örnekleri (örneğin, hastalıklı bireyleri) kaçırmadan tespit etmesi istenir.

4.3.5.F1 Skoru

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Dengesiz veri kümelerinde daha güvenilir bir metrik olup hem kesinlik hem de duyarlılığın önemli olduğu durumlarda kullanılır.

$$F1 = 2 \times \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (4.10)$$

F1 skoru hem kesinlik hem de duyarlılığın önemli olduğu durumlarda tercih edilir. Örneğin, spam filtrelemede yalnızca spam e-postaların doğru tespit edilmesi değil, önemli e-postaların da yanlışlıkla spam olarak algılanmaması gerekir.

4.3.6.ROC Eğrisi ve AUC (Area Under Curve)

ROC eğrisi, modelin çeşitli eşik değerlerinde duyarlılık ve özgüllüğünü gösterir. AUC, ROC eğrisinin altında kalan alanı temsil eder ve modelin sınıflandırma kapasitesini tek bir skorda özetler. AUC değeri 1'e yakınsa modelin performansı yüksektir.

- **ROC Eğrisi:** Duyarlılık (True Positive Rate) ve Yanlış Pozitif Oranı (False Positive Rate) grafiği.
- **AUC:** Modelin tüm sınıflandırma eşiklerinde genel performansını özetler.

ROC-AUC, özellikle dengesiz veri kümelerinde modelin performansını değerlendirmek için faydalıdır. Bankacılık, sağlık gibi yanlış sınıflandırmanın maliyetli olduğu alanlarda kullanılır.

4.3.7.Özgüllük (Specificity)

Özgüllük, negatif sınıfları doğru şekilde tanımlayabilme oranıdır. Yanlış pozitiflerin önemli olduğu durumlarda, örneğin sahte pozitiflerin sorun yaratabileceği alanlarda kullanılır.

$$\text{Özgüllük} = \frac{\text{Doğru Negatif}}{\text{Doğru Negatif} + \text{Yanlış Pozitif}} \quad (4.11)$$

Yanlış pozitiflerin olumsuz sonuçlar doğurabileceği durumlarda özgüllük kullanılır. Örneğin, bir kredi onay sürecinde, özgüllük ile modelin yalnızca gerçekten uygun olan başvuruları onaylayıp onaylamadığına bakılır.

4.3.8.Log-Kayıp (Logarithmic Loss veya Log-Loss)

Log-kayıp, modelin her bir sınıf için tahmin ettiği olasılıklar üzerinden doğruluğunu ölçer. Tahminler ile gerçek etiketler arasındaki farkın logaritmik kaybını hesaplar. Düşük log-kayıp, modelin tahminlerinin gerçek değerler ile uyumlu olduğunu gösterir.

Özellikle sınıflandırma tahminlerinin olasılıklı yapıldığı durumlarda, örneğin finansal tahminlerde ve sağlık teşhislerinde tercih edilir.

4.3.9.Cohen's Kappa Katsayısı

Cohen's Kappa, modelin doğruluğunu tesadüfi tahmin olasılığına göre ayarlayan bir ölçüttür. Değeri -1 ile 1 arasında değişir ve yüksek değerler daha güçlü bir model performansını gösterir.

Cohen's Kappa, özellikle iki sınıflı problemler için kullanılmakta olup modelin rastlantısal doğruluk olasılığı göz önünde bulundurularak değerlendirilmesi gereken durumlarda tercih edilir.

4.4. Verinin Hazırlanışı

Bu çalışmada kullanılan veri seti, gerçek elektrik tüketicileri sayaçlarından kaydedilen sayaç okuma değerleri ile oluşturulmuştur. Zamana bağlı olarak değişen elektrik tüketim verisinin elde edilmesi için sayaçlarda okunan değerler (W_t) zamanla diferansiyel alınarak, o zaman aralığı için tüketilen elektrik enerjisinin temsil edilmesi sağlanmıştır. Bu enerjinin zamana bağlı türevi ise herhangi bir anda çalışan toplam cihazların ortalama gücü (P_t) denklem 4.12 ile hesaplanabilir.

$$P_t = \frac{W_t - W_{t-1}}{\Delta t} \quad (4.12)$$

Toplamda 310 farklı kullanıcıdan elde edilen veriler kullanılmıştır. 2023 yılına ait yarım saat aralıklarla toplanmış veri, sayaç okuma işleminde kaçırılan değerler için lineer interpolasyon ile eksik değerler doldurulmuştur. Her zaman anı için değer üretilmesi sağlanarak zaman serisi olarak değerlendirilen veriler eş boyuta getirilmiştir. Şekil 4.20 - 4.24'te rastgele seçilmiş tüketicilerden alınan aktif elektrik tüketim verilerinin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi gösterilmiştir. Çizelge 4. 1'de sınıflara göre aktif tüketimin istatistikleri verilmiştir. Bu tabloda veri setinde buluna her bir örneğe ait istatistiksel değerler hesaplanarak, hesaplanan değerlerin minimum, maksimum ve ortalama değerleri verilmiştir. Buradaki %25,%50,%75 değerleri sıralanmış verinin çeyreklik dilimlerindeki verinin dağılımının daha iyi anlaşılmasına ve özellik çıkarılmasına yardımcı olan istatistiksel değerlerdir. Bu çeyreklikler verinin alt, orta ve üst bölümlerini anlamak için bir fikir oluşturmaktadır.

$$z = \frac{x - \mu}{\sigma} \quad (4.13)$$

z = Standart değer

x =gözlemlenen değer

μ = örneklemin ortalaması

σ = örneklemin standart sapması


Ancak ölçü aletlerinin arızası veya yanlış değerler kaydedilmesi ile sayaçlardan alınan değerlerde aykırı değerler veya sayacın geri sarması sebebi ile negatif değerler gözlemlenmiştir. Bu değerlerin ayrıştırılması için denklem 4.13'teki z-skoru istatistiğinden yararlanılmıştır. Buna göre ortalama değerden 3 x standart sapma kadar sapan değerler aykırı değerler olarak veri setinden çıkarılarak yerine lineer interpolasyon ile değerler doldurulmuştur. Sınıf bazında toplam istatistiksel büyüklükler tablo 1'de verilmiştir. Bu istatistiksel değerlerden bazıları ile sınıfların ayrışabileceğini göstermektedir.

Çizelge 4.1 Sınıflara göre aktif tüketimin istatistikleri (min.-ort.-maks.)


İstatistik \ Sınıflar	Tarımsal	Ticari	Sanayi	Mesken	İçme suyu
Adet	66	74	81	31	58
Min.	0.0 - 0.10 - 5.61	0.00-2.72-52.43	0.00-2.53-115.91	0.00-0.28-0.81	0.00-10.30-232.87
Maks.	0.08-39.84-281.17	0.64-63.28-1711.20	0.12-206.86-2207.99	0.01-8.44-71.75	0.02-35.73-565.80
Ort.	0.01-11.72-90.55	0.07-25.09-612.97	0.01-75.81-1251.05	0.01-2.00-32.85	0.01-23.10-405.67
Std Sapma	0.03-9.03-81.12	0.05-13.01-400.10	0.01-49.76-591.64	0.00-2.00-15.34	0.01-5.67-50.61
25%	0.00-4.02-43.12	0.00-13.55-193.20	0.00-41.41-695.52	0.01-0.98-21.39	0.00-18.45-357.07
50%	0.00-10.06-75.89	0.01-24.92-717.5999	0.00-70.72-1531.79	0.00-1.06-26.22	0.00-24.01-424.34
75%	0.00-17.25-153.52	0.07-33.87-938.39	0.00-98.13-1752.60	0.00-1.93-44.16	0.00-26.86-441.59

Modelin karmaşıklığı, verinin uzun boyutlu olması sınıflandırmanın daha iyi analiz edilebilmesi bakımından 310 adet (310x3) zaman serisi aylık zaman serilerine dönüştürülmüş, her kullanıcıdan 10 adet örnek ile nihai veri seti oluşturulmuştur. Verinin aynı sınıfa ait tüketiciler için aylık olarak aynı özellikleri içerebileceği zamanın tekrar etmesi bakımından kaçınılmaz sonuçtur. Bu sebepten bir örnek için aynı özellikleri içeren veri tekrarı gereksizdir. Sonuç olarak zaman serisi sınıflandırma işleminde her bir değerlerin mimariler için bir özellik olmaktadır. Aynı zamanda bu kadar çok özellik barındıran


verinin modelde eğitim süresi uzun olacaktır. 1 aylık veri toplamda 1440 adet (yarım saatlik) zamana bağlı değişen veri içermektedir. Böylelikle hem bir örnek için özellik sayısı azaltılmış hem de her bir sınıftaki örnek sayısı 10 katına çıkmıştır. Bu işlem sonrası gözlemlenen verideki örnek sayısının yetersizliği için aşırı örnekleme (oversampling) metotlarına, bir örnek için özelliklerin azaltılması amacı ile yetersiz örnekleme (undersampling) metotlarına ihtiyaç duyulmamıştır.




Şekil 4.20 İçme suyu sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi




Şekil 4.21 Mesken sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi




Şekil 4.22 Sanayi sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi



Şekil 4.23 Tarımsal sulama sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi



Şekil 4.24 Ticarethane sınıfından rastgele seçilmiş tüketicilerin aktif elektrik tüketiminin zaman serisi olarak gösterimi ve mikro ölçeklerde incelenmesi




Şekil 4.25 Sınıfların dağılımı

Daha sonra bu seçilen aylık verilerde değer içermeyen (tamamı '0' olan) örnekler çıkarılmıştır. Nihai olarak 2968 adet örnek ile sınıflandırma işlemi yapılmıştır. Çoğullama ile elde edilen 3100 adet örneğin sınıfları ve her sınıftan ön işleme sonucu elde edilen örnek sayısı Şekil 4.25'te verilmiştir. Bu sınıflar Türkiye elektrik dağıtım sektöründe mevzuat ile belirlenen sınıflar olup, her biri kendi sınıfına ait özellikler barındırmaktadır. Gerek çalışma zamanları, periyodikliği gerekse çalışan cihazların özellikleri (çalışma süresi ve gücü) en ayırt edici özellikler olarak karşımıza çıkmaktadır.

Bu adımlar sonucunda elde edilen veri seti, CNN-LSTM modelinin eğitim ve doğrulama süreçlerinde kullanılmıştır. Bu süreçlerde, veri setinin dengesi ve çeşitliliği göz önünde bulundurularak %80-%20 şeklinde bölünmüş ve kullanılmıştır.


Veri setinin hazırlanışı, önerilen modelin doğruluğu ve güvenilirliği açısından kritik öneme sahiptir. Doğru ve temiz veri, modelin etkin bir şekilde eğitilmesini ve nihai olarak doğru tahminler yapmasını sağlamaktadır. Son olarak her bir örnek önerilen modelde kullanılan CNN-2D katmanına giriş verisi olarak resme dönüştürülmüştür. Veriye farklı açıdan bakılmasını sağlayan bu dönüşümde her sınıfta görsel olarak farklı şekillerin çıkması Şekil 4.26-30'de gözlemlenmektedir.



Şekil 4.26 Mesken tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))


Rastgele seçilmiş örnekler incelendiğinde Şekil 4. 26’teki mesken abonesinin aynı zaman diliminde endüktif ve kapasitif tüketimlerinin aktif tüketime oranlarının yüksek olduğu görülmektedir. Bu durum mesken abonelerine uygulanmayan reaktif tüketim kontrolünden kaynaklandığı söylenebilir.

Zaman serisinin resme dönüştürülmesi ile verinin herhangi noktasındaki korelatif veri sayısı arttırılmıştır. Zaman serisi olarak çıkarılamayan özellikler resme dönüştürüldükten sonra CNN-2D yardımı ile çıkarılabilir. Yani bir noktadaki verinin öncesinde ve sonrasındaki verilerin haricinde üstünde (bir gün önce aynı saat) ve altındaki (bir gün sonra aynı saatte) veriler ile ilişkiler de incelenebilir. Böylece bir örnekte her gün aynı zamanda çalışan bir cihaz bulunması durumunda bu ilişkilerin korelasyon katsayısı yüksek çıkmaktadır.




Şekil 4.27 İçme suyu tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))

Şekil 4.27’teki içme suyu aboneliğinde tek bir alıcının tüm gün boyunca periyodik olarak programlanan saatlerde çalıştığı görülmektedir. Bazı tesislerde içme suyu tesisindeki pompanın şamandıra yardımı ile seviye kontrolü yapılarak veya dijital olarak programlanmış bir röle yardımı ile belirli aralıklarda çalıştırılması sağlanabilir. Her iki durumda da korelasyon grafiğinde 0 değerinden pozitif bir değere geçişler görünecektir. Şekil 4.31 ‘de korelasyon grafiği görülmektedir.




Şekil 4.28 Sanayi tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))




Şekil 4.29 Ticari tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))

Şekil 4.28 ve Şekil 4.31’da görülen sanayi ve ticari örneklerin günün belirli saatlerinde tüketim yapıldığı, diğer zamanlarda ise nispeten daha küçük tüketim yapıldığı zaman serisinin resme dönüştürülmesi ile ancak görülebilmektedir. Mesai saatlerine tekabül eden bu tüketim saatleri, resmî tatil gibi tatillerde kullanım olmadığı gibi çıkarımlar derin ağlar yardımı ile kolayca yapılabilir.




Şekil 4.30 Tarımsal tüketiminin 2D resme dönüştürülmesi (a-zaman serisi, b-tek kanal aktif tüketim (gri ölçekli), c-üç kanal (RGB))


Şekil 4.30'deki tarımsal sulama örneğinde ise üretilen ürüne göre yılın belirli mevsimlerinde tüketimin yoğun olduğu. İnsan gözü ile bakıldığında resme dönüştürmek bu şekilde yorum yapma olanağı tanırken bu işlemin CNN ile yaptırılması abone gruplarının özelliklerinin daha detaylı çıkarılarak daha doğru sonuçlara ulaşmayı kolaylaştırmaktadır.




Şekil 4.31 İçme suyu sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri




Şekil 4.32 Mesken sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri



Şekil 4.33 Sanayi sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri



Şekil 4.34 Tarımsal sulama sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri




Şekil 4.35 Ticarethane sınıfından rastgele seçilmiş tüketicilerin yarım saat öncesi ve bir gün sonraki aynı zamandaki verilerin korelasyon grafikleri

4.5. Önerilen Model

Bu çalışmada, elektrik tüketimi verilerinden tarife grubu tahmini yapmak için CNN ve LSTM modellerini bir araya getiren bir model kullanılmıştır. CNN modeli görüntü işleme ve sınıflandırma çalışmalarında oldukça yoğun olarak kullanılmaktadır. LSTM ise zaman serilerinin geçmiş gözlemleri hafıza ederek tahmin algoritmalarında sıklıkla kullanılmaktadır. Bu modellerin birleştirilmesi, zaman serilerinde hem uzamsal hem de zamansal desenleri etkili bir şekilde öğrenebilir ve karmaşık ilişkileri modelleyebilir.

CNN, her ne kadar çoğunlukla resimlerin sınıflandırmasında kullanılsa da sinyalleri tanımda sinyal işleme tekniği olan konvolüsyon işlemi ile özelliklerin çıkarılmasında başarılı bir tekniktir. Konuşma tanımda ses sinyalleri filtrelenerek sınıflandırma yapılmıştır (Abdel-Hamid vd. 2013). İnsan aktivitelerine bağlı olarak sensörlerden elde edilen verilerin hareketin tanımlanmasında CNN'den yararlanılmıştır (Sadouk vd. 2018) CNN-TS adının verildiği modelde, zaman serileri ön işleme esnasında sentetik olarak genişletilerek daha hızlı bir öğrenme süreci sağlanmıştır (Taherkhani vd. 2023). Bu şekilde ResNet ağına oranla 8,43 kat daha hızlı eğitim zamanı yakalanmıştır. LSTM ağı, zaman serilerinin ardışık özelliklerinin çıkarılmasında etkili bir yöntem olarak Parkinson hastalığı teşhisinde kullanılmıştır (Pham vd. 2019). Fizyolojik sinyallerin

sınıflandırmasında LSTM ve bulanık mantık kullanılarak yüksek doğruluk ve daha hızlı öğrenme sağlanmıştır (Pham 2021). LSTM-FCN adında oluşturulan ağa CNN-1D katmanından sonra eklenen sıkıştırma-uyarma (squeeze-and-excite) katmanı ile eğitim süreci hızlandırılmıştır (Karim vd. May 2019, August 2019). LSTM-FCN, LSTM ve CNN bloklarının paralel olarak çalışması sonrası sınıflandırma katmanında birleştirme mantığına dayanır. MACNN adında önerilen ağda, zaman serilerinin farklı özellikleri paralel CNN ağları ile çıkarılarak daha yüksek doğruluğa sahip sınıflandırma yapılabildiği belirtilmiştir (Cui vd. 2021).



Şekil 4.36 Önerilen modelin blok diyagramı


Modelin ilk katmanı, elektrik tüketimi verilerinin uzamsal desenlerini öğrenmek için bir CNN katmanıdır. Bu katman, veri setindeki örüntüleri algılamak ve önemli özellikleri çıkarmak için evrişim işlemlerini kullanır. CNN katmanına giriş olarak verinin iki boyutlu matris formatına dönüştürülmesi şekil 4.26- 4.30'de gösterilmiştir. Farklı günlerin aynı saatlerinde gözlemlenen verilerin özellikle bir gün öncesi veya bir gün sonrasında yüksek korelasyona sahip olduğu şekil 4.31- 4.35'te gözlemlenmiştir. Bu sebepten zaman serisi resme dönüştürülerek 2 boyutlu CNN mimarisi kullanılması sağlanmıştır. Ayrıca CNN çıktıları ile LSTM giriş boyutu azaltılmış olur. Bu da LSTM eğitim süresini de azaltır.

CNN bloklarından sonra elde edilen özellik haritaları, bir dizi LSTM hücresine iletilir. LSTM, zaman serilerindeki uzun süreli bağımlılıkları modellemek için kullanılan bir tür tekrarlayan sinir ağıdır. LSTM katmanı, geçmiş zaman adımlarından gelen bilgileri kullanarak gelecekteki değerleri tahmin etmek için içsel hafıza mekanizmalarını kullanır. Unutma kapısı(F) ile geçmiş verilerin şimdiki zaman için önemsizliği bulunarak sonraki


eğitimlerden silinmesi, giriş kapısı(I) ile geçmiş verilerin şimdiki zaman ile ilişkisi oranında sonraki eğitimlere dâhil edilmesi sağlanır. Çıkış kapısından(O) üretilen sonuçlar hem çıkış katmanına(C) hem de bir sonraki bloğa(H) iletilerek tekrarlayan bir yapı oluşturulmuştur.

LSTM katmanının çıktıları, tam bağlantılı katmanlar aracılığıyla sınıflandırma için sonuçlara dönüştürülür. Bu katmanlar, modelin çıktısını belirli sınıf etiketlerine karşılık gelen olasılık dağılımlarına dönüştürür. Şekil 4.36' de modelin blok diyagramı görülmektedir. LSTM katmanının karmaşıklığı uzun eğitim süreçlerinde verinin ezberlenmesine yol açmaktadır. Bu durumun engellenmesi amacı ile her turdan sonra model parametrelerinin bir kısmı “dropout” katmanı ile elenmelidir.


CNN blokları sonrası oluşturulan aktivasyon haritaları şekil 4.37 - 4.40'ta verilmiştir. Yukarıdan aşağı doğru sırası ile 1., 2., ve 3. CNN katmanı sonrası filtrelenen veriler görüntülenmektedir.




Şekil 4.37 İçme suyu aktivasyon Haritası




Şekil 4.38 Mesken aktivasyon haritası



Şekil 4.39 Sanayi aktivasyon haritası



Şekil 4.40 Tarımsal aktivasyon haritası



Şekil 4.41 Karışıklık matrisi


Şekil 4.41'deki karmaşıklık matrisi incelendiğinde tarımsal sulama tarifesinin oransal olarak daha düşük doğrulukta tahmin edildiği görülmektedir. Diğer tarifelerin daha doğru modellendiği durumda tarımsal sulama tarifesinin özellik çıkartılması işleminin nispeten daha başarısız olduğu, bu sınıftaki örneklerin zamansal olarak dengesiz çalıştığı yorumu yapılabilir. Gerçekte ticari olup modelde sanayi tahmin edilen, gerçekte sanayi olup ticari olarak tahmin edilen başarısız tahminler de diğer başarısız tahminlere oranla daha yüksek olduğu görülmektedir. Bu durumun bölüm 4'te anlatılan iki sınıfa ait ortak özelliğın olmasından kaynaklandığı söylenebilir.

Model, elektrik tüketimi verilerinin zaman içindeki değişimlerini dikkate alarak hangi tarife grubuna ait olduğuna dair tahmin edilmesi amacı ile kullanılmıştır. Eğitim sürecinde, modelin parametreleri, veri seti üzerindeki kayıpların minimize edilmesi amacıyla öğrenilmiştir. Kullanılan model hem uzamsal hem de zamansal desenleri etkili bir şekilde öğrenerek, elektrik tüketimi verilerinden tarife gruplarının tahmininde başarılı sonuçlar elde etmiştir.

5. TARTIŞMA ve SONUÇ

Bu çalışma, elektrik tüketimi verilerinden bir örneğin hangi tarife grubuna ait olduğu ile alakalı tahmin yapmak için CNN ve LSTM modellerini bir araya getiren bir yaklaşım önermektedir. Tarifelerin sınıflandırılması ile alakalı literatürde çalışma olmaması bakımından özgün bir çalışma olarak bu alandaki çalışmalara öncülük edecektir. Önerilen model, veri setindeki 3 kanallı zaman serileri üzerinde eğitilmiş ve doğrulanmıştır. Elde edilen sonuçlar aşağıda özetlenmektedir:

- Eğitim Verisi Doğruluğu: Model, eğitim verisi üzerinde %87 doğruluk elde etmiştir. Bu sonuç, modelin elektrik tüketimi verilerinden tarife gruplarına ilişkin desenleri başarıyla öğrendiğini göstermektedir.
- Doğrulama Verisi Doğruluğu: Model, doğrulama verisi üzerinde %82 doğruluk elde etmiştir. Bu sonuç, modelin genelleme yeteneğinin olduğunu ve yeni veri örneklerinde de etkili olduğunu göstermektedir.



Şekil 5.1 Model Özeti

3 adet CNN-2D, 1 adet LSTM katmanı içeren modelde toplamda 860549 parametre bulunmaktadır. Şekil 5.1’de gösterilmiştir. Katmanlarda bulunan filtre sayısı ve pencere genişliği gibi parametreler deneysel olarak eğitimin hızı ve doğruluğu ön planda tutularak

belirlenmiştir. Yapılan sınıflandırma eğitimi sonrası tahmin edilen sınıflara ait karışıklık matrisi şekil 5.7’de verilmiştir.

Model daha sonra aynı ekseninde diğer modeller ile çizelge 5.1’’de karşılaştırılmıştır. CNN-2D katmanları ile çıkarılan özelliklerin CNN-1D katmanlarından elde edilen özelliklerden daha ayırt edici olduğu tespit edilmiştir. Ayrıca modelleri sadece CNN veya sadece LSTM katmanları ile eğitildiğinde önerilen modele oranla daha başarısız olduğu görülmektedir. Modellerin giriş verisinin zaman serisi olmasına rağmen 2 boyutlu yaklaşım ile daha uygun sonuçlar alınmıştır. Burada sadece LSTM katmanı içeren modelin diğer modellere göre daha uzun eğitim süresine sahip olduğu tespit edilmiştir. CNN-1D yaklaşımı veriyi iyi öğrenmesine karşılık test verisinde CNN-2D yaklaşımına göre hem daha yavaş hem de doğruluk bakımından başarısız olmuştur.

Çizelge 5.1 Farklı modellerin 25 tur eğitim sonucu doğruluk değerleri karşılaştırması

	CNN-2D	LSTM	CNN-1D+LSTM	CNN-2D+LSTM
Eğitim Doğruluğu(%)	72.69	63.42	96.03	87.83
Test Doğruluğu(%)	69.66	58.16	75.51	82.37
Eğitim Süresi (sec.)	185	6371	484	186

Bu çalışmanın sonuçları gelecekte müşteri segmentasyonunun daha doğru yapılması ile akıllı şebeke uygulamalarında talep tarafının daha doğru analiz edilerek yönlendirilmesine katkı sağlayacaktır. Bu şekilde şebeke ve tesis planlamaları da daha doğru yapılabilecektir. Ayrıca gözlemsel olarak yapılacak usulsüz kullanım tespitinin ulaşım ve işçi maliyetlerini düşürerek hızlı bir şekilde yapılabilmesine olanak sağlayacaktır. Gelecek çalışmalarda farklı abone grupları ile veri örnek sayısı da artırılarak derin ağlarla oluşturulacak farklı modeller oluşturulabilir. Dinamik fiyatlama mekanizmalarından alınacak verilerle de tüketim verileri ilişkilendirilip tüketim-fiyat ilişkisi ile daha doğru sonuçlar elde edilmesi planlanmaktadır.

6. KAYNAKLAR

- Aadhitya A., Rajapriya R., Vineetha R.S., May 2023, M.B. Anurag, Predicting Stock Market Time-Series Data using CNN-LSTM Neural Network Model. <https://doi.org/10.48550/arXiv.2305.14378>
- Abdel-Hamid O., Deng L., Yu D., 2013, Exploring convolutional neural network structures and optimization techniques for speech recognition, Proc. Interspeech, Lyon, France, pp.1173-1175. OI:10.21437/Interspeech.2013-744
- Amyady N, 2001. Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability, IEEE Transactions on Power Systems, Vol. 16, No.4, pp.798-805.
- Antonucci A., De Rosa R., Giusti A., et al., January 2015, Robust classification of multivariate time series by imprecise hidden Markov models, International Journal of Approximate Reasoning, vol.56, part B, pp.249-263. <https://doi.org/10.1016/j.ijar.2014.07.005>
- Bagnal A., Lines J., Bostrom A., Large J., Keogh E., November 2016, The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances, Data Min Knowl Discov, vol.31, no. 3, pp.606-660.
- Bevk P., Sučić B., Pušnik M., 2013, Challenges and opportunities of electricity consumption optimisation in Slovenian households, 4th International Youth Conference on Energy (IYCE), Hungary. DOI:10.1109/IYCE.2013.6604134
- Cejka S., Frieden D., Kitzmüller D, 2021, Implementation of self-consumption and energy communities in Austria's and EU member states' national law: A perspective on system integration and grid tariffs, Online Conference. DOI: 10.1049/icp.2021.1526
- Ceylan G., 2004, Yapay Sinir Ağları İle Kısa Dönem Yük Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 117s, İstanbul.

- Chen X., Weng L., Zhu H., Lian D., 18 June 2021, A Novel Pricing Algorithm Based on Reward-Punishment Mechanism for Supply and Demand Balancing, Frontiers in Energy Research. DOI:10.3389/fenrg.2021.682300
- Cui Z., Chen W., Chen Y., April 2021, Multi-scale convolutional neural networks for time series classification, Neural Networks, vol.136, pp. 126-140. <https://doi.org/10.1016/j.neunet.2021.01.001>
- Dağıtım Lisansı Sahibi Tüzel Kişiler Ve Görevli Tedarik Şirketlerinin Tarife Uygulamalarına İlişkin Usul Ve Esaslar EPDK, 2015, Resmi Gazete, 31Aralık 2015, 29579.
- Deng H., Runger G., Tuv E., Vladimir M., August 2013, A time series forest for classification and feature extraction, Inf. Sci., vol. 239, pp.142-153. <https://doi.org/10.1016/j.ins.2013.02.030>
- Elektrik Piyasası Tüketici Hizmetleri Yönetmeliği, 2018, Resmi Gazete, 30 Mayıs 2018,30436.
- Fukushima K.,1980 Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, Biological Cybernetics 36.4, pp. 193–202.
- Grzanić M., Morales J.M., Pineda S., Capuder T., February 2021, Electricity Cost-Sharing in Energy Communities Under Dynamic Pricing and Uncertainty, IEEE Access, vol.9, pp. 30225-30241. DOI: 10.1109/ACCESS.2021.3059476
- Gudelek M. U., Boluk, S. A., and Ozbayoglu A. M., 2017, A deep learning based stock trading model with 2-D CNN trend detection. In: 2017 IEEE Symposium Series on Computational Intelligence (SSCI). IEEE.
- Güdelek M.U., 2019, Zaman Serisi Analizi ve Tahmini: Derin Öğrenme Yaklaşımı, TOBB ET Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 102s, Ankara.

- Güneş O., Morgül Ö., 2021, LSTM Based Classification of Targets using FMCW Radar Signals, 29th Signal Processing and Communications Applications Conference (SIU), Istanbul, Turkey. DOI: 10.1109/SIU53274.2021.9477927
- Hochreiter S. and Schmidhuber, J., 1997, Long Short-Term Memory, Neural Computation, 9.8, pp. 1735–1780.
- Jeong Y., Jeong M.K., Omitaomu O.A., September 2011, Weighted dynamic time warping for time series classification, Pattern Recognition, vol.44, no.9, pp. 2231-2240. <https://doi.org/10.1016/j.patcog.2010.09.022>
- Karim F., Majumdar S., Darabi H., Chen S., December 2017, LSTM Fully Convolutional Networks for Time Series Classification, IEEE Access, vol.6, pp. 1662–1669. DOI:10.1109/ACCESS.2017.2779939
- Karim F., Majumdar S., Darabi H., May 2019, Insights Into LSTM Fully Convolutional Networks for Time Series Classification, IEEE Access, vol.7, pp. 67718 – 6772. DOI: 10.1109/ACCESS.2019.2916828
- Karim F., Majumdar S., Darabi H., Harford S., August 2019, Multivariate LSTM-FCNs for time series classification, Neural Networks, vol.116, pp. 237-245. <https://doi.org/10.1016/j.neunet.2019.04.014>
- Kaya H., Gündüz Oguducu S., July 2015, A distance-based time series classification framework, Information Systems, vol. 51, pp. 27-42. <https://doi.org/10.1016/j.is.2015.02.005>
- Kocaman B., 2012, Elektronik Sayaç Kullanımında Tarife Seçiminin Önemi, BEÜ Fen Bilimleri Dergisi, 1, 59-65, 2012.
- Krizhevsky A., Sutskever I., and Hinton G. E., 2012, ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems 25. Ed. by Pereira, F. et al. Curran Associates, Inc., pp. 1097–1105.

- LeCun, Y. A. et al. ,2012, Efficient BackProp. Ed. by Montavon, G., Orr, G. B., and Müller, K.-R. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 9–48.
- LeCun, Y. et al., 1989, Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation 1.4, pp. 541–551.
- Lee H., May 2024, Automated tariff design for energy supply–demand matching based on Bayesian optimization: Technical framework and policy implications, Energy Policy, vol 188. <https://doi.org/10.1016/j.enpol.2024.114102>.
- Lines J., Bagnall A., 2014 Time series classification with ensembles of elastic distance measures, Data Min Knowl Discovery, vol 29, no3, pp.565-592, June 2014. DOI:10.1007/s10618-014-0361-2
- Mahmoud R.A.A., Emam A., May 2022, Coherence-based automatic power factor correction (APFC) algorithm for power grids, The Journal of Engineering, vol. 2022, no.5, pp.512-527, <https://doi.org/10.1049/tje2.12133>
- Mörchen F., 2003, Time series feature extraction for data mining using DWT and DFT. Data Bionics, Philipps-Univ, Marburg, Germany, Teknik Rapor, pp.1-33.
- Nakai M., Loessl V. ve Wetzel H., September 2024, Preferences for dynamic electricity tariffs: A comparison of households in Germany and Japan, Ecological Economics, Vol. 223. <https://doi.org/10.1016/j.ecolecon.2024.108239>
- Olah C., 2015, Understanding LSTM Networks.
- Otomatik Sayaç Okuma Sistemlerinin Kapsamına ve Sayaç Değerlerinin Belirlenmesine İlişkin Usul ve Esaslar EPDK, 2011, Resmi Gazete, Rev. 2015, 10 Nisan 2011, 27901.
- Özbay Y., Ceylan R., Karlik B, April 2006, A fuzzy clustering neural network architecture for classification of ECG arrhythmias, Comput Biol Med, vol. 36, no.4, pp. 376–388. <https://doi.org/10.1016/j.combiomed.2005.01.006>

- Pal K. K., Sudeep, K. S., 2016, Preprocessing for image classification by convolutional neural networks, IEEE International Conference on Recent Trends in Electronics, Information Communication Technology (RTEICT), pp. 1778–1781.
- Pham T.D., March 2021, Time–frequency time–space LSTM for robust classification of physiological signals, Scientific Reports, vol.11, no.1. DOI:10.1038/s41598-021-86432-7
- Pham T.D., Wårdell K., Eklund A., Salerud G., November 2019, Classification of short time series in early Parkinson’ s disease with deep learning of fuzzy recurrence plots, IEEE/CAA Journal of Automatica Sinica, vol.6, no.6, pp. 1306 – 131. DOI: 10.1109/JAS.2019.1911774
- Rakthanmanon T., Campana B., Mueen A., et al., September 2013, Addressing big data time series: Mining trillions of time series subsequences under dynamic time warping, ACM Transactions on Knowledge Discovery from Data, vol.7 no.3, pp.1-31. <https://doi.org/10.1145/2500489>
- Reddy G.V., Aitha L.J., Poojitha C., Shreya A.N., Reddy D.K., Meghana G.S., June 2023, Electricity consumption prediction using machine learning, in 4th International Conference on Design and Manufacturing Aspects for Sustainable Energy, GRIET, India, vol.391, p.9. <https://doi.org/10.1051/e3sconf/202339101048>
- Sadouk L., 2019, CNN Approaches for Time Series Classification, Chun-Kit Ngan (ed.). DOI: 10.5772/intechopen.81170
- Sadouk L., Gadi T., Essoufi E.H., 15 May 2018, Convolutional neural networks for human activity recognition in time and frequency domain, in: Proceedings of ICRTS, pp:485-496.
- Sezer O. B. and Özbayoğlu A. M., 2018, Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. In: Applied Soft Computing 70, pp. 525–538.

- Singh D., Singh S. P., 2001. A Self-Selecting Neural Network For ShortTerm Load Forecasting, Electric Power Components and Systems, Taylor and Francis, Vol. 29, pp.117-130.
- Singh S, Yassine A., February 2018, Big Data Mining of Energy Time Series for Behavioral Analytics and Energy Consumption Forecasting, Data Science and Big Data in Energy Forecasting, vol.11, no.2, pp.452. <https://doi.org/10.3390/en11020452>
- Stute J. ve Klobasa M., June 2024, How do dynamic electricity tariffs and different grid charge designs interact? Implications for residential consumers and grid reinforcement requirements, Energy Policy, vol. 189. <https://doi.org/10.1016/j.enpol.2024.114062>
- Taherkhani A., Cosma G., McGinnity T.M., 2023, A Deep Convolutional Neural Network for zTime Series Classification with Intermediate Targets, SN Computer Science, vol.4, no.832.
- Tao L., Gao Y., February 2020, Real-time pricing for smart grid with distributed energy and storage: A noncooperative game method considering spatially and temporally coupled constraints, International Journal of Electrical Power & Energy Systems, vol. 115. <https://doi.org/10.1016/j.ijepes.2019.105487>
- Théatec T., Sutera A. ve Ernst D., December 2023, Matching of everyday power supply and demand with dynamic pricing: Problem formalisation and conceptual analysis, Energy Reports, vol. 9, pp. 2453-2462. <https://doi.org/10.1016/j.egyr.2023.01.040>
- Türkiye Elektrik Dağıtım A.Ş. Genel Müdürlüğü, Mayıs 2024, Tedaş 2023 Yılı Elektrik Dağıtım Sektör Raporu,30.
- Türkiye Sanayi Kalkınma Bankası(TSKB), Nisan 2021, Talep Tarafı Yönetimi Bilgilendirme Notu.

- Vargas M. R., Lima B. S. L. P., and Evsukoff, A. G., 2017, Deep learning for stock market prediction from financial news articles. In: 2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA). IEEE, DOI: 10.1109/CIVEMSA.2017.7995302.
- Waibel A. et al., 1989, Phoneme recognition using time-delay neural networks, IEEE Transactions on Acoustics, Speech, and Signal Processing 37.3, pp. 328–339.
- Wang J., Liu P., She M.F.H., Nahavandi S., Kouzani A., November 2013, Bag-of-words representation for biomedical time series classification, Biomedical Signal Processing and Control, vol.8, no.6, pp. 634-644. <https://doi.org/10.1016/j.bspc.2013.06.004>
- Wang X., Wirth A., Wang L., October 2007, Structure-based statistical features and multivariate time series clustering, in Proc. IEEE Int. Conf. Data Mining, Omaha, NE, USA, pp:351-360. DOI:10.1109/ICDM.2007.103
- Wang F., Li K., Duić N., Mi Z., Hodge B.M., Shafie-khah M., Catalão J.P.S., September 2018, Association rule mining based quantitative analysis approach of household characteristics impacts on residential electricity consumption patterns, Energy Conversion and Management, vol.171, pp. 839-854. <https://doi.org/10.1016/j.enconman.2018.06.017>
- Wei Y., Zhang X., Shi Y., Xia L., Pan S., Wu J., Han M., Zhao X., February 2018, A review of data-driven approaches for prediction and classification of building energy consumption, Renewable and Sustainable Energy Reviews, vol. 82, no. 1, pp. 1027-1047. <https://doi.org/10.1016/j.rser.2017.09.108>
- Zhang J., October 2023, A Study on English Teachers' Behavior and Teaching Effectiveness in Universities Based on Big Data Technology, Applied Mathematics and Nonlinear Sciences, vol.9, no.1. DOI:10.2478/amns.2023.2.00456

Zhao G.Y., Liu Z.Y., He Y., Cao H.J., Guo Y.B., 15 August 2017, Energy consumption in machining: Classification, prediction, and reduction strategy, Energy, vol.133, pp. 142-157. <https://doi.org/10.1016/j.energy.2017.05.110>

Zhao J., Mao X., Chen L., January 2019, Speech emotion recognition using deep 1D & 2D CNN LSTM networks, Biomedical Signal Processing and Control, vol47, pp. 312-323. <https://doi.org/10.1016/j.bspc.2018.08.035>

Zhou P.Y., Chan K.C.C., June 2018, Fuzzy Feature extraction for multichannel EEG Classification, IEEE Transactions on Cognitive and Developmet Systems, vol. 10, no.2 pp. 267-279. DOI: 10.1109/TCDS.2016.2632130

İnternet Kaynakları

<https://www.tedas.gov.tr/tr/1> (14.11.2024.)

<https://www.epdk.gov.tr/Detay/Icerik/2-109/-epdkdan-onemli-karar-> (14.11.2024)

<https://www.epdk.gov.tr/Detay/Icerik/3-1994/dagitim-lisans-sahibi-tuzel-kisiler-ve-gorevli-t> (14.11.2024)

<https://www.epdk.gov.tr/detay/icerik/3-14771/elektrik-piyasasi-tuketici-hizmetleri-yonetmeligi> (14.11.2024)

<https://www.epdk.gov.tr/Detay/Icerik/3-1994/dagitim-lisans-sahibi-tuzel-kisiler-ve-gorevli-t> (14.11.2024)

<https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (16.11.2024)

<https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks> (16.11.2024)

