



Deep learning based residential load identification model and performance analysis

Ardan Hüseyin Eşlik*, Emre Akarslan, Rasim Doğan

Department of Electric Engineering, Faculty of Engineering, Afyon Kocatepe University, 03204, Afyonkarahisar, Türkiye

Highlights:

- A novel CNN deep learning model for residential load identification is proposed
- Residential load current data measured at Afyon Kocatepe University laboratories are used
- Comparisons with other machine learning methods have demonstrated the feasibility of the model

Keywords:

- Residential Load Identification
- Deep Learning
- Time Series Classification
- Convolutional Neural Network
- Machine learning

Article Info:

Research Article

Received: 25.04.2024

Accepted: 06.01.2025

DOI:

10.17341/gazimmfd.1473453

Correspondence:

Author: Ardan Hüseyin Eşlik
e-mail:

ardanhuseyineslik@gmail.com

phone: +90 272 218 2487

Graphical/Tabular Abstract

In this study, a novel method based on Convolutional Neural Network (CNN) deep learning has been proposed for identifying residential loads, and the feasibility and performance of the method have been investigated. Initially, six different loads commonly found in residences are identified, and the load datas are collected individually and in various combinations. These data are utilized to develop machine learning models including the proposed model, as well as Random Forest, Decision Trees, and K-Nearest Neighbor models, which are frequently employed for similar purposes in the literature. Subsequently, the identification results of residential loads for all models are compared using performance metrics, determining that the CNN model proposed in this study achieved the most successful identifications. Figure A illustrates the flowchart of the proposed CNN-based load identification approach.




Figure A. Proposed CNN deep learning model flow chart

Purpose:

Responding to the rapidly changing energy needs of the modern era has made the management of residential energy increasingly critical. This study aims to develop a new Convolutional Neural Network (CNN) based deep learning model to achieve more successful identification of residential loads. The objective is to demonstrate that the proposed deep learning-based model outperforms traditional machine learning models and showcases its applicability.

Theory and Methods:

With the proliferation of smart home technologies, the efficient identification and management of residential loads are gaining prominence. Within this framework, a novel CNN-based deep learning model is introduced for residential load identification. The study incorporates data measurements from six distinct loads conducted at the laboratories of Afyon Kocatepe University. The efficacy and suitability of the proposed model are evaluated through comparisons with various machine learning methodologies including Decision Tree Regression, Random Forest Regression, and K-Nearest Neighbour.

Results:

The identification performance of the proposed CNN model has been compared with other machine learning methods using four different statistical evaluation criteria (accuracy, precision, recall, F-score). The results indicate that the CNN model outperforms other comparative models in terms of all statistical evaluation criteria, establishing itself as the most successful predictive model.

Conclusion:

In this study, a novel deep learning model based on CNN for the identification of residential loads has been proposed and its performance and applicability have been investigated. The results demonstrate that the proposed CNN-based deep learning model outperforms machine learning algorithms in all accuracy, precision, recall, and F-score statistical evaluation criteria, indicating its effectiveness in the identification of residential loads.



Derin öğrenme tabanlı konut yükü tanımlama modeli ve performans analizi

Ardan Hüseyin Eşlik*, Emre Akarslan, Rasim Doğan

Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, 03204, Afyonkarahisar, Türkiye

ÖNEÇIKANLAR

- Konut yükü tanımlaması için CNN derin öğrenme ağı ile oluşturulmuş özgün bir derin öğrenme modeli
- Afyon Kocatepe Üniversitesi laboratuvarlarında toplanan verilerle üç farklı modelin performans karşılaştırması
- Diğer modellere oranla yüksek konut yükü tanımlama performansı

Makale Bilgileri

Araştırma Makalesi

Geliş: 25.04.2024

Kabul: 06.01.2025

DOI:

10.17341/gazimmfd.1473453

Anahtar Kelimeler:

Konut yükü tanımlaması,
derin öğrenme,
evrişimli sinir ağları,
zaman serisi sınıflandırması,
makine öğrenmesi

ÖZ

Modern çağın hızla değişen enerji ihtiyaçlarına cevap vermek, evlerin enerji yönetimini daha da kritik hale getirmektedir. Akıllı ev teknolojilerinin yükselişiyle birlikte, konut yüklerinin etkili bir şekilde tanımlanması ve yönetilmesi giderek daha büyük bir önem kazanmaktadır. Bu çalışmada, konut yükü tanımlaması için CNN derin öğrenme tabanlı yeni bir yaklaşım önerilmiştir. Önerilen modelin etkinliği ve uygulanabilirliği, geleneksel makine öğrenimi yöntemleri olan Rastgele Orman, Karar Ağaçları ve K-En Yakın Komşu ile karşılaştırılarak değerlendirilmiştir. Afyon Kocatepe Üniversitesi laboratuvarlarında gerçekleştirilen deneysel verilerle desteklenen çalışma sonuçları, CNN derin öğrenme modelinin doğruluk, kesinlik, duyarlılık ve F-ölçütü gibi kritik metriklerde en üstün performansı sergilediğini ortaya koymuştur.

Deep learning based residential load identification model and performance analysis

HIGHLIGHTS

- A novel deep learning model built with CNN deep learning network for residential load identification
- Performance comparison of three different models with data collected at Afyon Kocatepe University laboratories
- High residential load identification performance compared to other models

Article Info

Research Article

Received: 25.04.2024

Accepted: 06.01.2025

DOI:

10.17341/gazimmfd.1473453

Keywords:

Residential load
identification,
deep learning,
convolutional neural
networks,
time series classification,
machine learning

ABSTRACT

In light of the rapidly evolving energy demands of the modern era, it is becoming increasingly clear that home energy management is more crucial than ever. With the advent of smart home technologies, the effective identification and management of loads is becoming a crucial area of focus. In this paper, we present a novel CNN deep learning-based method for residential load identification. We evaluate the effectiveness and applicability of the proposed model by comparing it with traditional machine learning methods such as Random Forest, Decision Trees and K-Nearest Neighbor. The results of the study, which were supported by experimental data from Afyon Kocatepe University laboratories, indicate that the CNN deep learning model may offer the most promising performance in critical metrics such as accuracy, precision, sensitivity and F-measure.

1. Giriş (Introduction)

Artan nüfus ve gelişen ticari faaliyetler, konut ve işyerlerindeki elektrik yüklerinde belirgin bir artışa yol açmıştır [1-2]. Bu artış, elektrik enerjisi talebinde de gözle görülür bir yükselişe neden olmuştur. Elektrik enerjisinin etkin bir şekilde kullanımı hem konut hem de ticari sektörlerde mümkündür [3]. Konutlardaki cihazların uygun bir şekilde izlenmesi ve modellenmesi, tüketim deseninin belirlenmesine yardımcı olabilir. Böylece, enerji yönetimi uygulamalarında daha etkili bir rol oynayabilir. Konutlardaki elektrik yüklerinin izlenmesi için kullanılan bir teknik, bir konutun giriş noktasında mevcut gerilim ve akımın toplam birleşik bilgisini kullanarak ev yüklerini izlemektir [4-7]. Bu teknik, müdahaleci olmayan yük izleme (NILM) olarak adlandırılır. NILM, akıllı sayaçlar aracılığıyla enerji izlemede hayati bir rol oynamakta ve bilgi iletişimine olanak tanımaktadır. Akıllı sayaçlar, belirli bir sistemin enerji tüketimine ilişkin özel bilgileri ölçmek için kullanılabilir. Bu durum enerji şirketlerine tüketim zamanına ve mevsime bağlı olarak farklı ücretler belirleme olanağı sağlamaktadır. Ayrıca, dalgalanma gerilimleri ve harmonik bozulmalar gibi elektrik kalitesiyle ilgili ölçümleri sağlamakta, bu da güç kalitesinin analizini mümkün kılmaktadır.

Elektrik yük izleme teknikleri, genellikle müdahaleci yük izleme (ILM) ve müdahaleci olmayan yük izleme (NILM) olarak iki ana kategoriye ayrılabilir [3, 8]. İlk olarak, ILM tekniğinde, her bir cihaza bir dizi sensör bağlanabilir. Ancak, bu yöntem daha pahalı ve daha fazla alan gerektirir, bu nedenle konutlar için uygun değildir. Diğer yandan, NILM sadece yük izlemesi için bir dizi gerilim ve akım sensörü gerektirir. Genellikle, NILM teknikleri, akıllı sayaç verilerinden yalnızca elektrikli cihazları ayırabilir. Ancak, düşük örnekleme veri oranıyla NILM'in uygulanması oldukça zor olabilir. Hart tarafından ilk kez tanımlanan NILM tekniğinden bu yana [4], cihazlar için tanımlama ve elektrik tüketimi izlemesi için birçok farklı yöntem önerilmiştir. Bu yöntemler, sistemde bulunan elektrikli cihazların belirlenmesi, bunların tüketimlerdeki değişimlerin izlenmesi ve etkin enerji yönetimi stratejilerinin geliştirilmesi gibi bir dizi farklı amaç için kullanılabilir.

Bu kapsamda, konutlardaki enerji yönetimi gereksinimlerine uygun bir cihaz tanımlama süreci geliştirilmesi çalışmamızın temelini oluşturmuştur. Gerçekleştirilen çalışmada, cihaz tanımlama süreci, konutlarda enerji tüketiminin verimli yönetimi için kritik bir adım olarak ele alınmıştır. Cihaz tanımlama, elektrik yüklerinin öngörülebilir ve yönetilebilir hale getirilmesi amacıyla ilk adımdır. Tanımlama sürecinin ardından, belirlenen cihazların tüketim karakteristikleri dikkate alınarak toplam enerji tüketiminin analizi ve tahmini yapılabilir. Bu sayede, enerji tüketiminin daha etkin bir biçimde yönetilmesi mümkün hale gelmektedir. Bu bağlamda, çalışmada derin öğrenme yöntemlerinden evrişimli sinir ağı (CNN) modeli kullanılarak konut yükü tanımlamaları gerçekleştirilmiş ve ilgili modelin performansı ve uygulanabilirliği değerlendirilmiştir. Çalışmada Afyon Kocatepe Üniversitesi laboratuvarlarında gerçekleştirilen deneyler sonucunda toplanan yük akımı verilerinden yararlanılmıştır. Bu deneylerde ev ortamlarındaki yaygın kullanımları dikkate alınarak altı farklı ev aleti (monitör, lamba, dizüstü bilgisayar şarj cihazı, elektrikli süpürge, ısıtıcı ve su ısıtıcısı) kullanılmıştır. Deneyler, her bir cihazın tekil veya çeşitli kombinasyonlarla çalıştırılmasıyla laboratuvar ortamında gerçekleştirilmiştir. Son olarak, önerilen modelin çıktıları, çeşitli makine öğrenimi yöntemleriyle kıyaslanarak performans ve etkinlik değerlendirmeleri yapılmıştır.

Çalışmanın organizasyonu şu şekilde planlanmıştır: Bölüm 2'de literatürde gerçekleştirilen benzer çalışmalar, Bölüm 3 materyal metot

başlığı altında verilerin toplanma süreci ve evrişimli sinir ağları açıklanmıştır. Bölüm 4'de verinin hazırlanma süreci ve gerçekleştirilen deneysel çalışmalardan bahsedilmiştir. Bölüm 5'de ise deneysel çalışmalara ait analiz sonuçlarına yer verilmiştir.

2. İlgili Çalışmalar (Related Studies)

Günümüze kadar konut yükü tanımlama alanında farklı birçok çalışma yapılmıştır. Aşağıda yük tanımlama amacıyla gerçekleştirilmiş olan bu çalışmalardan önemli görülen birkaçı sunulmuştur.

Le vd. [9], NILM'de yük tanımlama doğruluğunu artırmak için Hilbert dönüşümü ve Sıralı Uzun Kısa Süreli Bellek (Seq2Seq LSTM) tabanlı yeni bir yöntem olan HT-LSTM'i sunmuşlardır. HT-LSTM, Amplitude-Phase-Frequency (APF) adlı bir Hilbert dönüşümü tabanlı transiyent özelliği oluşturmada ve bu özellikleri girdi verisi olarak kullanarak cihaz tanımlaması yapmaktadır. HT-LSTM yöntemi, BLUED ve PLAID gibi yüksek frekanslı açık erişimli veri setleri ve laboratuvarlarda toplanan özel bir veri seti kullanarak değerlendirilmiştir. Deney sonuçları önerilen yöntemin, tüm veri setlerinde F-ölçütüne göre diğer yöntemleri geride bıraktığını ortaya koymuştur. Ghosh vd. [1], evlerde gelişmiş yük özelliklerinin çıkarılması için bir fuzzy tabanlı NILM yöntemi önermişlerdir. Önerilen yöntem, ev içi yüklerin tanımlanma doğruluğunu iyileştirmekte ve kaynak ucundaki yükler tarafından üretilen enjekte harmonikleri sınırlamaktadır. Bulanık teknik kullanımının, geleneksel makine öğrenimi tekniklerine göre işlemci belleği gereksinimini azalttığını tespit etmişlerdir. Simülasyonlarla desteklenen deneysel sonuçlar, önerilen yöntemin geçerliliğini doğrulamıştır. Ghosh vd. [10] konut yük sistemindeki harmonik kirlilik yüklerinin tanımlanması için geliştirilmiş bir teknik sunmuşlardır. Önerilen yük izleme tekniğinde, sadece bir konut sisteminin toplam voltaj-akım verileri kullanılmıştır. Bu teknikte, yapay ayni kolonisi (ABC) algoritması gibi bir arama tabanlı optimizasyon kullanılmaktadır. Teknik, PLAID veri setleri kullanılarak doğrulanmış ve bazı önde gelen tekniklerle karşılaştırılmıştır. Önerilen metodolojinin yeteneğini göstermek için bir konut sistemi üzerinde uygun simülasyonlar ve deneysel veri seti yapılmıştır. Analiz sonucunda tekniğin yük tanımlama problemlerinde başarılı bir şekilde kullanılabileceği sonucuna ulaşılmıştır. Kumar vd. [11] benzer türden yüklerin tanımlanması için bir yük izleme sistemi geliştirmişlerdir. Çalışmada, aynı modelden farklı markaların hava koşullandırıcıları göz önünde bulundurulmuştur. Yük sınıflandırması için güç ve özel özelliklerden oluşan yeni bir özellik seti önerilmiştir. Bu yeni özellik setiyle yapılan çalışmalar, aynı modelden ve aynı markadan yüklerin sınıflandırmasında iyileştirilmiş performans göstermiştir. Ayrıca, yüklerin sınıflandırılmasını daha da iyileştirmek için yerel kısıtlı lineer kodlama (LLC) gibi bir özellik eşleştirme teknikleri kullanılmıştır. Han vd. [12] yük tanımlama için V-I (voltaj-akım) izdüşümünü kullanan bir yöntem önermişlerdir. Önerilen yöntem, yük tanımlamayı büyük ölçekli yaklaşık en yakın komşu aramasına dönüştürmektedir. Yeni yöntem, sorgu görüntülerini ve veritabanı görüntülerini asimetrik bir şekilde işleyerek doğruluğu artırmayı amaçlamaktadır. Deneysel sonuçlar, önerilen yöntemin REDD ve PLAID veri setlerinde yük tanımlama doğruluğunu önemli ölçüde artırdığını göstermiştir. Hu vd. [13] konut cihazları için ultra-seyrekleme ve gerçek zamanlı hesaplama temelli bir NILM yöntemi önermişlerdir. Bu yöntem, olay tespiti, özellik çıkarma ve yük tanımlama adımlarını içermektedir. Yöntem, karmaşık başlangıç süreçlerine sahip cihazların olay tespiti için bir dalgaletti ayrıştırma tabanlı standart sapma çoğulu (WDSM) kullanmaktadır. Ayrıca, yük tanımlaması için önemli bir özellik olan çoklu aşım (overshoot multiple) tanımlanmıştır. Önerilen yöntem, yük tanımlama doğruluğunu artırmak için değiştirilmiş ağırlıklı K-en yakın komşular (KNN) ve

çoklu aşımalar kombinasyonunu kullanmaktadır. Li vd. [14] yük tanımlamasını geliştirmek için bir yığın ensemble öğrenme (SEL) tabanlı bir metodoloji önermişlerdir. Önerilen yöntem, fiziksel ve siber özellik tanımlayıcılarını entegre ederek özellikleri uygun sınıflandırıcılarla birleştirmektedir. Yapılan deneyler, önerilen yöntemin evsel yükler için tanımlama performansını önemli ölçüde artırdığını ve önceki yöntemleri geride bıraktığını göstermiştir. Ghosh vd. [15] yüksek boyutlu özellik setlerinden türetilen özelliklerin tanımlanması için t-dağıtımli stokastik komşu yerleştirme (t-distributed stochastic neighbour embedding - t SNE) tabanlı boyut azaltma yöntemi kullanarak, NILM için çapraz-korelasyon tabanlı sınıflandırma yöntemi önermişlerdir. Deneysel sonuçlar, çıkarılan özelliklerin farklı ve birleşik konut yüklerinin güvenilir tanımlanması ve sınıflandırılması için uygun olduğunu göstermiştir. Hosseini vd. [16] Quebec konutlarında NILM üzerine uygulamalı bir araştırma sunmuşlardır. Gerçek verileri kullanarak bir karşılaştırmalı istatistik analizi yapmışlar ve bu çalışmada Quebec evlerinde NILM zorluklarına çözüm getirmek için birleşik bir yaklaşım önermişlerdir. Önerilen teknikler, gözetimli ve gözetimsiz makine öğrenimi tasarımlarına dayanmaktadır ve coğrafi bağımlı durumların mevcut NILM yöntemlerinin performansını olumsuz etkilediğini göstermektedir.

Son yıllarda, derin öğrenme yöntemlerinin gelişimiyle birlikte, ev içi elektrik tüketimini analiz etmek amacıyla NILM sistemlerinde Evrişimli Sinir Ağları'na (Convolutional Neural Networks - CNN) dayalı çeşitli metodolojiler yaygınlaşmıştır [17-20]. Bu çalışmalar, genellikle transient (geçici) duruma dayalı sinyal analizi üzerine kuruludur. Bu yöntemler, bir yükün devreye girdiği anki ani değişiklikleri yakalayarak yük tanımlamasını gerçekleştirmektedir. Olay algılama (event detection) mantığı, yüklerin sisteme dahil olduğu anlarda ortaya çıkan geçici sinyal değişimlerine odaklanır ve bu sinyal örüntülerinin, geçmişteki yüklerin aktif durumuyla karşılaştırılması yoluyla yeni yüklerin tespiti sağlanır. Ancak bu yaklaşımın etkinliği, her yeni yük devreye girdiğinde bu olayın doğru bir şekilde algılanabilmesine bağlıdır. Ayrıca, yeni yükün yarattığı değişimlerin doğru bir şekilde değerlendirilebilmesi için sistemde zaten çalışan yüklerin sürekli izlenmesi ve takip edilmesi gerekmektedir. Özellikle gerçek zamanlı uygulamalarda, transient durumda yaşanabilecek sinyal kayıpları ya da kaçırılan olaylar, yük tanımlama doğruluğunu olumsuz etkileyebilir ve sistemin güvenilirliğini azaltabilir.

Önerilen yöntem, literatürdeki transient duruma dayalı yaklaşımlardan belirgin bir şekilde ayrılmaktadır. Bu çalışmada, yük tanımlaması için transient durum sinyallerine veya önceki sistem durumuna ilişkin bir bilgiye ihtiyaç duyulmamaktadır. Bunun yerine, sinyalin steady-state (kararlı durum) kısmına odaklanılarak, sinyalin

durağan hale geldiği herhangi bir zaman diliminde, o anda devrede olan tüm yüklerin toplu olarak tespit edilmesi sağlanmaktadır. Bu yaklaşım, transient sinyallere olan bağımlılığı ortadan kaldırmakta ve sürekli izleme gereksinimi olmaksızın, yüklerin daha esnek ve kapsamlı bir şekilde tanımlanmasına olanak tanımaktadır. Özellikle transient sinyal değişimlerinin kaçırılma riskinin elimine edilmesi ve sistemin herhangi bir anda kesintisiz olarak analiz edilebilmesi, yöntemin güvenilirliğini ve doğruluğunu artırmaktadır. Ayrıca, literatürde yaygın olarak kullanılan yöntemlerin aksine, önerilen model, yük kombinasyonlarını önceden tanımlanmış etiketlerle sınıflandırmak yerine, her bir yükün sinyalde var olup olmadığını ikili (binary) bir çıktı ile tespit edebilmektedir. Bu sayede, hangi yüklerin aktif olduğunu daha ayrıntılı ve hassas bir biçimde belirlemek mümkün olmaktadır.


3. Materyal ve Metot (Materials and Methods)

Bu bölümde gerçekleştirilen çalışmaya ait aşamalar alt başlıklar halinde sunulmuştur. Bu kapsamda ilk olarak 3.1'de veri toplanması ve hazırlanması 3.2'de önerilen model ve kıstas makine öğrenmesi yöntemleri sunulmuştur. Ayrıca Şekil 1'de önerilen CNN tabanlı derin öğrenme yaklaşımına ait akış diyagramı görülebilmektedir.

3.1. Veri Toplanması ve Hazırlanması (Data Collection and Preparation)

Son yıllarda teknolojinin ilerlemesiyle birlikte, yerleşim alanlarında kullanılan yüklerin çeşitliliği ve sayısı önemli ölçüde artmıştır. Bu yüklerin özelliklerini etkili bir şekilde belirlemek ve sınıflandırmak için, ayırt edici özelliklerin dikkatlice incelenmesi ve anlaşılması gerekmektedir. Bazı yükler pasif direnç gösterirken, diğerleri aktif endüktif veya kapasitif özelliklere sahip olabilir. Ancak, doğru bir tanımlama için bu özelliklerin yanı sıra diğer faktörler de göz önünde bulundurulmalıdır. Her bir yükün tanımlanması için doğru bir değerlendirme elde etmek, sadece temel özelliklerin değil, aynı zamanda diğer özelliklerin de analiz edilmesini gerektirir. Bu nedenle, bir yükü tanımlamak için çeşitli niteliklerin incelenmesi büyük önem taşır ve seçilen özellikler tanımlama sürecinin doğruluğunu etkileyebilir.

Gerçekleştirilen bu çalışmada, önerilen yaklaşımın performansını değerlendirebilmek amacıyla evlerde yaygın kullanımı dikkate alınarak altı farklı ev aleti seçilmiştir. Bu ev aletleri arasında monitör, lamba, dizüstü bilgisayar şarj cihazı, elektrikli süpürge, ısıtıcı ve su ısıtıcısı bulunmaktadır. Deneyler, Afyon Kocatepe Üniversitesi laboratuvarlarında her bir cihazın tek tek veya çeşitli kombinasyonlar halinde çalıştırılması ile gerçekleştirilmiştir. Yük kombinasyonları rastgele olarak belirlenmiş ve deney sırasında kombinasyonda bulunan tüm cihazlar aynı anda etkinleştirilmiştir. Veri toplama



Şekil 1. Önerilen CNN tabanlı derin öğrenme yaklaşımına ait akış diyagramı (Flow diagram of the proposed CNN-based deep learning approach)

öncesinde kararlı durum koşullarının sağlandığından emin olmak amacıyla üç saniyelik bir bekleme süresi uygulanmıştır. Her bir deneyde yüklerin çektikleri akım verileri Fluke marka bir akım probu ve Siglent marka bir osiloskop (SDS1102CNL) kullanılarak ölçülmüş ve kaydedilmiştir. Kullanılan akım probunun sahip olduğu 250 kS/s'lik örnekleme hızı ile birlikte anlık akım değerleri tespit edilebilmiştir. Ayrıca akım probunun bağlı olduğu osiloskop yardımıyla da elde edilen akım verileri “.csv” formatında kaydedilmiştir. Gerçekleştirilen her bir ölçüm için 2500 veri noktası içeren iki periyotlu sinyaller elde edilmiştir. Deneyler sonucunda 32 farklı yük ve yük kombinasyonu için toplamda 640 ölçüm gerçekleştirilmiştir. Her bir yük ve yük kombinasyonu için 20 ölçüm gerçekleştirilmiştir. Ölçümlerin gerçekleştirildiği sırada su ısıtıcısında bir litre su bulundurulmuş, dizüstü bilgisayar ise şarj modunda (%50 ile %80 arasında) tutulmuştur. Deneyler sırasında ölçümleri gerçekleştirilen yük ve yük kombinasyonları Tablo 1’de sunulmuştur.

Tablo 1. Çalışmada kullanılan yük, yük kombinasyonları ve ölçüm sayıları (The loads and load combinations utilized in the study)

No	Yük Tanımlaması
1	Halojen Lamba
2	Su Isıtıcısı
3	Isıtıcı
4	Monitör
5	Süpürge
6	Dizüstü Bilgisayar
7	Halojen Lamba + Isıtıcı
8	Isıtıcı + Süpürge
9	Su Isıtıcısı + Isıtıcı
10	Su Isıtıcısı + Süpürge
11	Halojen Lamba + Su Isıtıcısı
12	Halojen Lamba + Monitör
13	Monitör + Süpürge
14	Isıtıcı + Monitör
15	Su Isıtıcısı + Monitör
16	Halojen Lamba + Süpürge
17	Halojen Lamba + Dizüstü Bilgisayar
18	Monitör + Dizüstü Bilgisayar
19	Süpürge + Dizüstü Bilgisayar
20	Isıtıcı + Dizüstü Bilgisayar
21	Su Isıtıcısı + Dizüstü Bilgisayar
22	Halojen Lamba + Monitör + Dizüstü Bilgisayar
23	Isıtıcı + Süpürge + Dizüstü Bilgisayar
24	Monitör + Süpürge + Dizüstü Bilgisayar
25	Halojen Lamba + Süpürge + Dizüstü Bilgisayar
26	Isıtıcı + Monitör + Süpürge
27	Isıtıcı + Monitör + Dizüstü Bilgisayar
28	Halojen Lamba + Isıtıcı + Monitör + Dizüstü Bilgisayar
29	Halojen Lamba + Monitör + Süpürge + Dizüstü Bilgisayar
30	Halojen Lamba + Isıtıcı + Süpürge + Dizüstü Bilgisayar
31	Halojen Lamba + Isıtıcı + Monitör + Süpürge
32	Halojen Lamba + Su Isıtıcısı + Isıtıcı + Süpürge

Çalışma kapsamında oluşturulan veri seti hem bireysel yüklerin hem de yük kombinasyonlarının kararlı durum akım verilerini içerecek şekilde tasarlanmıştır. Literatürde mevcut veri setlerinden farklı olarak, sistemde mevcut olan yüklerin daha önceki yük durumuna ihtiyaç duyulmadan belirlenmesi için yapılacak çalışmalarda kullanılmaya uygun bir veri setidir.

Önerilen CNN yük tanımlama modelinin geliştirilebilmesi ve performans analizlerinin yapılabilmesi amacıyla toplanan yük akım verileri belirli ön işlemlerden geçirilmiştir. Bu kapsamda ilk olarak verilerde yer alan eksik veya hatalı olan sayısal ölçüm değerleri tespit

edilmiş ve ilgili veriler interpolasyon yöntemi kullanılarak düzeltilmiştir. İlgili yöntemde verilerin eksik olduğu alanın öncesinde ve sonrasında yer alan sayısal ölçüm değerleri arasındaki ilişki gözetilerek eksik veya hatalı ölçüm içeren alanlar veriye uygun bir şekilde doldurulabilmektedir. Ardından model performansını arttırabilmek ve işlem yükünü azaltabilmek amacıyla veriler normalize edilerek 0-1 aralığına indirgenmiştir. Verilerin normalize edilmesinde Eş. 1’de verilmiş olan formülünden yararlanılmıştır.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Eş. 1’de x' normalize edilmiş veriyi, x_i girdi değerini, x_{min} ve x_{max} ise sırasıyla veri seti içerisinde yer alan en küçük ve en büyük değeri ifade etmektedir.

Verilerin normalize edilmesinin ardından modelin eğitim ve testlerinde kullanılması planlanan çıktı matrisinin oluşturulması aşamasına geçilmiştir. Bu aşamada ilk olarak ölçümü gerçekleştirilen her bir bireysel yük matriste belirli bir sıraya yerleştirilmiştir. Ardından, belirlenen bu sıra gözetilerek her bir ölçümde ilgili bireysel yükün yer alması durumu 1, yer almaması durumu ise 0 ile kodlanmıştır. Bu sayede, yüklerin sınıflandırılma sürecinde, yük türlerinin CNN derin öğrenme yaklaşımı tarafından tanınabilir bir sayısal formata dönüştürülmesi sağlanmıştır. Bu amaç kapsamında gerçekleştirilen bireysel yük tanımlamaları Tablo 2’de sunulmuştur.

Tablo 2. Bireysel yük tanımlamaları (Individual load definitions)


Yük Tanımı	Sıra Değeri
Halojen Lamba	0
Su Isıtıcısı	1
Isıtıcı	2
Monitör	3
Elektrikli Süpürge	4
Dizüstü Bilgisayar	5

Son olarak, oluşturulan veri seti önerilen CNN modelin eğitim ve test aşamalarında kullanılmak üzere rastgele bir şekilde karıştırılarak iki bölüme ayrılmıştır. Bu aşamada literatürdeki yaygın veri seti bölme oranları dikkate alınarak veri setinin %80’i eğitim, geriye kalan %20’lik kısmı ise test için ayrılmıştır. Ayrıştırma sonucunda 512 ölçüm içeren eğitim veri seti ve 128 ölçüm içeren test veri setine ulaşılmıştır.

3.2. Önerilen Model ve Kıstas Makine Öğrenmesi Yöntemleri (Proposed Model and Benchmark Machine Learning Methods)

CNN, konut yükü tanımlama problemi için oldukça güçlü bir araç olarak öne çıkmaktadır. Bu bölümde, önerilen CNN modelinin geliştirilme süreci ve bu süreçte izlenen adımlar detaylı bir şekilde ele alınmaktadır. CNN eğitilebilen birçok katman ve parametreden oluşan bir derin öğrenme algoritmasıdır. Bu yöntem ilk olarak görme korteksini modellemek amacıyla geliştirilmiş olsa da, hem regresyon hem de sınıflandırma problemlerinde son derece sağlam bir araç olduğu kanıtlanmıştır [21]. Şekil 2’de, üç katmana sahip çok temel bir CNN mimarisine ait görsel sunulmuştur.

Herhangi bir CNN yapısı üç tür katmana sahiptir: evrişim katmanı, havuzlama katmanı ve tam bağlantılı katman [22]. Evrişim katmanında, bir sinir ağı gibi, her nöron önceki katmandaki bir grup nörona bağlıdır [22]. Nöronların bağlanması, çekirdek olarak adlandırılan bir parametre ile kontrol edilir. Her evrişim katmanında, giriş sinyallerinin özelliklerini çıkarmak için filtre görevi gören bir dizi çekirdek bulunur. Çekirdekler evrişim katmanındaki filtrelerin matrisleri gibi davranır. Veri matrisinin küçük bir bölümüne uygulanır



Şekil 2. Temel 1D-CNN mimarisi [22] (Basic 1D-CNN architecture)

ve bir evrişim matrisi üretirler. Bir görüntüde kenarları netleştirmek gibi giriş verisinin özelliklerini netleştirmek için kullanılırlar. Eğer çekirdeklerin boyutu $K * K$ ise ve bunlar $N * N$ boyutunda bir giriş verisine uygulanırsa, çıkış sonucu $((N - K)/S + 1) * ((N - K)/S + 1)$ boyutunda olacaktır, burada S çekirdeğin giriş matrisindeki hareket adımıdır. Çıkış sonucu, $N * N$ boyutunda T matrisidir ve i, j girişi Eş. 2 gibi hesaplanabilir [23].


$$T^{i,j} = \sum_{n=1}^K \sum_{m=1}^K (M_{K \times K} \circ Z_{K \times K}^{i,j})^{n,m} \quad (2)$$

Burada $M_{K \times K}$, $K \times K$ boyutunda çekirdek matrisi, $\circ$ Hadamard (eleman bazlı) matris çarpımıdır ve $Z_{K \times K}^{i,j}$, Z 'nin $K * K$ boyutunda giriş verisinin altmatrisi olup Eş. 3 gibi elde edilebilir [23].

$$Z_{K \times K}^{i,j} = \begin{bmatrix} Z_{i-h,j-h} & \dots & Z_{i-h,j+h} \\ \dots & Z_{ij} & \dots \\ Z_{i+h,j-h} & \dots & Z_{i+h,j+h} \end{bmatrix} \quad (3)$$

Burada $h = \frac{K-1}{2}$ olarak ifade edilmektedir. Birçok durumda, çıktının simetrik olması için çekirdek boyutu olan K tek sayı olarak varsayılmaktadır, fakat bu durum zorunlu değildir.

Ayrıca, aşırı uyumun önlenmesi ve uzay boyutunu azaltmaya yardımcı olmak için girişin boyutunu küçültmekle sorumlu olan bir havuzlama katmanı bulunmaktadır. Havuzlama katmanının kullanılmasının nedeni uzayın çok büyük olmasıdır. Uzayın boyutu arttıkça, daha karmaşık ve daha yüksek hesaplama maliyeti oluşacaktır. Bu nedenle, genellikle matrislerin boyutunu azaltma gerekliliği oluşmaktadır. Bu yöntemlerden biri, maksimum havuzlama (maxpooling) katmanını kullanarak daha zayıf nöronları atıp en güçlü olanları tutmaktır. $P \times P$ 'lik bir matrisin maksimum havuzlamasında maksimum hücre seçilmekte ve bir sonraki katmana aktarılmaktadır. Bu işlem Şekil 3'de 2×2 'lik bir maxpooling katmanı ile basitçe gösterilmiştir [23].



Şekil 3. Maksimum havuzlama katmanı süreci [23] (Max pooling layer process)

Son aşamada, denetimli öğrenmede sınıflandırma veya regresyon için kullanılabilen tam bağlantılı bir sinir ağı bulunmaktadır. Tam bağlantılı katmanın sonunda CNN yapısını regresyon veya sınıflandırma hedefine göre değiştirebilecek bir aktivasyon fonksiyonu bulunmaktadır. Gerçekleştirilen çalışmada literatürde sınıflandırma problemlerinin çözümlerinde sıklıkla kullanılan softmax fonksiyonu tercih edilmiştir. Bu fonksiyonu kullanmanın avantajı, ağız istenen sınıfa daha düzgün ve doğru bir şekilde yakınsamasına yardımcı olmaktadır [23, 24].

Eğitim ve test süreçlerinde kullanılması hedeflenen veri setlerinin oluşturulmasının ardından yük tanımlamalarını gerçekleştirebilecek CNN derin öğrenme modelinin geliştirilmesi aşamasına geçilmiştir. Bu aşamada python programlama dilinde oluşturulmuş olan Keras derin öğrenme kütüphanesinden yararlanılarak aşağıda Tablo 3'te sunulan mimariye sahip bir CNN derin öğrenme mimarisi oluşturulmuştur.

CNN derin öğrenme modeline girdi olarak 1×2500 boyutlarında olan yük veya yük kombinasyonuna ait ölçüm verisi verilmekte ve model içerisinde yer alan her bir bireysel yük için 1, olmayan yükler için ise 0 kodlamasının yer aldığı 1×6 'lık bir matris çıktısı vererek yük tanımlamalarını gerçekleştirmektedir. CNN modelinin oluşturulma aşamasında optimizasyon algoritması olarak Adam optimizasyon algoritması tercih edilmiştir. Öğrenme oranı 0.001, döngü (epoch) değeri 100 olarak seçilmiş ve her bir döngüde öğrenme oranı; "öğrenme oranı/toplam döngü sayısı" kadar azaltılmıştır. Yığın sayısı (batch size) gerçekleştirilen deneysel çalışmalar sonucunda en iyi performansın gözlemlendiği 2 olarak belirlenmiştir. Ayrıca, kayıp fonksiyonu olarak sınıflandırma problemlerinde literatürde de sıklıkla kullanılan "binary_crossentropy" fonksiyonu kullanılmıştır.

Yük tanımlaması amacıyla önerilen CNN derin öğrenme modelinin etkinliğinin ve performansının kapsamlı bir şekilde değerlendirilebilmesi için üç farklı makine öğrenmesi yöntemi belirlenmiş ve bu modellerin çıktıları CNN modelinin çıktıları ile karşılaştırılmıştır. Bu kapsamda, mevcut literatürde yaygın olarak kabul görmeleri, yük tanımlama alanında kıstas (benchmark) algoritmalar olarak sıkça kullanılmaları ve farklı veri türleri ile gösterdikleri başarılı performanslarının göz önünde bulundurulmasıyla Karar Ağacı Regresyonu (DTR), Rastgele Orman Regresyonu (RFR) ve K-En Yakın Komşu (KNN) makine öğrenimi algoritmaları tercih edilmiştir.

Seçilen makine öğrenmesi algoritmalarının parametrelerinin belirlenmesinde, Bouktif ve ekibinin çalışması referans alınmıştır [25]. Parametre değerleri, Tablo 4'de detaylı bir şekilde sunulmuştur.

Seçilen parametreler, her bir algoritmanın yük tanımlama performansını iyileştirmek için tercih edilmiştir.

Tablo 3. Yük tanımlaması için geliştirilen CNN derin öğrenme modeli mimarisi
(CNN deep learning model architecture developed for load identification)

Katman Adı	Filtre Sayısı	Filtre Boyutu	Nöron Sayısı	Havuzlama Boyutu	Sönümleme Oranı	Aktivasyon Fonksiyonu
1 Boyutlu Evrişim Katmanı	32	5	-	-	-	Relu
Yığın Normalleştirme (Batch Normalization) Katmanı	-	-	-	-	-	-
Havuzlama (Pooling) Katmanı	-	-	-	2	-	-
1 Boyutlu Evrişim Katmanı	64	5	-	-	-	Relu
Yığın Normalleştirme Katmanı	-	-	-	-	-	-
Havuzlama Katmanı	-	-	-	2	-	-
1 Boyutlu Evrişim Katmanı	128	5	-	-	-	Relu
Yığın Normalleştirme Katmanı	-	-	-	-	-	-
Havuzlama Katmanı	-	-	-	2	-	-
1 Boyutlu Evrişim Katmanı	256	5	-	-	-	Relu
Yığın Normalleştirme Katmanı	-	-	-	-	-	-
Havuzlama Katmanı	-	-	-	2	-	-
Düzleştirme (Flatten) Katmanı	-	-	-	-	-	-
Yoğun (Dense) Katman	-	-	256	-	-	Relu
Sönümleme (Dropout) Katmanı	-	-	-	-	0,1	-
Yoğun Katman	-	-	6	-	-	Sigmoid

Tablo 4. Makine öğrenmesi modellerinde kullanılan parametre değerleri (Parameter values used in machine learning models)

Makine Öğrenmesi Modeli	Parametre Değerleri
Karar Ağaçları Regresyon	Maksimum Ağaç Derinliği: 100 Minimum Numune Bölünmesi: 4 Minimum Numune Yaprığı: 4
Rastgele Orman Regresyon	Ağaç Sayısı: 125 Maksimum Ağaç Derinliği: 100 Minimum Numune Bölünmesi: 4 Minimum Numune Yaprığı: 4
K-En Yakın Komşu	Komşu Sayısı: 5 Mesafe Ölçütü: Öklid Ağırlık Fonksiyonu: Uniform

Karar Ağaçları Regresyonu ve Rastgele Orman Regresyonu, ağaç derinliği ve numune ayarlarıyla aşırı uyumun önüne geçerken, K-En Yakın Komşu modelinde belirlenen komşu sayısı ve mesafe ölçütü, benzer yükleri ayırt etmede etkilidir. Parametreler, mevcut literatürle uyumlu olup, kullanılan makine öğrenimi modellerinin en iyi sonuçları verecek şekilde yapılandırılmasını sağlamaktadır.

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu bölümde ölçümü gerçekleştirilmiş olan yük akım verilerinin kullanılmasıyla önerilen CNN derin öğrenme modelinin uygulanabilirliği ve performansı incelenmiştir. Bu kapsamda “performans metrikleri” alt başlığı altında kullanılan istatistiksel değerlendirme ölçütleri, “deneysel çalışmalar” alt başlığı altında ise CNN modelinin geliştirme, test aşamaları ve bu aşamalar sonucunda elde edilen çıktılar sunulmuştur. Gerçekleştirilen tüm deneysel çalışmalarda anaconda platformu ve python programlama dili kullanılmıştır.

4.1 Performans Metrikleri (Performance Metrics)

Geliştirilen CNN yük tanımlama modeli ve diğer makine öğrenmesi modellerinin performanslarının incelenmesi ve karşılaştırılabilmesi amacıyla literatürde de sıklıkla kullanılan dört farklı istatistiksel değerlendirme ölçütü kullanılmıştır. Bu ölçütler doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F-ölçütü (F-score) olarak belirlenmiştir. İlgili değerlendirme ölçütlerine ait eşitlikler aşağıda sunulmuştur.

Doğruluk: Modelin gerçekleştirdiği doğru tanımlamaların tanımlanmak istenen tüm örneklerle oranı olarak tanımlanır. Hesaplanmasında Eş. 4’de sunulan formül kullanılmaktadır.

$$\text{Doğruluk} = \frac{\text{Başarılı bir şekilde tanımlanan örnek sayısı}}{\text{Toplam örnek sayısı}} \quad (4)$$

Model performansının analizinde kullanılan diğer ölçütler ise kesinlik, duyarlılık ve F-ölçütü değerleridir. Bu ölçütlerin hesaplanmasında doğru pozitif (true positive – TP), yanlış pozitif (false positive – FP), doğru negatif (true negative -TN) ve yanlış negatif (false negative – FN) gibi parametreler kullanılmaktadır. Doğru pozitif, bir testin veya modelin doğru bir şekilde pozitif sonuç verdiği durumu ifade eder; yani gerçek pozitif vakaları doğru bir şekilde tanımlar. Yanlış pozitif ise gerçekte pozitif olmayan ancak test veya model tarafından pozitif olarak sınıflandırılan durumları belirtir. Doğru negatif, test veya modelin gerçek negatif vakaları doğru bir şekilde tanımladığı durumdur. Yanlış negatif ise gerçek pozitif

vakaları yanlış bir şekilde negatif olarak sınıflandıran durumu ifade eder. Çalışmada, her bir yükün bağımsız olarak doğru veya yanlış sınıflandırılması sağlanmış ve sınıflandırma doğruluğu tüm cihazların birebir doğru olarak tanımlandığı örnekler üzerinden hesaplanmıştır. Model çıktısında, her bir cihaz için 1 veya 0 değerleri atanmış olup, cihazların her biri için doğru tahmin yapılması durumunda örnek, doğru sınıflandırılmış kabul edilmiştir. Örneğin, bir yük '1' iken '0' tahmin edilmesi ya da tam tersi durumda, örnek yanlış sınıflandırılmış sayılmaktadır.

Bu parametrelerin kullanılmasıyla hesaplanan kesinlik, duyarlılık ve F-ölçütü değerlerine ait formüller Eş. 5, Eş. 6, Eş. 7’de sunulmuştur.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (6)$$

$$F - \text{Ölçütü} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$

İlgili tüm ölçütlerde sonuçlar 0 ile 1 aralığında olmaktadır ve sonuçların 1’e olan yakınlığı modelin başarısını ifade etmektedir.

4.2. Deneysel Çalışmalar (Experiment Studies)

Bu bölümde, önerilen CNN derin öğrenme modelinin performans analizi ve değerlendirmesi için gerçekleştirilen deneysel çalışmalar sonucunda elde edilen çıktılar sunulmuştur. Bu kapsamda, önerilen modelin performans metriklerine ilişkin sonuçlar, kıyaslama yapılan makine öğrenmesi modelleri ve literatürdeki benzer çalışmaların bulguları ile karşılaştırılmıştır. Bu karşılaştırmalar yukarıda belirtilen doğruluk, kesinlik, duyarlılık ve F-ölçütü gibi performans ölçütleri kullanılarak gerçekleştirilmiştir. Tablo 5’de her model için elde edilen performans ölçüt değerleri sunulmuştur.

Elde edilen deneysel sonuçlar incelendiğinde, CNN derin öğrenme modelinin, diğer makine öğrenimi modellerine kıyasla istatistiksel kriterlerin tamamında daha etkili sonuçlar sergilediği görülebilmektedir. CNN modeli, yük tanımlamalarını 0,929 doğruluk, 0,989 kesinlik, 0,970 duyarlılık ve 0,979 F-ölçütü değerleriyle gerçekleştirmiştir. En düşük performansı gösterdiği gözlenen DTR modeline göre, CNN modeli, F-ölçütü ölçütü için ortalama %7,55 ve doğruluk ölçütü için ortalama %19,25’lik yüzdelere daha başarılı tanımlamalarda bulunmuştur. CNN modelinden sonra en yüksek


Tablo 5. CNN derin öğrenme modeline ait yük tanımlama performans metriği sonuçları
(Load identification performance metric results of CNN deep learning model)

Model	Doğruluk	Kesinlik	Duyarlılık	F-Ölçütü
DTR	0,750	0,927	0,894	0,910
RFR	0,882	0,973	0,970	0,971
KNN	0,906	0,970	0,970	0,970
CNN	0,929	0,989	0,970	0,979

Tablo 6. F-ölçütü ve doğruluk metrikleri kullanılarak konut yükü belirleme yaklaşımlarının karşılaştırılması
(Comparison of residential load identification approaches using the F-score and accuracy metrics)

No	NILM Tekniği	Veri Seti	F-Ölçütü	Doğruluk
1	De Baets vd. [26]	PLAID	0,776	-
2	Liu vd. [27]	PLAID	0,787	0,807
3	Paiva Penha vd. [20]	REDD	0,827	0,824
4	Silva Nolasco vd. [28]	LIT	0,968	0,970
5	Azzam vd. [29]	REDD	0,990	-
6	Önerilen model	Laboratuvar Prototipi	0,979	0,929

tanımlama başarısını sağlayan makine öğrenmesi modeli ise 0,906 doğruluk, 0,970 kesinlik, duyarlılık ve F-ölçütü değerleriyle Rastgele Orman Regresyon modeli olmuştur. Her bir model için elde edilen performans ölçütü değerleri Şekil 4'de grafiksel olarak sunulmuştur.



Şekil 4. Modellere ait performans ölçütlerinin grafiksel gösterimi
(Graphical representation of the performance measures of the models)

Grafik üzerinde yapılan incelemeler, önerilen derin öğrenme modelinin diğer makine öğrenimi yöntemlerine kıyasla, doğruluk, kesinlik, duyarlılık ve F-ölçütü performans metriklerinde en yüksek değerleri sunduğunu ortaya koymaktadır. Ayrıca, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını gösteren ve tüm hata maliyetlerini de içeren performans metriği olarak bilinen F-ölçütü metriğinde diğer modellere oranla en yüksek değeri elde etmiştir. Karar ağaçları modeli ise, doğruluk ve F-ölçütü performans metrikleri dikkate alındığında, en zayıf tanımlamaları gerçekleştirmiş ve dolayısıyla en düşük performansı sergilemiştir. Çalışmada kullanılan modellerin performans sıralaması, F-ölçütü ve doğruluk performans metriklerine dayanarak sırasıyla CNN, K-En Yakın Komşu, Rastgele Orman Regresyon ve Karar Ağaçları şeklindedir. Ayrıca, önerilen yöntemin etkinliğini daha iyi analiz edebilmek amacıyla, elde edilen F-ölçütü ve doğruluk değerleri literatürdeki benzer çalışmalarla karşılaştırılmıştır. Karşılaştırma sonuçları Tablo 6'da sunulmuştur.

Tablo 6'da sunulan sonuçlar incelendiğinde, önerilen CNN derin öğrenme modelinin, F-ölçütü kriteri açısından Liu, De Baets, Paiva Penha, Silva Nolasco vd. yaklaşımlarını geride bıraktığı görülmektedir. Azzam vd. çalışması, önerilen yaklaşıma göre %1.12 daha yüksek bir F-ölçütü sahip olmasına rağmen, çalışmada önerilen derin öğrenme modeli de verimlilik açısından güçlü bir performans sergilemektedir. Bunun yanı sıra, doğruluk değerleri açısından değerlendirildiğinde de, önerilen CNN modelinin 0,929 doğruluk oranıyla, konut yükü tanımlama görevinde iyi bir performans gösterdiği değerlendirilmektedir.

Bu performansın yanı sıra, önerilen model hesaplama ve saklama karmaşıklığı yönünden de incelenmiştir. Modelin hesaplama karmaşıklığı, Conv1D katmanları için filtre sayısı, giriş boyutu ve çekirdek boyutuna bağlıdır. Dört adet Conv1D katmanında sırasıyla 32, 64, 128 ve 256 filtre kullanılmış, her bir katman için işlem karmaşıklığı sırasıyla $O(2500 \times 32 \times 5)$, $O(2500 \times 64 \times 5)$, $O(2500 \times 128 \times 5)$ ve $O(2500 \times 256 \times 5)$ olarak hesaplanmıştır. Toplam hesaplama yükü yaklaşık 6 milyon işlem olarak belirlenmiştir. Bununla birlikte gerçekleştirilen deneysel çalışmalar için i7 işlemci, 16GB bellek ve 4GB ekran kartına sahip bir bilgisayar kullanılmış ve modelin eğitim süreci yaklaşık olarak 3 saat sürmüştür. Bu bilgiler ışığında, modelin paralel işleme ve GPU hızlandırmasıyla büyük veri setleri üzerinde de verimli çalışabileceği öngörülmektedir. Saklama

karmaşıklığı açısından, model parametrelerinin artan veri boyutuyla ölçeklenmesine rağmen, sıkıştırma ve bellek yönetimi teknikleriyle bu durum optimize edilebilir. Sonuç olarak, önerilen model büyük veri setleriyle başa çıkabilecek şekilde tasarlanmış olup, güçlü donanım altyapılarıyla kolayca genişletilebilir ve verimli bir şekilde uygulanabilir. Elde edilen sonuçlar göz önüne alındığında, önerilen yaklaşımın gelişime açık yönleri ile birlikte yüksek bir potansiyele sahip olduğu değerlendirilmektedir.

5. Sonuçlar (Conclusions)

Gerçekleştirilen bu çalışmada konut yüklerinin tanımlanması amacıyla bir CNN derin öğrenme modeli geliştirilerek modelin performans ve uygulanabilirliği araştırılmıştır. Bu kapsamda halojen lamba, su ısıtıcısı, ısıtıcı, monitör, elektrikli süpürge ve dizüstü Bilgisayar olmak üzere altı farklı yük seçilmiştir. İlgili yüklerin bireysel ve farklı kombinasyonlar halinde çalıştırılması ile 640 ölçüm sonucu elde edilmiştir. Çalışma kapsamında önerilen modelin eğitim, test ve performans analizlerinin gerçekleştirilmesi aşamalarında bu veriler kullanılmıştır. Önerilen CNN derin öğrenme modelinin performansının kapsamlı bir şekilde değerlendirilebilmesi amacıyla literatürde sıklıkla kullanılan ve en gelişmiş makine öğrenmesi yöntemlerinden olan Rastgele Orman Regresyon, K-En Yakın Komşu ve Karar Ağaçları makine öğrenmesi modelleri de çalışmaya dahil edilerek yük tanımlama sonuçları performans metrikleri yardımıyla karşılaştırılmıştır. Gerçekleştirilen deneysel çalışmalar sonucunda önerilen CNN derin öğrenme modelinin doğruluk, kesinlik, duyarlılık ve F-ölçütü değerlendirme ölçütlerinin tümü dikkate alındığında en başarılı tanımlamaları gerçekleştiren model olduğu belirlenmiştir. Araştırma kapsamında kullanılan modellerin başarı sıralaması, F-ölçütü ve doğruluk performans ölçütlerine dayanarak CNN, K-En Yakın Komşu, Rastgele Orman Regresyon ve Karar Ağaçları olarak belirlenmiştir.

Çalışma kapsamında elde edilen sonuçlar incelendiğinde, önerilen derin öğrenme modelinin geliştirilebilir yönlerinin yanı sıra yük tanımlamada etkin bir biçimde kullanılabileceği sonucuna varılmıştır. Bununla birlikte, derin öğrenme modellerinin geniş veri kümelerine ihtiyaç duymaları sebebiyle veri miktarının artırılmasıyla birlikte model performansının geliştirilebileceği öngörülmektedir. Modelin içerdiği parametrelerin optimize edilmesi ve yükler ile ilişkili farklı zaman serilerinin tanımlama sürecine entegre edilmesi ile modelin tanımlama performansının artırılabilirliği öngörülmektedir.

Ek olarak, çalışmada kullanılan veri seti, Afyon Kocatepe Üniversitesi laboratuvarlarında gerçekleştirilen deneysel çalışmalar sonucunda özel olarak oluşturulmuştur. Veri seti, yüksek frekanslarda toplanan verilerle steady-state sinyallere dayalı analizlere olanak sağlamaktadır. Ayrıca, veri seti, cihazların bağımsız olarak ikili çıktı ile tanımlanabilmesi ve genel yük izleme süreçlerini desteklemesi açısından yenilikçi bir yaklaşım sunmaktadır. Bu yönleriyle, literatüre, enerji yönetim sistemleri için önemli bir katkı sağlayacağı düşünülmektedir. Bu çalışmada kullanılan veri setine ilgili linkten ulaşılabilir: <https://github.com/ArdanEslık/AKU-RLI-Dataset>

Kaynaklar (References)

1. Ghosh S., Chatterjee A., Chatterjee D., An improved load feature extraction technique for smart homes using fuzzy-based NILM, IEEE Transactions on Instrumentation and Measurement, 70, 1-9, 2021.
2. Eşlik A.H., Sen O., Serttaş F., CNN-LSTM model for solar radiation prediction: performance analysis, Journal of the Faculty of Engineering and Architecture of Gazi University, 39 (4), 2155-2162, 2024.
3. Chojeci A., Rodak M., Ambroziak A., Borkowski P., Energy management system for residential buildings based on fuzzy logic: Design and implementation in smart-meter, IET Smart Grid, 3, 254-66, 2020.

4. Hart G.W., Nonintrusive appliance load monitoring, *Proceedings of the IEEE*, 80, 1870-91, 1992.
5. Eşlik A.H., Akarslan E., Doğan R., A novel approach for residential load identification based on dynamic time warping, *Sustainable Energy, Grids and Networks*, 101316, 2024.
6. Akarslan E., Doğan R., A novel approach based on a feature selection procedure for residential load identification, *Sustainable Energy, Grids and Networks*, 27, 100488, 2021.
7. Akarslan E., Doğan R., A novel approach for residential load appliance identification, *Sustainable Cities and Society*, 63, 102484, 2020.
8. Gürbüz F.B., Bayındır R., Seyfettin V., Elektrikli ev aletlerinde müdahalesiz yük izleme, sınıflandırma ve kontrolünün gerçekleştirilmesi, *Gazi University Journal of Science Part C: Design and Technology*, 11, 1209-22, 2023.
9. Heo S., Kim H., Toward load identification based on the Hilbert transform and sequence to sequence long short-term memory, *IEEE Transactions on Smart Grid*, 12, 3252-64, 2021.
10. Ghosh S., Chatterjee D., Non-intrusive identification of harmonic polluting loads in a smart residential system, *Sustainable Energy, Grids and Networks*, 26, 100446, 2021.
11. Kumar M., Gopinath R., Harikrishna P., Srinivas K., Non-intrusive load monitoring system for similar loads identification using feature mapping and deep learning techniques, *Measurement Science and Technology*, 32, 125902, 2021.
12. Han Y., Xu Y., Huo Y., Zhao Q., Non-intrusive load monitoring by voltage-current trajectory enabled asymmetric deep supervised hashing, *IET Generation, Transmission & Distribution*, 15, 3066-80, 2021.
13. Hu M., Tao S., Fan H., Li X., Sun Y., Sun J., Non-intrusive load monitoring for residential appliances with ultra-sparse sample and real-time computation, *Sensors*, 21, 5366, 2021.
14. Li Y., Wang H., Yang Z., Yang J., Chen Z., Stacking ensemble learning-based load identification considering feature fusion by cyber-physical approach, *IEEE Sensors Journal*, 23, 5997-6007, 2023.
15. Ghosh S., Panda D.K., Das S., Chatterjee D., Cross-correlation based classification of electrical appliances for non-intrusive load monitoring, 2021 International Conference on Sustainable Energy and Future Electric Transportation (SEFET): IEEE, 1-6, 2021.
16. Hosseini S.S., Delcroix B., Henao N., Agbossou K., Kelouwani S., Towards feasible solutions for load monitoring in Quebec residences, *Sensors*, 23, 7288, 2023.
17. Yin H., Zhou K., Yang S., Non-intrusive load monitoring by load trajectory and multi feature based on DCNN, *IEEE Transactions on Industrial Informatics*, 2023.
18. Moradzadeh A., Mohammadi-Ivatloo B., Abapour M., Anvari-Moghaddam A., Gholami Farkoush S., Rhee S.B., A practical solution based on convolutional neural network for non-intrusive load monitoring, *Journal of Ambient Intelligence and Humanized Computing*, 12, 9775-89, 2021.
19. Ding D., Li J., Zhang K., Wang H., Wang K., Cao T., Non-intrusive load monitoring method with inception structured CNN, *Applied Intelligence*, 1-18, 2022.
20. De Paiva Penha D., Castro A.R.G., Convolutional neural network applied to the identification of residential equipment in non-intrusive load monitoring systems, 3rd International Conference on Artificial Intelligence and Applications, 11-21, 2017.
21. Hubel D.H., Wiesel T.N., Receptive fields of single neurones in the cat's striate cortex, *The Journal of Physiology*, 148, 574, 1959.
22. Wen L., Li X., Gao L., Zhang Y., A new convolutional neural network-based data-driven fault diagnosis method, *IEEE Transactions on Industrial Electronics*, 65, 5990-8, 2017.
23. Rahimilarki R., Gao Z., Jin N., Zhang A., Convolutional neural network fault classification based on time-series analysis for benchmark wind turbine machine, *Renewable Energy*, 185, 916-31, 2022.
24. Karaali I., Eminağaoğlu M., A convolutional neural network model for marble quality classification, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (1), 347-358, 2021.
25. Bouktif S., Fiaz A., Ouni A., Serhani M.A., Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches, *Energies*, 11, 1636, 2018.
26. De Baets L., Ruysinck J., Develder C., Dhaene T., Deschrijver D., Appliance classification using VI trajectories and convolutional neural networks, *Energy and Buildings*, 158, 32-6, 2018.
27. Liu H., Wu H., Yu C., A hybrid model for appliance classification based on time series features, *Energy and Buildings*, 196, 112-23, 2019.
28. Da Silva Nolasco L., Lazzaretti A.E., Mulinari B.M., DeepDFML-NILM: A new CNN-based architecture for detection, feature extraction and multi-label classification in NILM signals, *IEEE Sensors Journal*, 22, 501-9, 2021.
29. Azzam A., Sanami S., Aghdam A.G., Low-frequency load identification using CNN-BiLSTM attention mechanism, 2024 32nd Mediterranean Conference on Control and Automation (MED): IEEE, 712-7, 2024.