

Automatic Classification of Household Electrical Appliances with Convolutional Neural Network

Ebra Nur ZUREL¹  Zeynep Mine ALÇİN²  Muzaffer ASLAN^{3,*} 

¹ Bingöl Üniversitesi, Fen Bilimleri Enstitüsü, 12100, Merkez/BİNGÖL

² Vedat Topçuoğlu Anatolian Vocational High School, Electrical and Electronics Department, 27010, Şahinbey/GAZİANTEP

³ Bingöl Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 12100, Merkez/BİNGÖL

Graphical/Tabular Abstract

Article Info:

Research article
Received: 22.05.2022
Revision: 8.10.2022
Accepted: 25.10.2022

Highlights

- Energy Efficiency.

Keywords

Detection of Household Appliances,
Short-Term Fourier Transform,
Deep Learning,
CNN

In this study, a CNN model is proposed for the fast and effective detection of household appliances used in residential by using the time series properties. (Figure A.)

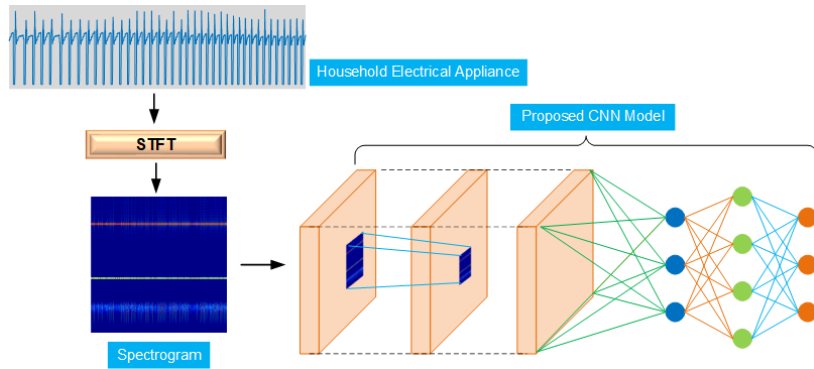


Figure A. The general structure of the proposed method

Purpose: Recently, smart building applications such as energy management and home automation system have been needed to meet the increasing electrical energy demand in residences. This study aims to plan efficient energy management by detecting these appliances from the power consumption of electrical appliances used in homes.

Theory and Methods: In the preprocessing stage of the proposed method, time series of 18 residential appliances were converted into images with STFT, which is more sensitive to frequency changes. These images were then resized in accordance with the designed CNN model input. Then, these images were applied to the CNN model with the feature designed, and the automatic detection of the devices used in the houses was realized.

Results: In the experimental studies carried out with the proposed method for detecting household appliances, the appliances in the dataset have an accuracy rate of 94.78%.

Conclusion: The proposed model achieved a higher performance rate of 1.98% in accuracy and 13.12% in the F1 score when the state-of-the-art methods of detecting electrical household appliances were compared.



Automatic Classification of Household Electrical Appliances with Convolutional Neural Network

Ebra Nur ZUREL¹ Zeynep Mine ALÇİN² Muzaffer ASLAN^{3,*}

¹ Bingöl Üniversitesi, Fen Bilimleri Enstitüsü, 12100, Merkez/BİNGÖL

² Vedat Topçuoğlu Anadolu Meslek Lisesi, Elektrik-Elektronik Bölümü, 27010, Şahinbey/GAZİANTEP

³ Bingöl Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 12100, Merkez/BİNGÖL

Abstract

Today, technological developments increase the demand for energy resources at a great rate. In particular, the increase in the number of electrical appliances used in residences increases the consumption of electrical energy in homes, as in the industry. Effective supply-demand balance depends on identifying electrical loads in the home and the design of non-intrusive load monitoring (NILM) systems. Through NILM systems, users can control their household appliance usage habits and then adjust their behavior to save electricity. It is a topic of recent interest in both academia and industry. NILM is used to reveal useful information about consumption breakdown by device or activity level, so it can be an important solution to show various smart home services and opportunities. For this purpose, deep learning is emerging as a prominent solution. This study proposes an efficient convolutional neural network (CNN) model for the fast and effective detection of electrical appliances used in residential buildings. A new CNN model with lower computational complexity Exponential Linear Unit (ELU) activation function is designed in the proposed model. Experimental studies were carried out with the data set containing the power consumption time series of 18 different electrical appliances used in residences. Short-Time Fourier Transform (STFT) converted preprocessing time series to color images. These images were then applied to the ESA for feature extraction and classification. In experimental studies, the accuracy, sensitivity, specificity, precision, and F1-score values of the proposed method were 94.78%, 87.371%, 99.70%, 90.5404, and 88.62%, respectively. In addition, the proposed method provided higher success rates of 1.78% and 1.98% in the accuracy criterion, one of the state-of-the-art methods, and 11.02% and 13.12% in the F1-score criterion.

Makale Bilgisi

Araştırma makalesi
Başvuru: 22.05.2022
Düzeltilme: 8.10.2022
Kabul: 25.10.2022

Keywords

Detection of Household
Electrical Appliances,
Short-Term Fourier
Transform,
Deep Learning,
CNN

Anahtar Kelimeler

Elektrikli Ev Cihazlarının
Tespiti,
Kısa Süreli Fourier
Dönüşümü,
Derin Öğrenme,
Evrişimli Sinir Ağları

Konutlardaki Elektrikli Cihazların Evrişimli Sinir Ağı ile Otomatik Sınıflandırılması

Öz

Günümüzde teknolojik gelişmeler enerji kaynaklarına olan talebi büyük bir oranda artmaktadır. Özellikle konutlarda kullanılan elektrikli cihaz sayılarının artması endüstri de olduğu gibi konutlarda elektrik enerji tüketimini oldukça artmaktadır. Arz-talep dengesini etkili bir şekilde sağlanabilmesi konutlardaki elektriksel yüklerin tanımlanmasına ve müdahaleci olmayan yük izleme (MOYİ) sistemlerinin tasarımına bağlıdır. MOYİ sistemleri vasıtasıyla kullanıcıların, ev aletleri kullanım alışkanlıklarını kontrol edebilir ve ardından elektrik tasarrufu için davranışlarını ayarlayabilir. Bu nedenle, son zamanlarda MOYİ hem akademik hem de endüstride ilgi çeken bir konudur. MOYİ, cihaz veya aktivite seviyesindeki tüketim dökümü ile ilgili faydalı bilgileri ortaya çıkarmak için kullanılır, bu nedenle çeşitli akıllı ev hizmetleri ve fırsatlarını ortaya çıkarmak için önemli bir çözüm olabilir. Bu amaçla, derin öğrenme öne çıkan bir çözüm olarak ortaya çıkmaktadır. Bu çalışmada, konutlarda kullanılan elektrikli cihazların hızlı ve etkili bir şekilde tespit için etkin bir evrişimli sinir ağı (ESA) modeli önerilmiştir. Önerilen modelde, daha düşük hesaplama karmaşıklığına sahip exponansiyel lineer ünite (ELU) aktivasyon fonksiyonu içeren yeni bir ESA modeli tasarlanmıştır. Deneysel çalışmalar, konutlarda kullanılan 18 farklı elektrikli cihazların güç tüketim zaman serilerini içeren veri seti ile gerçekleştirilmiştir. Ön işlem zaman serileri, kısa süreli fourier dönüşümü (KSFD) ile renkli görüntülere dönüştürüldü. Daha sonra bu görüntüler özellik çıkarımı ve sınıflandırma için ESA'ya uygulandı. Yapılan deneysel

çalışmalarda önerilen yöntemin doğruluk, duyarlılık, özgüllük, kesinlik ve F1-skor değerleri sırasıyla %94,78, %87,371, %99,70, %90,5404 ve %88,62 olarak elde edilmiştir. Ayrıca önerilen yöntem son teknoloji yöntemlerden doğruluk ölçütünde %1,78 ve %1,98, ayrıca F1-skor ölçütünde %11,02 ve %13,12 oranlarında daha yüksek başarımla sonuçlanmıştır.

1. GİRİŞ (INTRODUCTION)

Son dönemlerde, teknolojik ve ekonomik gelişmeler ile birlikte enerji talebi de önemli oranda artmaktadır. Artan bu enerji talebinin karşılanabilmesi için sınırlı olan fosil yakıt kaynaklarının daha fazla kullanımına neden olmaktadır. Fakat bu durum daha fazla sera gazı salınımı ve küresel iklim değişimi gibi ciddi problemlere sebep olmaktadır. Bu nedenle özellikle gelişmiş ve gelişmekte olan ülkeler çeşitli yenilikçi, teknolojik, sürdürülebilir farklı enerji kaynakları arayışına yönelmekte diğer bir yandan da mevcut enerji kaynaklarının nasıl daha verimli kullanılabileceğini araştırmaktadır [1]. Enerjinin verimli kullanımı ve enerji maliyetlerinin en alt seviyeye düşürmek için tüm sanayii tesislerinde önemli çalışmalar yapılmakla birlikte dünyada en büyük enerji tüketicilerinden biri olan konutlarda bu çalışmalar istenilen seviyelerde değildir. Binalarda tüketilen enerji, dünya enerjisinin %40'ını ve karbondioksit emisyonları toplamın üçte birinden fazlasını oluşturmaktadır [2]. ABD'de elektrik enerjisi tüketiminin yaklaşık %72'si binalarda harcanmaktadır [3]. Ayrıca hızlı nüfus artışı ve kırsaldan kentlere olan aşırı göç dikkate alındığında konutlardaki elektrik tüketiminin daha da artması muhtemeldir.

Konutlarda kullanılan elektrik enerjisi verimliliğini artırmak için enerji yönetimi ve ev otomasyonu gibi akıllı bina uygulamaları için detaylı enerji kullanım bilgilerinin sağlanması esastır. Bu bakımdan son zamanlarda araştırmacılar enerji dağıtım sisteminde cihaz düzeyinde güç tüketimlerini izlemek için müdahaleci olmayan yük izleme (MOYİ) tekniklerine yönelmektedirler [4]. MOYİ tekniği, bireysel cihazlara müdahaleci ve düşük maliyetli sensörler eklemeyen yükleri ayrıştırmak ve tanımlamak için akıllı algoritmalar kullanır [5]. Bu yaklaşım ile konut cihaz tespitindeki en önemli süreçlerden biri yük imza yapısıdır. Elektrik sinyallerinden oluşturulan temel olarak üç tür yük imzası vardır. Bunlar, gerçek güç ve reaktif güçteki değişiklikler, güç faktörü ve güç faz açısı gibi verilerdir [6]. Bu tür imzalar vasıtasıyla, konut cihazlarının güç tüketimi bakımından en iyi şekilde ayırt edilebilmekte ve bunları omik, endüktif ve kapasitif yükler olarak kolayca sınıflandırılır.

Literatürde, yük imzalarını kullanarak konutlardaki cihazların otomatik olarak tespitine yönelik çalışmalara son zamanlarda büyük bir ilgi olmuştur. Aggelos ve ark. [6] MOYİ algoritmalarının daha yüksek verimliliği için farklı yüklerde çalışmalar yapmışlardır. Üç farklı yük imzalarına sahip ve bunların mevcut dalga biçimlerinin analizlerini yapmışlardır. İki farklı ölçüm seti ile yüksek düzeyde verimli tanıma prosedürü geliştirerek test yapmışlar. Yapmış oldukları bu çalışma ile çevrimiçi ve gerçek zamanlı akıllı şebeke uygulamalarında kullanıma açık hale getirmişlerdir. Yuan ve ark. [7] Bayes sınıflandırması modeli ile yedi çeşit (buzdolabı, elektrikli ocak, klima, televizyon, dizüstü bilgisayar, çamaşır makinesi ve su sebili) ev aletlerinden aldıkları verilerden öznitelik çıkarımı yaparak güç tüketimini yeni algoritma ile uygulanabilirliğini test etmişlerdir. Koç ve ark. [8] elektrikli cihazların tespiti makine öğrenmesi yöntemlerini önermişlerdir. Çalışmalarında, yük modellerine göre elektrikli cihazların aktif ve reaktif güçlerini referans olarak destek vektör makinaları ve karar ağaçları yöntemleri ile elektrikli cihazları sınıflandırdılar. Deneysel çalışmalarda en yüksek doğruluk oranına %83,4 ile destek vektör makinaları ulaşılar.

Hasan ve ark. [9] cihaz profillerini tanımlamak için V-I yörünge tabanlı özellikleri referans alan önerdi. Yöntemde, akım-gerilim yörüngesinin çevrelediği alan, akım-gerilim ortalama yörünge eğrisinin doğrusal olmaması ve akım-gerilim yörüngesinin kesişim sayısı gibi dalga işaretleri öznitelik olarak kullanılmıştır. Bates ve ark. [10] cihaz işaretlerini tanımlamak için ağırlıklı piksel V-I görüntülerini kullandı ve akım-voltaj görüntüleri, cihaz sınıflandırması için bir ESA modeline uygulandı. Önerilen yöntemin etkinliği WHITED ve PLAID veri setleri ile test edilmiştir Athanasiadis ve ark. [11] konut cihazlarının aktif güç ölçümleri temel alan gerçek zamanlı bir model sunmuşlar. Bu model, cihazların çalışma konumunu belirleyen bir algoritma, ESA ve sınıflandırıcı olmak üzere üç bölümden oluşmaktadır. Devlin ve ark. [12] konutlarda kullanılan cihazları tespit etmek için akıllı bir sayaç ölçümlerini çok katmanlı ileri beslemeli sinir ağlarına dayalı bir yöntem önerdiler. Yöntem herkese açık olan akıllı sayaç

verileri ile test edilmiştir. Paiva ve ark. [13] MOYİ sistemlerinde konutlardaki elektrikli cihazları tespiti için ESA modellerine dayalı yaklaşım kullanımı önerdiler. 1Hz gibi düşük frekanslardaki REED veri setinden alınan veriler ile modellerini test ettiler.

Yapılan bu çalışmalarda, konutlardaki cihazların tespitinde önemli başarımlar sağlanmakla birlikte güç ile ilgili imzaların kullanımı dalga formunun seviye bilgilerini yok saymaktadır. Bu gerilim değişimleri olduğunda cihaz tespit başarımını negatif etkilemektedir. Araştırmacılar bu durumun üstesinden gelebilmek için güç tüketim sinyallerinin frekans ve zaman serisi özelliklerinden kullanmaya yöneldiler. Bazı çalışmalarda frekans alanındaki elektrik sinyali seyrekliği ve fourier dönüşümü kullanılarak hesaplanabilen akım harmonikleri gibi frekans alanı yük imzalarını kullandılar [14,15]. Le ve ark. [16] konutlarda kullanılan cihazları tespitinde, yük izlerinden hızlı fourier dönüşümü ile tek sayılı harmonikleri seçerek öznelik çıkarımı yaptılar. Daha sonra bu öznelikler torbalama karar ağacına uygulayarak sınıflandırmaya çalıştılar. Liu ve ark. [17], zaman serisi özelliklerine dayalı hibrit model tasarlamışlardır. Hibrit model olarak diğer prensiplerden farklı olarak zaman serisi öznelik kullanmışlar. Genişletilmiş PLAID veri seti ile doğrulama olarak daha iyi performans elde etmişlerdir. Christoforos ve ark. [18] çok etiketli MOYİ için zaman serisi gösteriminde bulunmuşlardır. Signal2Vec kullanarak iki popüler veri kümesi üzerinde değerlendirmelerde bulunmuşlardır. Böylelikle gömülü cihazlara entegre ederek gizlilik sağlanabilir olduğunu test etmişlerdir.

Yukarıdaki çalışmalar incelendiğinde, konutlardaki cihazların tespitinde çok sayıda sınıflandırma algoritması çalışılmış olmasına rağmen, sınıflandırıcılar oluşturulurken sınıf dengesizliği sorununa çok az dikkat edilmiştir. Bununla birlikte cihazların çalışma frekansı değiştiğinden, bu sorun daha zor bir hale dönüşmektedir [19].


Bu çalışmada, yukarıda bahsedilen problemlerin çözümü için konutlarda kullanılan cihazların zaman serisi özelliklerini referans alan derin öğrenme tabanlı yeni bir yaklaşım önerilmiştir. Genel olarak önerilen yaklaşım ön işlem ve öznelik çıkarımı, sınıflandırma olmak üzere iki aşamadan oluşmaktadır.

Ön işlem aşamasında konut cihazlarına ait zaman serileri Kısa Süreli Fourier Dönüşüm (KSFD) ile görüntüye dönüştürüldü. Ardından öznelik çıkarım ve sınıflandırma için yeni geliştirilen ESA mimarisine uygulanmıştır. Deneysel sonuçlar, önerilen modelin konutlarda kullanılan cihazları etkili bir şekilde sınıflayabildiğini göstermektedir. Ayrıca önerilen yöntem basit, hızlı ve düşük boyutlu olması gibi avantajları dikkate alındığında gerçek zamanlı uygulamalarda kullanımı potansiyeline sahiptir.

Çalışmanın geri kalan kısmı; kullanılan veri seti, uygulanan yöntemler, deneysel çalışmalar ve sonuçlar, doğrultusunda tartışma ve sonuç bölümlerinden oluşmaktadır.

2. MATERYAL VE METOTLAR (MATERIALS AND METHODS)

Bu çalışmada, konutlarda kullanılan elektrik cihazların otomatik tespiti için yeni bir ESA modeli sunulmaktadır. Şekil 1'de genel yapısı görülen yöntemin ön işlem aşamasında, frekans değişimlerine daha duyarlı KSFD ile 18 adet konut cihazlarına ait 916 örnekten oluşan zaman serileri görüntüye dönüştürüldü. Ardından bu görüntüler önerilen ESA model girişine uygun olarak 224x224x3 olarak yeniden boyutlandırıldı. Daha sonra bu görüntüler öznelik çıkarımı ve sınıflandırma için yeni oluşturulan 26 katmanlı ESA modeline uygulanarak konutlarda kullanılan cihazların otomatik tespiti yapılmaktadır.



Şekil 1. Önerilen yöntemin genel yapısı

2.1. Veri Seti (Dataset)

Bu çalışmada, ev aletlerinin güç ve reaktif güç profilleri ile ilgili yüksek çözünürlüklü veri seti kullanılmıştır [20]. Veri seti detayları Tablo 1’de verilen ve Avrupa’da konutlarda yaygın olarak kullanılan 18 farklı elektrikli cihazı içermektedir. Çamaşır makinesi, ekmek kızartma makinesi, ütü, saç kurutma makinesi ve klima gibi elektrikli cihazların aktif güç tüketimi verileri iki aylık (Aralık 2018 ve Ocak 2019) olarak ölçülmüştür. Isı pompasının farklı çalışma konumlarına ait aktif ve reaktif güç tüketimleri ile elektrikli bisiklet ve akülü aracın şarj tüketimleri Avrupa Komisyonu Ortak Araştırma Merkezi’nin (JRC) akıllı şebeke birlikte çalışabilirlik laboratuvarındaki (SGILab) ölçümlerinden alınmıştır [21].

Tablo 1. Elektrikli Cihazlar ve Özellikleri

No	Elektrikli Cihazlar	Güç (W)	Örnek Sayısı
1	Klima	1400	120
2	Test cihazı (Test)		6
3	Akülü Araç	6600	120
4	Bulaşık Makinası	2100	24
5	Kurutucu	2300	6
6	Buzdolabı	170	168
7	Saç Kurutma	2100	44
8	Isı pompası	2600	20
9	Ütü	2200	12
10	Led Lamba	60	8
11	Flüorsan Lamba	200	8
12	Bilgisayar	500	78
13	Fırın	2200	72
14	Televizyon	108	82
15	Tost Makinası	700	48
16	Su Isıtıcısı	400	12
17	Çamaşır Makinası	2300	28
18	Elektrikli Bisiklet	200	60

2.2. Kısa Süreli Fourier Dönüşümü (Short-time Fourier Transform)

Bir zaman serisinin frekans dağılımını analiz etmek için Fourier dönüşümü genellikle en etkili yöntemlerden biri olarak kabul edilmektedir. Fakat bu dönüşümden sonra zaman bilgisi kaybolmaktadır. Sonuç olarak, sinyaldeki ani değişikliklerin belirlenmesinde yetersiz kalmaktadır. Literatürde, hem zaman hem de frekans bilgisinin gerekli olduğu KSFD ve Wigner-Ville dönüşümü (WWT) gibi çok çeşitli uygulamalar vardır [22]. KSFD, zaman serilerindeki frekans ve faz değişimini ölçmek için Gabor tarafından önerilen bir yöntemdir [23]. Bu yöntem temel olarak tüm zaman serilerini bir kerede düşünmek yerine, kısa zaman aralıklarında (kayan bir pencerede) bir zaman serisinin frekans bileşenlerini temsilini sağlamaktadır [24]. Bu tür temsilleri zaman içinde birleştirmek, bir dalga biçiminin zaman ve frekansın 2 boyutlu bir fonksiyonu olarak görselleştirilmesine izin verir [25].

Verilen bir x zaman serisi ve ilgili KSFD gösterimi f göz önüne alındığında şu şekilde hesaplanır:

$$f(\tau, \omega) = \int_{-\infty}^{+\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (1)$$


burada ω , τ zamanında ortalanmış bir pencere fonksiyonudur. Ayrıca kayan pencereli KSFD temsilinin kare büyüklüğü, $|f(\tau, \omega)|^2$ genel olarak spektrogram olarak adlandırılır [26].

2.3. Evrişimli Sinir Ağları (Convolution Neural Network)

Geleneksel Makine Öğrenme (MÖ) teknikleri kullanarak sınıflandırma sürecinde, ön işleme, özellik çıkarma, akıllı özellik seçimi, öğrenme ve sınıflandırma olmak üzere birkaç ardışık süreci gerektirmektedir. Ayrıca, özellik seçiminin makine öğrenimi tekniklerinin performansı üzerinde büyük etkisi vardır [27]. Ayrıca önyargılı özellik seçimi, sınıflar arasında yanlış ayırım yapılmasına neden olabilmektedir. Fakat Derin Öğrenme (DÖ), geleneksel MÖ yöntemlerinden farklı olarak, çeşitli görevler için özellik setlerinin öğrenilmesini otomatikleştirebilmektedir [28,29]. DÖ, öğrenme ve sınıflandırmanın tek seferde elde edilmesini imkan sağlayabilmektedir [27]. DÖ ağları genellikle tekrarlayan sinir ağları ve ESA olmak üzere iki ana gruba ayrılırlar. Bununla birlikte ESA'lar, herhangi bir insan denetimi olmadan önemli özellikleri otomatik olarak algılama yetenekleri nedeni ile araştırmacılar tarafından yaygın olarak tercih edilmektedir [27].

ESA tipik bir sinir ağı gibi katmanlar halinde organize edilen ve hiyerarşik temsilleri öğrenebilen nöronlara dayanır [30]. Genel olarak bir ESA modeli evrişim, havuzlama, tam bağlı ve softmax katmanlarından oluşur.

Evrişim Katmanı: ESA mimarisinde en önemli katmandır. Bir dizi evrişimsel filtreden (çekirdekler olarak adlandırılır) oluşur. N boyutlu olarak ifade edilen girdi görüntüsü, çıktı özellik haritasını oluşturmak için Şekil 2'de görüldüğü üzere (3×3 , 5×5 , 7×7 gibi) farklı boyutlardaki filtrelerle konvüle edilir [31].



Şekil 2. Konvolüsyon işlemi


Havuzlama Katmanı: Bu katmanın ana görevi, özellik haritalarının alt örneklenmesidir. Bu haritalar, evrişim işlemleri takip edilerek oluşturulur. Başka bir deyişle, bu yaklaşım, daha küçük özellik haritaları oluşturmak için büyük boyutlu özellik haritalarını küçültür. Eşzamanlı olarak, havuzlama aşamasının her

adımında baskın bilgilerin (veya özelliklerin) çoğunluğunu korur. Ortalama, minimum ve maksimum havuzlama gibi çeşitli havuzlama yöntemleri mevcuttur [27].

Tam Bağlantılı Katman: Bu katman, genellikle ESA mimarisinin sonunda yer almaktadır. Bu katmanın içinde, her nöron, bir önceki katmanın tüm nöronlarına bağlanır. Bir tür ileri beslemeli yapay sinir ağında olduğu için geleneksel çok katmanlı algılayıcı sinir ağının temel yöntemini izler. Tam bağlantılı katmanın girişi, son havuzlama veya evrişim katmanından gelir. Bu girdi, düzleştirmeden sonra özellik haritalarından oluşturulan bir vektör biçimindedir [32,33].

Softmax: son tam bağlantılı katmandan elde edilen özelliklerin sınıflandırılmasını sağlamaktadır. Sınıflandırma işleminde olasılıksal değerler kullanılarak ilgi sınıfa atama işlemi yapılır [31].

Bu çalışma, popüler ve sıklıkla kullanılan ön eğitilmiş ESA mimarileri yerine daha düşük kapasiteli donanımlarda kullanılabilen basit ve daha düşük hesaplama karmaşıklığına sahip etkili bir ESA mimarisi önerilmiştir. Genel yapısı Şekil 3'te görülen bu mimaride daha az parametreye sahip konvolüsyon katmanlar ve ReLU fonksiyonu yerine ELU fonksiyonu kullanan aktivasyon katmanlarına sahiptir.



Şekil 3. Önerilen ESA modeli

2.4. Değerlendirme Ölçütleri (Evaluation Criteria)

Önerilen yöntem sonuçlarını analiz etmek doğruluk, duyarlılık, özgüllük, kesinlik ve F1-skor parametreleri kullanılmıştır. Bu parametreler önerilen modelin sınıflandırma sonuçlarına göre etiketlenen sınıf değeri ile gerçek sınıf değeri arasındaki ilişkiye göre belirlenir. Bunun için Tablo 2'de verilen karmaşıklık matrisinden faydalanılmıştır.

Tablo 2. Karmaşıklık matrisi

Karmaşıklık Matrisi		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçekteki Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Performans değerlendirme ölçütleri Denklem 2-6'daki bağıntılar ile hesaplanmaktadır [33].

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \times 100 \quad (2)$$

$$\text{Duyarlılık (Geri Çağırma)} = \frac{DP}{DP + YN} \times 100 \quad (3)$$

$$\text{Özgüllük (Seçicilik)} = \frac{DN}{DN + YP} \times 100 \quad (4)$$

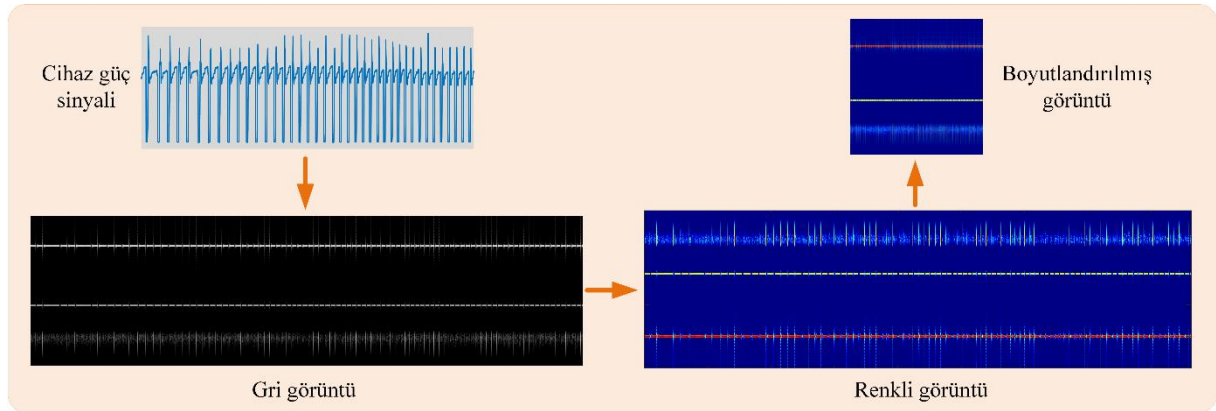
$$Keskinlik = \frac{DP}{DP + YP} \times 100 \quad (5)$$

$$F1 Skor = \frac{Duyarluluk \times Keskinlik}{Duyarluluk + Keskinlik} \times 100 \quad (6)$$

3. BULGULAR VE TARTIŞMA (FINDINGS AND DISCUSSION)

Bu bölümde, konutlarda kullanılan elektrikli cihazların tespiti ve cihazların sınıflandırılması için deneysel kurulum ve deneysel sonuçlar hakkında kısa bilgiler sunulmaktadır. Deneyler, Intel Xeon Silver 3.3 GHz işlemci, 32 GB RAM, NVIDIA P2200 Quadro GPU kartı ve MATLAB 2020a yazılımı ile donatılmış iş istasyonunda gerçekleştirilmiştir.

Deneysel çalışmaların ilk aşamasında zaman serileri KSFD ile görüntüleme dönüştürüldü. Veri setindeki elektrikli cihazlara ait zaman serilerinden spektrogram görüntülerini oluşturmak için deneysel olarak belirlenen 200ms'lik Hamming penceresi kullanıldı ve FFT sayısı 1000 olarak seçilmiştir. Bu değerlere göre 1×86400 boyutlarındaki her bir zaman serisi detayları Şekil 4'de görüldüğü gibi önce 251×1727 boyutlarında gri görüntüye dönüştürüldü. Daha sonra gri görüntüdeki piksel parlaklığı ve kontrast değerlerindeki değişimler homojen olarak değişen bir jet128 renk haritası ile renklendirilerek $251 \times 1727 \times 3$ renkli spektrogram görüntüye dönüştürüldü ve son olarak önerilen ESA model girişine uygun olarak $224 \times 224 \times 3$ olarak yeniden boyutlandırıldı.



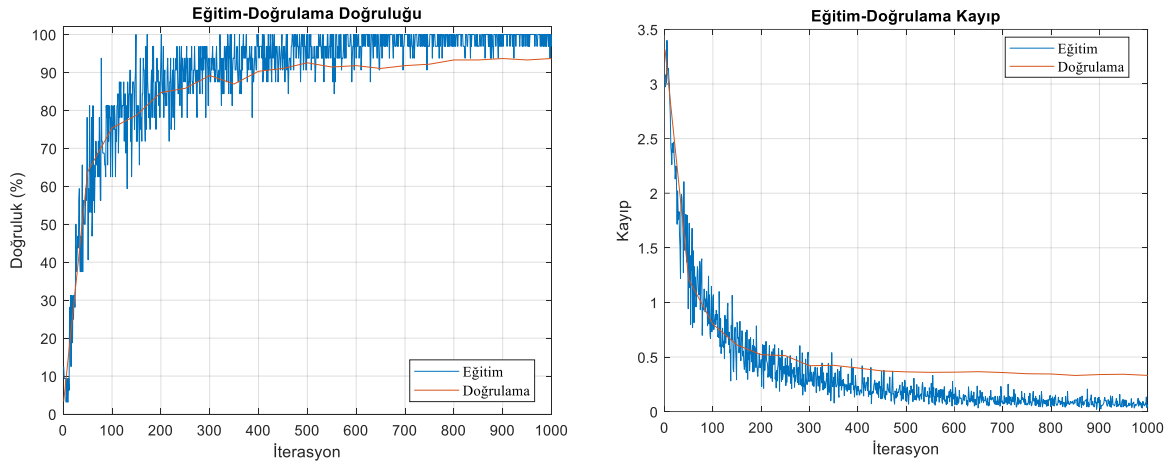
Şekil 4. Zaman serilerinden spektrogram görüntülerinin elde edilmesi

Deneysel çalışmaların ikinci aşamasında, önerilen ESA modeli ile öznelik çıkarımı cihazların sınıflandırılması için elde edilen görüntülerin %70'i (648 görüntü) eğitim ve %30'u (268 görüntü) test için ayrılmıştır. Eğitim verileri önerilen ESA modelinin eğitilmesi ve test verileri önerilen ESA model parametrelerinin belirlenmesi hem de performans değerlendirmesi amacıyla kullanıldı. ESA modelinin eğitim sürecinde modele ait en iyi parametrelerinin belirlenmesi deneyler birkaç kez tekrar edildi ve belirlenen ESA model eğitim parametreleri Tablo 3'de görülmektedir.

Tablo 3. ESA model eğitim parametreleri

Optimizasyon	Öğrenme Oranı	Maksimum Tekrar Sayısı	Minimum Yığın Sayısı	Doğrulama Frekansı
Stokastik Gradyan Azalma (SGD)	10^{-3}	50	32	50

Tablo 3'de verilen eğitim parametrelerine göre önerilen ESA modelinin eğitim ve sınıflandırma süreçlerine ait eğitim-doğrulama ve eğitim kayıp grafikleri Şekil 5'te görülmektedir.



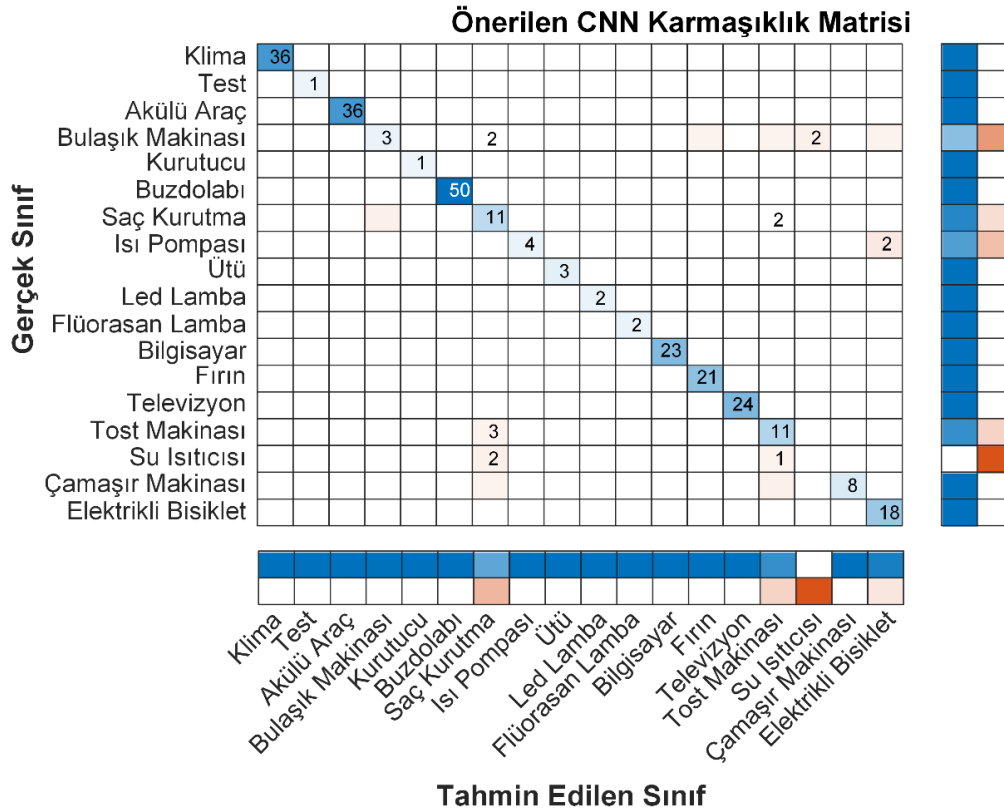
Şekil 5. ESA modelinin doğruluk ve kayıp eğrileri

Şekil 5’de görüleceği üzere ESA model eğitimi 1000 iterasyonda 0,5’ten düşük eğitim doğrulama kaybı ile tamamlanmıştır. Tablo 4’te önerilen ESA modelinin performans sonuçlarına göre %94,78’lik bir doğruluk oranı ve %99,70’lik özgüllük skoru elde edildiği görülmektedir.

Tablo 4. Önerilen ESA model performans sonuçları (%)

Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Skor
94,78	87,37	99,70	90,54	88,62

Ayrıca Şekil 6’da test verilerin karmaşıklık matrisleri görülmektedir. Şekil 6 detaylı incelendiğinde bulaşık makinası, saç kurutma, ısı pompası, tost makinası ve su ısıtıcısı dışındaki tüm elektrikli cihazlar doğru bir şekilde tahmin edilmiştir.



Şekil 6. Önerilen ESA modeline ait karmaşıklık matrisi

Gerçekte bulaşık makinası olan ikişer adet test verileri sırasıyla saç kurutma ve su ısıtıcısı olarak hatalı sınıflandırılmıştır. Gerçekte saç kurutma olan iki test verisi, tost makinası olarak hatalı tahmin edilmiştir. Bununla birlikte gerçekte 3 tost makinası ve 2 su ısıtıcı test verisi hatalı bir şekilde saç kurutma ve bir su ısıtıcı test verisi hatalı şekilde tost makinası olarak sınıflandırılmıştır.

Önerilen yöntemin veri setindeki her bir cihaz ait daha detaylı performans analizi Tablo 5’de görülmektedir. Tablo 5’deki doğruluk oranlarına bakıldığında en düşük başarımla %96,25 saç kurutma, %97,76 tost makinası, %98,13 su ısıtıcısı ve %99,25 ile ısı pompası ve elektrikli bisiklette görülmektedir. Diğer cihazlar %100 doğruluk oranlarına sahiptir.

Tablo 5. Önerilen modelin her bir cihaza ait performans sonuçları

Elektrikli Cihaz	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Keskinlik (%)	F1 Skor
Klima	100,00	100,00	100,00	100,00	1,00
Test cihazı (Test)	100,00	100,00	100,00	100,00	1,00
Akülü Araç	100,00	100,00	100,00	100,00	1,00
Bulaşık Makinası	98,51	100,00	98,49	100,00	1,00
Kurutucu	100,00	100,00	100,00	100,00	1,00
Buzdolabı	100,00	100,00	100,00	100,00	1,00
Saç Kurutma	96,22	61,11	99,09	61,11	0,61
Isı pompası	99,25	100,00	99,24	100,00	1,00
Ütü	100,00	100,00	100,00	100,00	1,00
Led Lamba	100,00	100,00	100,00	100,00	1,00
Flüorsan Lamba	100,00	100,00	100,00	100,00	1,00
Bilgisayar	100,00	100,00	100,00	100,00	1,00
Fırın	100,00	100,00	100,00	100,00	1,00
Televizyon	100,00	100,00	100,00	100,00	1,00
Tost Makinası	97,76	78,57	98,82	78,57	0,79
Su Isıtıcısı	98,13	0,00	98,87	0,00	0,00
Çamaşır Makinası	100,00	100,00	100,00	100,00	1,00
Elektrikli Bisiklet	99,25	90,00	100,00	90,00	0,90

Tablo 6. Önerilen yöntemin son teknoloji yöntemler ile performans karşılaştırması

Yöntem	Veri Seti	Elektrikli Cihaz Sayısı	Doğruluk	Özgüllük	F1 Skor
Athanasiadis ve diğ. [10]	WHITED	22	-	-	0.755
Devlin ve Hayes [12]	UK-DALE	7	-	-	0.776
Paiva Penha ve diğ. [13]	REDD	6	0.9300	-	0.930
Le ve diğerleri [16]	PLAID	11	0.9280	-	0.924
Önerilen yöntem	Yüksek Çözünürlük	18	0.9478	0,9970	0.8862

Önerilen yöntemin detaylı performans analizi için benzer veri setlerinin kullanıldığı son teknoloji yöntemler ile performans karşılaştırmaları Tablo 6'da görülmektedir. Tablo 6'da görüldüğü üzere veri setlerindeki cihaz sayıları farklılık göstermektedir. Bununla birlikte önerilen yöntem %94,78 doğruluk oranı ile son teknoloji yöntemlerden daha başarılı olduğu görülmektedir. Önerilen yöntem [13] ve [16] çalışmalardan sırasıyla %1,78 ve %1,98 daha yüksek doğruluk oranına sahiptir. Ayrıca [10] ve [12] çalışmalardan sırasıyla %13,12 ve %11,02 daha yüksek F1 skor değerine sahiptir.

4. SONUÇ (CONCLUSION)

Bu çalışmada, konutlarda kullanılan elektrikli cihazların otomatik olarak sınıflandırılması için yeni bir derin öğrenme modeli önerilmiştir. Önerilen model, klasik ESA modellerindeki RELU aktivasyon fonksiyonu yerine ELU aktivasyon fonksiyonu kullanılan yeni bir ESA modeli ile sınıflandırma başarımının artırılması hedeflenmiştir. Çalışma ön işlem, öznitelik çıkarma ve sınıflandırma gibi aşamalardan oluşmaktadır. Deneysel çalışmalarda, halka açık konutlarda kullanılan elektrikli cihazlara ait zaman serileri kullanılmıştır. Bu zaman serileri önerilen ESA modeline uygun olarak renkli görüntülere dönüştürmüştür. Daha sonra cihazların otomatik amacıyla bu görüntüler ESA modeline uygulanarak özellik çıkarımı ve sınıflandırılmıştır. Deneysel çalışmalarda, %94,78 doğruluk ile cihazlar sınıflandırılmıştır. Önerilen yöntem veri setindeki 18 farklı cihazın 12'sini %100 doğrulukta tespit etmiştir. Ayrıca son teknoloji yöntemler ile karşılaştırıldığında daha yüksek sınıflandırma doğruluğu elde edilmiştir.

Gelecekteki çalışmalarda, konutlarda kullanılan farklı çalışma fonksiyonlarına sahip cihaz türleri ve çalışma konumlarının belirlenmesi planlanmaktadır.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) (Proje No: 121E347) tarafından desteklenmiştir. Katkılarından dolayı TÜBİTAK'a teşekkürlerimizi sunarız.

KAYNAKLAR (REFERENCES)

- [1] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53.
- [2] Aslan, M. (2021). Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *European Journal of Science and Technology*, 23, 540–546.
- [3] Aslan, M. (2022). Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 399-407.
- [4] Athanasiadis, C., Doukas, D., Papadopoulos, T., & Chrysopoulos, A. (2021). A scalable real-time non-intrusive load monitoring system for the estimation of household appliance power consumption. *Energies*, 14(3), 767.
- [5] Bouhouras, A. S., Milioudis, A. N., & Labridis, D. P. (2014). Development of distinct load signatures for higher efficiency of NILM algorithms. *Electric Power Systems Research*, 117, 163–171.
- [6] De Baets, L., Develder, C., Dhaene, T., Deschrijver, D., Gao, J., & Berges, M. (2018). Handling imbalance in an extended plaid. *5th IFIP Conference on Sustainable Internet and ICT for Sustainability, SustainIT 2017*, 1–5.

- [7] De Baets, L., Ruyssinck, J., Develder, C., Dhaene, T., & Deschrijver, D. (2018). Appliance classification using VI trajectories and convolutional neural networks. *Energy and Buildings*, 158, 32–36.
- [8] Demir, F., Abdullah, D. A., & Sengur, A. (2020). A New Deep CNN Model for Environmental Sound Classification. *IEEE Access*, 8, 66529–66537.
- [9] Devlin, M. A., & Hayes, B. P. (2019). Non-Intrusive Load Monitoring and Classification of Activities of Daily Living Using Residential Smart Meter Data. *IEEE Transactions on Consumer Electronics*, 65(3), 339–348.
- [10] Du, L., Restrepo, J. A., Yang, Y., Harley, R. G., & Habetler, T. G. (2013). Nonintrusive, self-organizing, and probabilistic classification and identification of plugged-in electric loads. *IEEE Transactions on Smart Grid*, 4(3), 1371–1380.
- [11] Gabor, D. (1946). Theory of communication. part 1: The analysis of information, *Journal of the Institution of Electrical Engineers-Part III: Radio and. Communication Engineering*, 93(26), 429–441.
- [12] Ghaderpour, E., Pagiatakis, S. D., & Hassan, Q. K. (2021). A survey on change detection and time series analysis with applications. *Applied Sciences (Switzerland)*, 11(13), 6141.
- [13] Hassan, T., Javed, F., & Arshad, N. (2014). An empirical investigation of V-I trajectory based load signatures for non-intrusive load monitoring. *IEEE Transactions on Smart Grid*, 5(2), 870–878.
- [14] Joint Research Center. (2018). The smart grid interoperability laboratory. European Research Center.
- [15] Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49.
- [16] Koç, F., ve Karabiber, A. (2021). Makine Öğrenmesi Yöntemleri Kullanılarak Elektrikli Cihazların Sınıflandırılması. *Türk Doğa ve Fen Dergisi*.
- [17] Kryonidis, G. C., Barzegkar-Ntovom, G. A., Papadopoulos, T. A., Marinopoulos, A. G., Covrig, C. F., Doukas, D. I., & Kontis, E. O. (2020). A Bottom-up Modelling Approach for Household Power Profiles Using Time-series Measurements. *UPEC 2020-2020 55th International Universities Power Engineering Conference, Proceedings*, 1–6.
- [18] Le, T. T. H., Kang, H., & Kim, H. (2020). Household appliance classification using lower odd-numbered harmonics and the bagging decision tree. *IEEE Access*, 8, 55937–55952.
- [19] Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- [20] Li, W., Zhou, Y., Cetin, K., Eom, J., Wang, Y., Chen, G., & Zhang, X. (2017). Modeling urban building energy use: A review of modeling approaches and procedures. *Energy*, 141, 2445–2457.
- [21] Lin, S., Zhao, L., Li, F., Liu, Q., Li, D., & Fu, Y. (2016). A nonintrusive load identification method for residential applications based on quadratic programming. *Electric Power Systems Research*, 133, 241–248.
- [22] Liu, H., Wu, H., & Yu, C. (2019). A hybrid model for appliance classification based on time series features. *Energy and Buildings*, 196, 112–123.
- [23] Liu, Y., Wang, X., Zhao, L., & Liu, Y. (2018). Admittance-based load signature construction for non-intrusive appliance load monitoring. *Energy and Buildings*, 171, 209–219.

- [24] Meehan, P., McArdle, C., & Daniels, S. (2014). An efficient, scalable time-frequency method for tracking energy usage of domestic appliances using a two-step classification algorithm. *Energies*, 7(11), 7041–7066.
- [25] Nalmpantis, C., & Vrakas, D. (2020). On time series representations for multi-label NILM. *Neural Computing and Applications*, 32(23), 17275–17290.
- [26] Paiva Penha, D. de, & Garcez Castro, A. R. (2018). Home Appliance Identification for Nilm Systems Based on Deep Neural Networks. *International Journal of Artificial Intelligence & Applications*, 9(2), 69–80.
- [27] Pérez-Lombard, L., Ortiz, J., & Pout, C. (2008). A review on buildings energy consumption information. *Energy and Buildings*, 40(3), 394–398. <https://doi.org/10.1016/j.enbuild.2007.03.007>
- [28] Samiee, K., Kovács, P., & Gabbouj, M. (2015). Epileptic seizure classification of EEG time-series using rational discrete short-time fourier transform. *IEEE Transactions on Biomedical Engineering*, 62(2), 541–552.
- [29] Sejdić, E., Djurović, I., & Jiang, J. (2009). Time-frequency feature representation using energy concentration: An overview of recent advances. *Digital Signal Processing: A Review Journal*, 19(1), 153–183.
- [30] Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040–53065.
- [31] Turkoglu, M., Alcin, O. F., Aslan, M., Al-Zebari, A., & Sengur, A. (2021). Deep rhythm and long short term memory-based drowsiness detection. *Biomedical Signal Processing and Control*, 65(October 2020), 102364.
- [32] Yan, D., Jin, Y., Sun, H., Dong, B., Ye, Z., Li, Z., & Yuan, Y. (2019). Household appliance recognition through a Bayes classification model. *Sustainable Cities and Society*, 46, 101393.
- [33] Yoon, S. H., Kim, S. Y., Park, G. H., Kim, Y. K., Cho, C. H., & Park, B. H. (2018). Multiple power-based building energy management system for efficient management of building energy. *Sustainable Cities and Society*, 42(May), 462–470.