



NEW TRENDS IN ELECTRICAL, ELECTRONIC AND COMMUNICATION ENGINEERING



All Sciences Academy

***NEW TRENDS IN
ELECTRICAL,
ELECTRONIC AND
COMMUNICATION
ENGINEERING***

Editor

Asst. Prof. Dr. Umut ÖZKAYA





New Trends in Electrical, Electronic and Communication Engineering

Editor: Asst. Prof. Dr. Umut ÖZKAYA

Design: All Sciences Academy Design

Published Date: March 2024

Publisher's Certification Number: 72273

ISBN: 978-625-6530-88-1

© All Sciences Academy

www.allsciencesacademy.com

allsciencesacademy@gmail.com

CONTENT

1. Chapter	4
Elektrikli Araçlarda Şarj İşleminin Şebeke Üzerindeki Tüketim Miktarının Yapay Zekâ İle Öngörülmesi	
<i>Hakan KAYA, Selcan Sıla YILMAZ, Kadir OLCAY, Arif BAŞGÜMÜŞ, Mustafa NAMDAR</i>	
2. Chapter	31
Three-Phase Voltage and Current Meter and Data Scope Application for Android Device with Arduino	
<i>Erdem ILTEN</i>	
3. Chapter	46
Elektrik Enerjisinin Verimli, Güvenli ve Tasarruflu Kullanılabilmesi İçin Tesisat Projelerinde Dikkat Edilmesi Gereken Bazı Hususlar: Otel Projesi Uygulama Örneği, Kırklareli	
<i>Zeynep Sude AKÇAY, Taner ÇARKIT</i>	

ELEKTRİKLİ ARAÇLARDA ŞARJ İŞLEMİNİN ŞEBEKE ÜZERİNDEKİ TÜKETİM MİKTARININ YAPAY ZEKÂ İLE ÖNGÖRÜLMESİ

Hakan KAYA¹

Selcan Sıla YILMAZ²

Dr. Kadir OLCAY³

Dr. Öğr. Üyesi Arif BAŞGÜMÜŞ⁴

Doç. Dr. Mustafa NAMDAR⁵

- 1- Kütahya Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü.
hakann.kaya0@gmail.com ORCID No: 0009-0005-8872-9887
- 2- Kütahya Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü.
selcansilayilmaz@gmail.com ORCID No: 0009-0001-0060-0677
- 3- Kütahya Dumlupınar Üniversitesi, Dumlupınar Meslek Yüksekokulu.
kadir.olcay@dpu.edu.tr ORCID No: 0000-0001-7918-6482
- 4- Dr. Öğr. Üyesi, Bursa Uludağ Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü.
basgumus@uludag.edu.tr ORCID No: 0000-0002-0611-3220
- 5- Doç. Dr., Kütahya Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü.
mustafa.namdar@dpu.edu.tr ORCID No: 0000-0002-3522-4608

ÖZET

Bu çalışmada, fosil yakıtlı araçların yerini elektrikli araçlara bırakmasıyla ortaya çıkan enerji sistemlerindeki altyapı zorluklarını ele almakta ve çözüm önerileri sunmaktadır. Elektrikli araçların şebeke sistemlerine entegre edilmesi, enerji sistemlerinde kapasite zorlanması ve gerilim düşüşleri gibi sorunlara neden olabilmektedir. Bu sorunların önlenmesi için, şarj istasyonlarının şebeke üzerindeki etkilerinin öngörülmesi gerekmektedir. Bu amaçla, şarj istasyonlarının bağlı olduğu şebekenin simülasyonu ve simülasyon sonuçlarına dayalı tahminler için makine öğrenmesi yazılımının tasarlanması yapılmıştır.


Anahtar Kelimeler – Elektrikli Araçlar, Enerji Sistemleri, Şarj İstasyonu, Şebeke Simülasyonu, Yapay Zekâ.

GİRİŞ

Ulaşım sektörünün temel yapı taşı olan fosil yakıtlı araçlar yerini elektrikli araçlara devretmeye her geçen gün daha da yaklaşmaktadır. Elektrikli araçların ulaşım sistemine dâhil edilmesi aynı zamanda enerji sistemlerine de dâhil edilmesi anlamına gelmektedir. Bu aşamada ortaya çıkabilecek en doğal problem, hiç şüphesiz, elektrikli araç yüklerinin enerji sistemleri üzerindeki kapasite zorlayıcı gerilim düşümü etkileri olmaktadır. Bu problemlerin önüne geçilebilmesi için enerji tedariki gerçekleştirilen sistemlerde oluşabilecek gerilim düşümü veya kapasite zorlanması gibi durumların ön görülmesi gerekmektedir.

Kullanıcıların öngörülemeyen zamanlarda şarj istasyonlarında gerçekleştireceği şarj işlemi şebeke sistemindeki kapasitenin zorlanmasında ve buna paralel olarak gerilim düşümlerine neden olmaktadır. Bu çalışmada, şarj istasyonlarının bağlı olduğu şebekenin simülasyonu ve sonuçlara göre makine öğrenmesi yazılımının tasarımı gerçekleştirilmektedir.

Çalışma kapsamında izlenecek genel adımlar ise Şekil 1’de gösterilen şemada yer almaktadır.



Şekil 1. Genel çalışma şeması.


ŞEBEKENİN SİMÜLE EDİLMESİ

Elektrifikasyonun ana elemanlarından biri olan şebeke sistemleri şarj istasyonlarının genel beslenme havuzlarıdır. Şarj istasyonları bu havuzlardan beslenir ve elektrikli araçların şarj edilmesi bu sayede gerçekleştirilir.

Elektrikli araçların enerjilendirilmesi sürecinin ilk aşaması, şebeke kısmından başlamaktadır. Bu kısımda, MATLAB üzerinden, 6 baralı 3 jeneratörlü ve 3 yüklü temel IEEE referanslı [1] bir şebeke sistemi referans alınarak, Şekil 2’de yer alan genel bir sistem simüle edilmiştir.

Şebeke sistemi tasarımı oluşturulurken, kaynaktan yüke yaklaşımı referans alınmıştır. Bu yaklaşım çerçevesince sistem, aşağıdaki algoritma adımlarınca oluşturulmuştur.


- Jeneratör (Kaynak)
- 3 fazlı alçaltıcı trafo
- Salınım ve gerilim kontrolsüz baraların tasarımı
- İletim hatlarının tasarımı
- Yük baralarının tasarımı
- Yüklerin tasarımı
- Ölçüm cihazlarının (scope) eklenmesi



Şekil 2. Şebeke sisteminin genel görünümü.

Jeneratör (Kaynak) Tasarımı

Enerji sistemlerinde şebekeyi beslemek için birçok kaynak ve yöntem kullanılmaktadır. Bu yöntemler sayesinde elektrik enerjisi elde edilir ve sistem beslenmiş olunur. Günümüzde bu yöntemlerin arasında hidroelektrik, termik ve nükleer santraller olmakla birlikte güneş ve rüzgâr santralleri de yer almaktadır.



Şekil 3. Üç fazlı jeneratörün genel görünümü.

Simülasyonun bu aşamasında sistemin enerjilendirilmesi için MATLAB üzerinde “Three-Phase Source” adlı 3 adet Jeneratör (Şekil 3) modeli kullanılarak referans bir kaynak oluşturulmuştur. Bu kaynak üç fazlı olup, 50Hz’lik sabit bir frekansla çalışmaktadır. Jeneratörlerin her birinin parametreleri ise Şekil 4’te gösterilen tablodaki gibi belirlenmiştir.

Block Parameters: Generator1

Three-Phase Source (mask) (link)

Three-phase voltage source in series with RL branch.

Parameters Load Flow

Configuration: Yg

Source

☐ Specify internal voltages for each phase

Phase-to-phase voltage (Vrms): 1.05

Phase angle of phase A (degrees): 0

Frequency (Hz): 50

Impedance

☒ Internal ☒ Specify short-circuit level parameters

3-phase short-circuit level at base voltage(VA): 10

Base voltage (Vrms ph-ph): 1

X/R ratio: 1


OK Cancel Help Apply

Şekil 4. Üç fazlı jeneratörün parametreleri.

Alçaltıcı trafo (kaynak) tasarımı

Elektrik enerjisi, ilgili jeneratörde üretildikten sonra iletim sistemleri üzerinden minimum kayıpla yüke ulaşabilmesi için yükseltici trafolarla gerilim değerleri yükseltilir. Burada kullanılan 3 fazlı çift sarımlı transformatörler (trafolar), jeneratörün çıkışına AG ucu, iletim sistemine ise OG ucu gelecek şekilde sisteme bağlanmıştır. 3 fazlı ve çift sarımlı trafolar delta (üçgen) modeli ile çalışır.

Simülasyonun bu aşamasında MATLAB üzerinde “Three-Phase Transformer” adlı 3 adet alçaltıcı trafo (Şekil 5) modeli kullanılmıştır. Trafoların her birinin parametreleri ise Şekil 6’da gösterilen tablodaki gibi belirlenmiştir.




Şekil 5. Alçaltıcı trafonun genel görünümü.

Baraların tasarımı

Elektrik üretim sistemlerinde üretilen elektrik enerjisi dağıtım tesislerine ve tüketicilere baralar yoluyla iletilir. Simülasyonda yer alan elektrik şebekesinde toplam 6 adet bara kullanılmıştır. Şebeke içerisindeki baralar ise fonksiyonlarına göre aşağıdaki gibi sınıflandırılmıştır;

- 3.1.1.a Salınım barası
- 3.1.1.b Gerilim kontrolsüz bara
- 3.1.1.c Yük barası




Şekil 6. Alçaltıcı trafonun parametreleri.

Salınım barası

Şebekedeki bütün santrallerin aktif üretimleri hat kayıplarından dolayı kesin olarak bilinmemektedir. Bu yüzden sistemdeki baralardan biri aktif bilinmeyen güç seçilir ve bu baraya salınım barası denir.

Simülasyonun bu aşamasında MATLAB üzerinde “Three-Phase V-I Measurement” adlı 1 adet Salınım Barası (Şekil 7) modeli kullanılmıştır. Simülasyonda yer alan “Bus 1” adlı salınım barasının parametreleri ise Şekil 8’de gösterilen tablodaki gibi belirlenmiştir.




Şekil 7. Salınım barasının genel görünümü.

Şekil 8. Alçaltıcı trafonun parametreleri.


Gerilim kontrolsüz bara

Aktif bilinmeyen güç seçilen salınım barası ve yüklerin doğrudan beslendiği yük baralarının haricinde yer alan baralar gerilim kontrolsüz baralar olarak adlandırılır. Bu baralar salınım barası ve yük baralarının aksine sabit bir gerilim kontrolüne tabi değildirler. Jeneratörün performansına, iletim hatlarının kayıplarına ve yüklerin tüketimine göre pek çok etmeden dolayı sabit bir gerilim düzeyinde değildirler.



Şekil 9. Gerilim kontrolsüz baraların genel görünümü.

Simülasyonun bu aşamasında MATLAB üzerinde “Three-Phase V-I Measurement” adlı 2 adet gerilim kontrolsüz bara (Şekil 9) modeli kullanılmıştır. Simülasyon içerisinde yer alan “Bus 1” adlı gerilim kontrolsüz baranın parametreleri ise Şekil 10’da gösterilen tablodaki gibi belirlenmiştir.




Şekil 10. “Bus 2” gerilim kontrolsüz barasının parametreleri.

Yük barası

Yük baraları şebeke içerisinde tüketimi gerçekleştiren yükün doğrudan beslendiği son dağıtım sistemidir. Burada yer alan baralar yükün etkisinin en çok görüldüğü baralardır.

Simülasyonun bu aşamasında MATLAB üzerinde “Three-Phase V-I Measurement” adlı 3 adet yük barası (Şekil 11) modeli kullanılmıştır. Simülasyonda yer alan “Bus 6” adlı yük barasının parametreleri ise Şekil 12’de gösterilen tablodaki gibi belirlenmiştir.




Şekil 11. Yük baralarının genel görünümü.

Şekil 12. “Bus 6” yük barasının parametreleri.


Yüklerin Tasarımı

Şebeke içerisinde kullanılan yükler, iletim sistemleri üç fazlı olduğu için simulink üzerinde üç fazlı seri RLC yükü kullanılarak simülasyon gerçekleştirilmiştir.

Simülasyonun bu aşamasında Matlab üzerinde “Three-Phase Series RLC Load” adlı 3 adet yük (Şekil 13) modeli kullanılmıştır. Simülasyonda yer alan “Three-Phase Series RLC Load-6” adlı yükün parametreleri ise Şekil 14’te gösterilen tablodaki gibi belirlenmiştir.



Şekil 13. “Three-Phase Series RLC Load-6” yükünün genel görünümü.




Şekil 14. “Three-Phase Series RLC Load-6” yükünün parametreleri


İletim hatlarının tasarımı

Enerji iletim hatlarında kullanılan pi eşdeğer devresi devre sistem empedansı ile paralel iki yarım admitanstan oluşmaktadır. Pi eşdeğer devresinde devre empedansı iletkenin direnç (R) ile reaktans değerleri (L) toplamına, admitans ise kapasitans (C) değerine eşittir.

Simülasyonun bu aşamasında MATLAB üzerinde “Three-Phase Series R-L-C Branch” adlı 11 adet pi eşdeğer devresi (Şekil 15) modeli kullanılmıştır. Örneğin, simülasyon içerisinde yer alan “Three-Phase Series R-L-C Branch-13” adlı pi eşdeğer devresinin parametreleri ise Şekil 16’da gösterilen tablodaki gibi belirlenmiştir.




Şekil 15. Pi eşdeğer devresinin genel görünümü.




Şekil 16. Three-Phase series R-L-C branch-13 parametreleri.

Ölçü sistemlerinin modellenmesi

Simülasyon içerisinde yer alan ölçüm operatörleri sistem üzerinde gerçekleşen akım ve gerilim değişimlerinin hem sayısal hem de görsel olarak tespit edilmesini sağlarlar. Bu çalışmada Şekil 17’de gösterilen 3 adet scope; salınım ve gerilim kontrolsüz baralara bağlanmıştır. İlgili baralar ilk etapta enerji kaynağından doğrudan beslendiği için buradaki scope’lar sayesinde simülasyon boyunca enerji sistemi tarafındaki değerler gözlemlenebilmektedir.




Şekil 17. Salınım ve gerilim kontrolsüz baralara yerleştirilen scope’ların genel görünümü.



Şekil 18. Yük baralarına yerleştirilen scope'ların genel görünümü.

Şekil 18'de gösterilen 3 adet scope ise yük baralarına bağlanmıştır. İlgili baralar yük üzerinden beslendiği için buradaki scope'lar sayesinde simülasyon boyunca şarj istasyonlarının dışındaki yüklerin akım ve gerilim değerleri gözlemlenebilmektedir.

Örneğin, simülasyonun çalışma süresince “Bus 4” ölçüm gösterge operatörüne yansıyan veri grafiği Şekil 19'daki gibi gözlemlenmiştir.



Şekil 19. “BUS-4” barasının ölçüm grafiği.

YAZILIM AŞAMASI

Kısa dönem tüketim tahmininin doğruluğu güç sistemleri için önemli bir parametredir. Tüketim tahmini, geçmişteki tüketim verilerinin incelenerek gelecekteki tüketim durumunun tahmin edilmesine dayanır. Bu tahmin ile şebekeyi gerçek zamanlı olarak kontrol altına alıp elde edilen veriler ile şebeke yönetim sistemi oluşturulmuştur. Geçmiş verileri kullanarak oluşturulmuş algoritma ile gelecek veriler için tahmin sisteminin modellenmesinde değişimler göz önüne alınarak, tüketicilere daha hızlı, güvenilir ve kaliteli enerji sunmak, sistem ünitelerinin çalışmasının planlanması için önemli bir etken olmuştur.

Bu çalışmada, kısa dönem olarak elektrikli araçlarda harcanan elektrik miktarı değerlendirilerek tahmin algoritmasının elde edilmesi, makine öğreniminin en yaygın yöntemi olan regresyon analizi ile sağlanmıştır.

Makine Öğrenimi

Makine öğrenimi, örnek verileri veya veri yığını içinde öğrenme geçirmiş deneyimleri kullanarak performans ölçütlerini optimize etmek için kullanılan programlama yöntemidir. Çalışmadaki temel makine öğrenimi prensibi Şekil 20’de gösterilmiştir [2].



Şekil 20. Temel makine öğreniminin çalışma prensibi.

Makine öğrenmesi, algoritmalarla oluşur. Bu algoritmalar programlanmadan, tahminler veya kararlar vermek için öğrenme verilerine dayalı bir matematiksel model oluşturur. Sonrasında model, analizlere dayalı olarak en iyi kararları ve tahminleri yapmak için eğitilir.

Programlama için kullanılacak makine öğrenmesi yönteminde, bilgiyi sayısallaştırıp veriye dönüştüren, toplayan, birleştiren ve kıyaslama yapan model ile ortak değerlendirmenin iyi anlaşılması için, Google’un sunmuş olduğu Colaboratory ortamda Python dili ile kodlanmıştır. Python, makine öğrenmesi ve yapay zekâ uygulamalarında oldukça kullanışlı ve popüler bir dildir [3]. Google Colab, yapay zekâ uygulamaları geliştirmek için

kullanılan, ücretsiz GPU ve RAM desteği sağlayan bir bulut hizmetidir. Geliştirilmiş olan makine öğrenmesi modelinde gerekli olan algoritmaların ve yöntemlerin hızlı ve doğru bir şekilde işlenebilmesi için tercih edilen Google Colab, kişisel bilgisayarlarda GPU kullanımının yaygın olmaması, CPU'ların hiç yapılandırma gerektirmemesi ve kolay paylaşım imkânı sunması nedeni ile seçilmiştir.

Regresyon Analizi

Makine öğrenmesi, değerleri tahmin etmek için regresyon analiz algoritmalarını kullanır. Regresyon analizi, değişkenler arasındaki ilişkiyi incelemek ve geçmiş verilere dayanarak sonraki tahminleri elde etmek için kullanılmaktadır. Serbest X_1 , X_2 , X_3 ve Y bağımlı değişken ölçülerine dayanan Y ile X_1 , X_2 , X_3 değişkenleri arasındaki fonksiyonel ilişkiye regresyon analizi adı verilmekte ve (1)'deki gibi gösterilmektedir [4].


$$Y = f(X_1, X_2, X_3, \dots) \quad (1)$$

Fonksiyonel ilişki sayesinde, X_1, X_2, X_3 serbest değişkenleri ölçülerek ve ölçülemeyen Y değeri işlemler ile tahmin edilebilmektedir. Regresyon algoritmaları, girdi (X) özellikleri ile çıktı (Y) arasındaki ilişkiyi modelleyen istatistiksel bir yaklaşım olup veri kümesine ait birden fazla sayıda fonksiyon elde edilir. Bu durumda doğru fonksiyon seçimine göre analiz edilir. Regresyon analizi ile değişkenlerin geçmiş verileri baz alınarak gelecekte ne gibi sonuçlar elde edilebileceği tahmin edilmekte ve öngörüsül analiz yapılmasına yardımcı olunmaktadır.

Lineer (Doğrusal) regresyon analizi

Lineer regresyon analizi; bağımsız değişkenlere dayanan istatistiksel tahmin değerini modelleyen makine öğrenimi yöntemidir. Bu analiz, değişkenler ve tahmin arasındaki ilişkiyi bulmak için kullanılır. Tahmin etmek istenilen değişken, bağımlı değişken, değerini tahmin etmek için kullanılan değişken ise bağımsız değişkendir.

Lineer regresyon, bir dizi noktaya en uygun düz çizgiyi bulmak için kullanılmaktadır. Şekil 21'de gösterilen lineer regresyon, en uygun kırmızı düz çizgi kullanarak bağımlı değişken $E(Y_i)$ ile bir veya daha fazla bağımsız değişken arasındaki bir ilişkidir [5].



Şekil 21. Lineer regresyon analizi.

Lineer regresyon analizi değişkenler arasında bulunduğu kabul edilen gerçek doğrusal ilişkiyi vermektedir. Doğrusal regresyonda $E(Y_i)$ ile X_i arasındaki fonksiyonel ilişki (2) ile bulunmaktadır.


$$E(Y_i) = \beta_0 + \beta_1 X_i \quad (2)$$

Burada (Y_i) bağımlı değişken (çıkıtı), X_i bağımsız değişken (girdi)'dir. β_0 ; sabit olup $X = 0$ olduğunda Y_i 'nin aldığı değerdir. β_1 ise doğrunun eğimi olup X deki birim değişim ile $E(Y_i)$ arasındaki değişim oranını tanımlamaktadır.

Bir modelde Y_i kendi ana kütle ortalamasından $E(Y_i)$ sapması matematiksel modele bir hata terimi n eklenerek açıklanmaktadır. Bu noktada doğrusal regresyon denklemi (3) şeklinde olmaktadır [6].

$$E(Y_i) = \sum_{i=1}^n [\beta_0 + \beta_1 X_i] + n \quad (3)$$

Şekil 22'de lineer regresyon analiz örneğinde, siyah noktalar asıl veri noktaları, yani x ve y ; mavi doğru, en küçük kareler yöntemi ile hata mesafesinin minimum olduğu en uygun doğrudur. Kırmızı çizgiler, gözlenen (gerçek) veri ile en uygun doğru arasındaki mesafedir. Hatalar (bias) doğrunun eğimi β_1 katsayısı ile bulunur. $x=0$ olduğunda y doğrusunu kesen nokta ise β_0 katsayısı ile tespit edilir.




Şekil 22. Lineer regresyon analiz örneği.

Doğrusal olmayan regresyon analizi

Doğrusal olmayan regresyon modelleri makine öğrenmesi algoritması olup doğrusal modeller gibi denklemle gösterilirken, denklemdeki parametre sayısı verideki değişken sayısıyla doğrudan ilişkisi olmadığı için daha karmaşık veri kümeleri kullanılır. Bu regresyon modellerinde model parametreleri doğrusal değildir ancak bağımsız değişkenler doğrusal yapıda olabilir.

Doğrusal olmayan ilişkiler, verilen bağımsız değişken veya değişkenlere dayalı olarak bir bağımlı değişkeni tahmin etme işlevini gerçekleştirir. Böylece, bu regresyon tekniği, bağımlı bir değişken ile verilen diğer bağımsız değişkenler arasında doğrusal olmayan bir ilişki kurar. Şekil 23'te bulunan iki grafikte de regresyon çizgisi (Kırmızı çizgi) doğrusal olarak ilerlememektedir. Çoğu veri setlerinde de bağımlı ve bağımsız değişkenler arasında bu gibi durumlar gözlenmektedir [7].



Şekil 23. Doğrusal olmayan ilişkiler.

Elektrik araçlarının şarj işlemi sırasında, şebekeye etki eden çok sayıda parametresi vardır. Buna bağlı olarak, şebekeden çekilen elektrik miktarının yoğunluğa göre analiz edilmesinde, farklı saatlerde yoğunluk miktarı doğrusal (linear) değişmemektedir. Tanımlanmış olan makine öğrenmesi problemi ve öğrenme stratejisi ile ilişkili olarak, pek çok makine öğrenmesi algoritması bulunmaktadır. Bu çalışma kapsamında, *K-neighbors Regressor* makine öğrenimi algoritmaları ile model oluşturulmuştur.

K-Nearest Neighbours (en yakın komşu algoritması) (KNN), denetimli öğrenme yöntemlerinden biri olan sınıflandırma ve regresyon için kullanılan çok yönlü bir algoritmadır. Bağımlı değişken değerini, bağımsız değişkenlerin en yakın komşularının ortalamasını alarak, yaklaşık tahmin eden bir yöntemdir [8]. Kullanımı için "*K-NeighborsRegressor*" kütüphanesinin içe aktarılması gerekmektedir. Şekil 24'te gösterilmiştir.

```
from sklearn.neighbors import KNeighborsRegressor
```

Şekil 24: K-Neighbors Regressor kütüphanesi gösterimi.

Makine öğrenmesi yazılım uygulama süreci

Elektrikli araçların şarj işlemi sırasında şebekeye etkisinin analiz edilmesi için MATLAB simülasyon çalışmasından veriler elde edilmiştir. Bu verilere göre elektrikli araçlarda kısa süreli tüketilen elektrik miktarı hesabını

yaparken regresyon modellerinden yararlanılmıştır. Şekil 25’te araştırmanın adım adım yazılım kısmı gösterilmiştir.



Şekil 25. Yazılım şeması.

Veri setleri ve regresyon yöntemi ile oluşturulan modelin yazılımı Şekil 26’da gösterilmiştir.

```
[ ] # Kütüphanelerin Yüklenmesi

from sklearn.metrics import mean_squared_error
from sklearn.metrics import mean_absolute_error
from sklearn.model_selection import train_test_split
from sklearn.neighbors import KNeighborsRegressor
import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
import warnings
warnings.filterwarnings("ignore")
```

```
[ ] # Veri Seti Dosyası Okunması

veri = pd.read_csv('simulasyonverileri.csv')
print(veri.describe())

x = veri["saat"]
y = veri["tuketim"]
```

```
[ ] # Verilerin Görselleştirilmesi

x=veri["saat"]
y=veri["tuketim"]
plt.xlabel("saat")
plt.ylabel("tuketim")
plt.title('saate Göre tüketim')
plt.scatter(x,y)
plt.show()
```

```
[ ] # Veri Setinden Bağımlı ve Bağımsız Değişkenleri Oluşturma

x = veri.iloc[:, :-1].values
y = veri.iloc[:, 1].values
```

```
[ ] # Değişkenlerimizi Eğitim ve Test Olmak Üzere İkiye Bölme

x_train, x_test, y_train, y_test = train_test_split(x, y, test_size=0.20, random_state=0)
```

```
[ ] # Eğitim/Test Verisi Ayrılması
# import the regressor
# create a regressor object
regressor = KNeighborsRegressor(n_neighbors=2)
```

```
[ ] # Fit the regressor with X and Y data
regressor.fit(x_train, y_train)
```

```
[ ] # Model Üzerinde Tahminler Yapma
y_pred = regressor.predict(x_test)
```

```
[ ] # Making Predictions

input_value = float(input(Yogunluğu öğrenmek için saat giriniz'))
score = regressor.predict([[input_value]])[0]
print(score)
```

```
[ ] # Tahminleme Modelini Görselleştirme

y_pred_all = []
for i in range(10):
    y_pred_all.append(regressor.predict([[i]]))

plt.scatter(x, y, color='red')
modelin_tahmin_ettigi_y = regressor.predict(x_train)
plt.plot(x, y_pred_all, color='blue')
plt.title('sate göre tüketim tahmini Regresyon Modeli')
plt.xlabel('saat')
plt.ylabel('tüketim')
plt.show()
```

Şekil 26. Model yazılımı.

PERFORMANS ÖLÇÜTLERİ VE SONUÇLAR

Sadece model oluşturmak yeterli değildir. Model oluşturulduktan sonra performansı değerlendirilmelidir. Aksi takdirde oluşturulan modelin verimliliği analiz edilemez. Bu durumda, model hakkında yorum yapılması ve doğru sonuca ulaşılması engellenir. Bir sonraki zaman dilimlerinde şebekeden çekilen elektrik miktarını kontrol etmek için gerçek değer ile tahmin arasındaki benzerliğe göre, modelin performansını değerlendirmek önemlidir. Bu doğrultuda algoritma başarısı hesaplanmış ve Şekil 27’de ifade edilmiştir.

Elde edilen performansın geliştirilmesi / iyileştirilmesi için çeşitli yöntemlerden faydalanılmaktadır. Yapılan araştırmada tahmin sonucunun gerçek değerden ne ölçüde uzak olduğunu hesaplamak için kullanılan fonksiyonlar: ortalama mutlak hata (Mean Absolute Error, MAE), ortalama kare hata (Mean Squared Error, MSE) ve kök ortalama kare hatası (Root Mean Squared Error, RMSE) ile ifade edilmektedir [9]. Burada amaç, en küçük değere sahip sonuca ulaşmaktır.

Oluşturulan modelin performansının değerlendirilmesi ölçütlerinden biri olan ortalama mutlak hata, oluşturulan tahmin çıktısı ile gerçek değer arasındaki farkı ifade eder ve aşağıda (4) ile tanımlanır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (4)$$

Modelde kullanılan diğer performans ölçütü hataların dağılımını ölçen ortalama kare hata, tahmin değerlerinin gerçek değerlerden farkının karesinin ortalaması olarak hesaplanır ve (5) ile ifade edilir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (e_i)^2 \quad (5)$$

Kök ortalama kare hatası ise tahmin değerleri ile gerçekleşen değerler arasındaki farklar üzerinden modelin performansını değerlendirir. Denklem (6)’da bu performans ölçütü gösterilmiştir.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i)^2} \quad (6)$$

```
# Gerçek değerle tahmin arasındaki hatayı hesaplama

mae = mean_absolute_error(y_pred, y_test)
mse = mean_squared_error(y_pred, y_test)
rmse = np.sqrt(mse)

print('Mean Absolute Error (MAE): %.2f' % mae)
print('Mean Squared Error (MSE): %.2f' % mse)
print('Root Mean Squared Error (RMSE): %.2f' % rmse)
```

Şekil 27. Model performansı.

TEŞEKKÜR

Bu çalışma 1919B012102347 başvurusu numarası ile TÜBİTAK 2209-A üniversite öğrencileri araştırma projeleri destekleme programı kapsamında desteklenmiştir.

REFERANSLAR

- [1] <https://www.al-roomi.org/power-flow/6-bus-systems/system-i>
- [2] https://www.researchgate.net/publication/357974983_Makine_Ogrenmesi_-_Machine_Learning
- [3] <https://colab.research.google.com/notebooks/welcome.ipynb?hl=tr>
- [4] Ceylan, G., (2004), Yapay Sinir Ağları ile Kısa Dönem Yük Tahmini, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [5] <https://www.ibm.com/tr-tr/analytics/learn/linear-regression>
- [6] Koçbey, M.E., (2019), Bursa İli Elektrik Gücü Talep Tahmin Analizi, Yüksek Lisans Tezi, Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Balıkesir.
- [7] [https://arinway.com/Subject/SubjectDetails/1198?name=II.-Do%C4%9Frusal-Olmayan-%C4%B0li%C5%9Fkiler-\(Non-Linear-Relationships\)](https://arinway.com/Subject/SubjectDetails/1198?name=II.-Do%C4%9Frusal-Olmayan-%C4%B0li%C5%9Fkiler-(Non-Linear-Relationships))
- [8] Dilki G., Başar, Ö.D., (2020), İşletmelerin İflas Tahmininde K-En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması, İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, İstanbul.
- [9] Küçükönder, H., (2011), Yapay sinir ağları ve tarımda bir uygulama, Doktora Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş, 4, 86-87.