

Elektrikli Ev Aletlerinde Müdahalesiz Yük İzleme, Sınıflandırma ve Kontrolünün Gerçekleştirilmesi

Fethi Batıncan Gürbüz^{1*} , Ramazan Bayındır^{1*} , Seyfettin Vadi^{1*} 

¹Gazi Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 06500, Yenimahalle/Ankara

Article Info

Research article
Received: 22/09/2023
Revision: 06/12/2023
Accepted: 07/12/2023

Keywords

Non-intrusive Load
Monitoring
KNN
SVM
Event Detection of Smart
Grids

Makale Bilgisi


Araştırma makalesi
Başvuru: 22/09/2023
Düzeltilme: 06/12/2023
Kabul: 07/12/2023

Anahtar Kelimeler

Müdahalesiz Yük İzleme
KNN
SVM
Akıllı Şebekelerin Olay
Tespiti

Grafik Özet (Graphical/Tabular Abstract)

Bu çalışmada elektrikli ev aletlerinin tespiti, müdahalesiz yük izleme yöntemiyle birlikte makine öğrenme algoritmalarıyla gerçekleştirilmiştir. / This study employs machine learning algorithms in combination with non-intrusive load monitoring methods to detect electrical household appliances.



Şekil A.: Çalışmanın Genel Yapısı / Figure A: General Structure of the Study

Highlights (Önemli noktalar)

- Makine Öğrenme Yöntemleri / Machine Learning Methods
- Müdahalesiz Yük İzleme / Non-intrusive Load Monitoring
- Kontrol Kartları ile Senaryo Çalışmaları / Scenario Studies with Control Cards
- Veri Toplama / Data Collection

Amaç (Aim): Bu çalışma ile birlikte yüksek doğrulukta verilerin tespiti müdahalesiz yük izleme yöntemiyle gerçekleştirilmesi amaçlanmıştır. Amaç doğrultusunda oluşturulan veri toplama aşaması ve makine öğrenme algoritmalarıyla tespitler yapılmıştır. / This study employs machine learning algorithms in combination with non-intrusive load monitoring methods to detect electrical household appliances.

Özgünlük (Originality): Yapılan çalışmada hibrit bir algoritma önerilmiştir. Önerilen algoritma ile literatürdeki makaleler karşılaştırılmış ve sonucunun daha iyi olduğu gözlemlenmiştir. Ayrıca veri toplama aşamasında oluşturulan kontrol kartlarıyla ile çalışmalara yeni bir bakış açısı getirilmiştir. / This study proposes a hybrid algorithm that was compared to existing literature, demonstrating superior results. Additionally, the study introduces a new perspective through the use of control cards during the data collection phase.

Bulgular (Results): Literatürdeki yayınlarda kullanılan tek çeşit algoritma yerine hibrit algoritmaların kullanılmasıyla daha yüksek doğrulukta tespitler yapılabildiği görülmektedir. Kontrol Kartları ile senaryoların oluşturulması literatürdeki zorlukların önüne geçmektedir. / Hybrid algorithms have been shown to achieve higher accuracy detections compared to single algorithms used in literature publications. To avoid the difficulties encountered in literature, scenarios with Control Cards can be created.

Sonuç (Conclusion): Çalışma sonucunda, hibrit algoritmaların daha kesin, yüksek doğrulukta tespitler yapılabilmesi için gösterilmiştir. Literatürden örnekler verilerek karşılaştırılmalar yapılmış ve diğer algoritmalarından farkı belirtmiştir. / The study demonstrates that hybrid algorithms produce more precise and accurate detections. This is supported by examples from the literature and the distinction from other algorithms.



Elektrikli Ev Aletlerinde Müdahalesiz Yük İzleme, Sınıflandırma ve Kontrolünün Gerçekleştirilmesi

Fethi Batıncan Gürbüz^{1*} , Ramazan Bayındır^{1*} , Seyfettin Vadi^{1*}

¹Gazi Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 06500, Yenimahalle/Ankara

Makale Bilgisi

Araştırma makalesi
Başvuru: 22/09/2023
Düzeltilme: 06/12/2023
Kabul: 07/12/2023

Anahtar Kelimeler

Müdahalesiz Yük İzleme
KNN
SVM
Akıllı Şebekelerin Olay Tespiti

Öz

Son yıllarda giderek büyüyen enerji ihtiyacı, araştırmacıları enerji yönetimi ve akıllı şebekeler gibi alanlara yöneltmiştir. Özellikle, şebekeye bağlı yüklerin analizleri ve izlenmesi gün geçtikçe daha da önem kazanmıştır. Bu ihtiyaç, müdahalesiz yük izleme (MYİ) yönteminin ortaya çıkmasına yol açmıştır. MYİ, elektrikli cihazların şebeke üzerinden izlenmesini ve tespit edilmesini, özelliklerine göre kategorize edilmesini amaçlamaktadır. Bu sistemler, şebekeye bağlı cihazların tek bir noktadan izlenerek güç kullanımının takip edilebilmesine katkı sağlamaktadır. Bu çalışmada, deneysel ortamda toplanan verilerle müdahalesiz yük izleme yöntemine uygun yazılım ve donanımlar oluşturulmaktadır. Ayrıca, toplanan veri setleri üzerinde yapılan çalışmalarla bir hibrit algoritma önerilmektedir. Böylece, elde edilen verilerin doğruluğu ve algoritmanın etkinliği daha iyi anlaşılmaktadır. Çalışma kapsamında geliştirilen cihaz kontrol üniteleri, yüklerin belirli senaryolarda otomatik olarak etkinleştirilmesi veya devre dışı bırakılmasını sağlayarak, yeni bir perspektif sunmaktadır. Bu sayede, enerji yönetimine daha esnek ve etkili bir yaklaşım sunulmaktadır. Çalışma, enerji yönetim sistemleri ve akıllı şebekelerin geliştirilmesine katkıda bulunmayı amaçlamaktadır. Enerji ihtiyacının artmasıyla ortaya çıkan zorluklara çözümler sunarak enerji verimliliğini artırmayı ve elektrik kayıplarını azaltmayı hedeflemektedir. Müdahalesiz yük izleme yöntemiyle elde edilen bulgular, enerji sektöründeki uygulamalara yönelik yeni çözümler sunmak için önemli bir adım olacaktır.

Non-intrusive Load Monitoring, Classification and Control in Electrical Home Appliances

Article Info

Research article
Received: 22/09/2023
Revision: 06/12/2023
Accepted: 07/12/2023

Keywords

Non-intrusive Load Monitoring
KNN
SVM
Event Detection of Smart Grids

Abstract


The growing energy demand in the past 15 years has directed researchers towards fields like energy management and smart grids, with a particular emphasis on analyzing and monitoring grid-connected loads. This has led to the emergence of Non-Intrusive Load Monitoring (NILM) methods, which aim to track and categorize electrical appliances on the grid, contributing to more efficient energy management and reduced electrical losses. In this study, software and hardware tailored for NILM are developed using experimental data, accompanied by the proposal of a hybrid algorithm to enhance data accuracy and algorithm efficiency. The study's device control units enable automated load activation or deactivation, offering a flexible and effective approach to energy management. Ultimately, this research aims to contribute to the development of energy management systems and smart grids, addressing challenges posed by increasing energy needs and providing innovative solutions for the energy sector.

1. GİRİŞ (INTRODUCTION)

Günümüzde, teknolojinin ilerlemesi nedeniyle artan enerji problemleri, enerjinin verimli kullanılmasının yanında enerjinin sınıflandırılması gerekliliğini ortaya çıkarmıştır. Bu konuda yapılan çalışmalar her geçen gün artmaktadır. Bu çalışmaların temel amacı, enerji takibi yapılarak tahminlerde bulunulması sonucunda enerji verimliliğinin artırılması, maliyetlerin azaltılmasıdır. Literatürde

yapılan çalışmalara bakıldığında, enerji verimliliği konusunda tartışmalı ve öne çıkan bir konu olan akıllı şebekeler, önemli bir odak noktası olmuştur. Akıllı şebekeler, son kullanıcıların enerji üretimine doğrudan katkı sağlayabilme özelliğiyle büyük bir avantaj sunmaktadır [1]. Mevcut şebeke yapılarında bulunan sayaçlar, Şekil 1'de görüldüğü üzere, sadece haftalık veya aylık periyotlarda genel tüketim verilerini sunarak sınırlı bilgi

sağlamaktadır. Yapılan bir araştırma, bu tür sayaçların dahi son tüketim noktalarına entegre edilmesiyle enerji tasarrufu sağlanabileceğini göstermiştir [2-3].



Şekil 1. Hane ve cihazların geri bildirim grafiği

(Feedback graph of households and devices)

Şekil 1'de görülen hane ve cihazların geri bildirim grafiğinde elde edilen sonuçlar, tüketiciye belirli bir süre sonunda ödenecek toplam tutarın belirlenebilmesini sağlamaktadır. Bu tüketim verileri, sayaçlar aracılığıyla detaylı bir şekilde tüketiciye sunulmaktadır ve bu veriler doğrultusunda tüketiciye kendi önlemlerini almak için sistem tarafından fırsat verilmektedir. Tüketim verilerinin sadece son tüketicileri ilgilendirdiği düşünülebilir; ancak, enerji üreten şirketler için de bu bilgilerin elde edilmesi son derece önemlidir. Enerji üreten firmalar, bu verileri kullanarak üretim planlamalarını daha doğru ve kesin bir şekilde gerçekleştirebilmektedir. Akıllı şebekelerin uygulanmasıyla birlikte, son tüketiciler ve enerji üreticileri işbirliği yaparak maliyetleri ve enerji tüketimini azaltma potansiyeline sahip olacaktır. Literatürdeki çalışmalar, evlerdeki elektrik enerji tüketiminin %12 oranında azaltılabileceğini göstermektedir [2-3]. Bundan dolayı akıllı şebekelerin benimsenmesi ile hem tüketici hem de enerji üreten firmalar için önemli avantajlar sunabileceği sonucuna varılmaktadır.

Akıllı şebekeler sayesinde yük-cihaz yönetim sistemleri, sayaçlar ve enerji analizörleri gibi inovasyonlar, elektrikli cihazların şebekeye entegre edilmesi ve verilerin kaydedilmesi konusunda çözümler sunmaktadır. Literatürde yapılan araştırmalar, cihaz yük izleme (CYİ) alanında müdahaleli ve müdahalesiz olmak üzere iki ana kategori olduğunu göstermektedir. Müdahaleli yük izleme, sensörlerin şebeke girişlerine ve her bir cihaza takılarak gerçek zamanlı izleme sağlayan çalışmaları içermektedir. Müdahaleli yöntem, yüksek izleme doğruluğu sağlamasıyla dikkat çeker. Bununla birlikte, müdahalesiz yük izleme (MYİ) çalışmaları, maliyet ve uygulanabilirlik


açısından önem kazanmaktadır. MYİ yöntemi, genellikle elektrik devresinin girişindeki bir sensörden alınan verilerle cihazların karakteristik özelliklerini belirlemeyi amaçlar. Bu yaklaşımın esas amacı, şebeke girişine bağlı analizör tarafından elde edilen verileri kullanarak şebekeye bağlı yükleri ayırt etmek ve bu ayrıştırılmış sinyalleri ilgili yüklerle ilişkilendirmektir. En uygun koşullarda, geliştirilen yöntemler aracılığıyla hatta bağlı cihazların elde edilmiş ana sinyalden takip edilmesi amaçlanmaktadır. Geleneksel elektrik sayaçları sadece genel enerji tüketimini ölçerken, MYİ yöntemi cihaza özgü elektriksel imzaları tanımlayarak genel elektrik sinyalini analiz ederek ve bileşenlerine ayırmaktadır. Bu şekilde, enerji tasarrufunu desteklemek ve enerji verileriyle akıllı ev uygulamalarını zenginleştirmek için daha ayrıntılı bir analiz yapmayı sağlar.

MYİ, 1985 yılında George W. Hart tarafından yapılan çalışmalar sonucunda ortaya çıkmış bir yöntemdir. Başlangıçta evler veya binalar gibi yapılar için toplam güç ölçüm cihazı olarak kullanılan MYİ yönteminin, daha sonraki çalışmalar ve teknolojik ilerlemelerle birlikte kullanıcıların tasarruf etmesine ve çevresel etkileri azaltmasına yardımcı olabileceği keşfedilmiştir. Evler veya elektrikli cihaz sistemleri gibi sistemlerde, cihazların enerji tüketimlerini belirleyebilmek için gerilim ve akım sensörlerinden oluşan cihazlarla izlenmeleri gerekmektedir. MYİ, bu sensörler aracılığıyla şebekeye bağlı cihazları algılamaya yardımcı olan bir yöntemdir. Bu sistemlerin kullanımının en önemli avantajı, geleneksel yöntemlerde olduğu gibi her bir cihaza takılan ölçüm sensörleri yerine, ölçümlerin şebeke giriş noktasından elde edilebilmesidir. Bu sayede kurulum maliyetlerinin azaltılması hedeflenmektedir. Yapılan çalışmalar, enerji yönetimi ve gerçek zamanlı verilere dayalı olarak enerji tüketiminde önemli oranda tasarruf sağlanabileceğini ortaya koymuştur [3-7].

Son zamanlarda MYİ yöntemi için yapay zeka tekniklerinin kullanımı üzerinde araştırmalar yapılmaktadır. Bu araştırmalarda, mevcut verilerin kullanılarak eğitim süreçleri gerçekleştirilmiştir. Bu eğitim sonucunda, cihazların sınıflandırılması hedeflenmiştir. MYİ yöntemi ile ilgili olarak makine öğrenmesi temelli birçok çalışma yapılmıştır [8]. Bu çalışmalar, cihazların tanımlanması ve olayların tespiti gibi hedeflere ulaşmada önemli bir rol oynamıştır. MYİ yöntemi,

literatürde farklı yaklaşımlarla ele alınmış ve çeşitli çalışmalar gerçekleştirilmiştir. İlgili örnekler arasında harmonik tabanlı araştırmalar [9-10], geçici durum analizine dayalı çalışmalar [11], kararlı durum analizleri ve akım-gerilim (VI) yörünge tabanlı analizler [12] gibi farklı yöntemler bulunmaktadır. Bu çalışmaların içeriğinde, yüksek frekanslı ölçümler, karmaşık hesaplamalar gerektiren senaryolar ve çoklu değişkenler gibi zorluklarla karşılaşmaktadır. Yüksek maliyetler ve sınırlı veri toplama imkanları gibi faktörler, sistemlerdeki zorlukları artırmaktadır. Gerçek zamanlı verilerin işlenmesi ve sistemlere uygulanması konusunda da bazı zorluklar bulunmaktadır, bu nedenle bu çalışmalar genellikle simülasyonlarla sınırlı kalmaktadır.

MYİ çalışmasının uygulanabilmesi için yapısal ve devreye bağlanma aşamaları mevcuttur. İlk adım olarak, cihazın şebekeye entegrasyonu gerçekleştirilir ve her bir fazdaki yüklerden elektriksel veriler toplanır. Ardından, bu verilerin ne zaman ve hangi aralıklarla devreye alındığı veya devreden çıktığı, olay tespiti aşamasında belirlenir. Bu aşamadan sonra, cihazların karakteristik özelliklerine göre bir özellik çıkarma yöntemi kullanılarak yük tespiti aşamasına geçilir. MYİ algoritmasının genel yapısı, Şekil 2'de gösterildiği şekliyle sunulmaktadır.



Şekil 2. MYİ algoritma aşamaları (MYI algorithm stages)

Literatürde yapılan çalışmalara bakıldığında, yapay sinir ağlarının yük belirleme sürecinde kullanıldığı gözlemlenmiştir. Roos tarafından yapılan çalışmada, endüstriyel elektrik yüklerinin ayrıştırılması ve sınıflandırılması için kararlı durum analizi yöntemi kullanılmıştır [13]. Ayrıca, Srinivasan tarafından MYİ yöntemi kullanılarak harmonikler üzerinde yapay sinir ağlarıyla geliştirilen bir yöntem yayınlanmıştır [14]. Bu çalışmalardaki yöntemlerin temelinde harmoniklerin etkilerinin tam olarak analiz edilmesi ve dikkate alınması gerekliliği vurgulanmıştır [15]. MYİ yöntemi, elektrik şebekesine bağlı olan cihazların herhangi bir anda hangilerinin aktif olduğunu ve bu cihazların toplam tüketim yüzdelerini belirlemeye yönelik bir zaman serisi

sınıflandırma problemi olarak karşımıza çıkmaktadır.

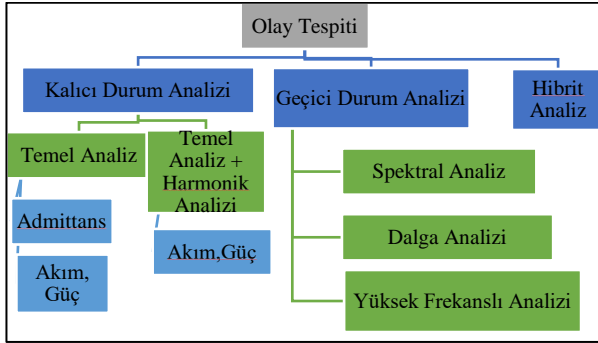
1.1. Veri Toplama (Data Collection)

Genel olarak MYİ yapısının ayrıntılı açıklamaları bu aşama olarak Şekil 2'de sunulmaktadır. Veri toplama aşamasında, MYİ yöntemiyle ilgili çalışmalarda evlerin ana giriş şebekelerine takılan sensörler vasıtasıyla cihazların verileri toplanmaktadır. Verilerin toplanma yöntemi çeşitli çalışmalarda farklılık gösterebilmektedir. Örneğin, bazı çalışmalarda aktif güç ölçümü için sensörler kullanılmakta ve bunun için voltaj, akım ve güç faktörü gibi temel ölçümler yapılmaktadır [16]. Diğer bir ölçüm yaklaşımı ise görünür güç, $\cos\theta$ ve reaktif güç gibi parametreleri içermektedir. Ayrıca, elektriksel karakteristikler, elektromanyetik bozunum (EMI), harmonik bozulma [17] ve geçici olaylar gibi ölçümler de yapılabilmektedir. Elektrik sinyallerinin analizi için kullanılan çalışmalarda genellikle iki temel veri toplama yöntemi öne çıkmaktadır [18]: yüksek örnekleme ve düşük örnekleme. Yüksek örnekleme yöntemi, 50 Hz ve daha yüksek hızlarda veri toplama işlemini kapsamaktadır ve bazı tüketim verilerinin kullanılmasında gereklidir. Bununla birlikte, yüksek maliyetli sensörlerin kullanımı nedeniyle genellikle özel çalışmalarda tercih edilmektedir. Düşük örnekleme yöntemi ise, örnekleme hızının 50 Hz ve daha düşük olduğu durumları ifade etmektedir. Bu durumda genellikle dakika veya saatlik veri toplama süreleri kullanılmaktadır. Düşük örnekleme yönteminin kullanım alanı geniş olup, literatürdeki çalışmaların bu örnekleme hızında gerçekleştirildiği gözlenmektedir.

1.2. Olay Tespiti (Event Detection)

Olay tespiti, MYİ algoritmasının etkin bir şekilde çalışabilmesi için kritik bir aşamadır. Bu aşamada, şebekeye bağlı her bir cihazın anahtarlama zamanları belirlenir. Genellikle, olay tespiti aktif gücün genlik değerine dayalı olarak gerçekleştirilir. Olay tespiti konusunda birçok çalışma yapılmıştır. Anderson'ın çalışmasında, olay tespitini dört gruba ayırarak analiz etmiştir: Uzman Sezgisel Modeller, Olasılık Modelleri, Şablon Eşleştirme Modelleri ve Hibrit modeller. Pencere tabanlı olay tespiti yöntemi temel alınarak geliştirilen uzman sezgisel modeller, normalize edilmiş rüzgâr enerjisi verileri üzerinde etkinlik göstermektedir ve bu algoritma George W. Hart tarafından hayata geçirilmiştir. Cihazlardan elde edilen grafiklere dayanarak, anlık

tepkiler, kalıcı ve geçici durumlar olarak tanımlanmıştır [18-19]. Olasılık modelleri, literatürde yapılan çalışmalarda, toplam güç tüketiminde değişim yaşandığı anlarda olay tespiti gerçekleştirilmektedir. Bu tür senaryolar genellikle, sistem devreye alındığında veya çıkarıldığında meydana gelen anlar olarak kabul edilir. Ancak, bazı durumlarda, devreye alma ve çıkarma işlemleri çeşitli faktörler tarafından etkilenebilmektedir. Bu tür durumlarda, sistemin devreye alındığı an ile sistemde meydana gelen bir gürültü arasındaki ayrımı yapmak gereklidir. Bu nedenle, bu tür durumları analiz etmek için bazı çalışmalar yapılmıştır [20-24]. Hibrit model çalışmalarında ise, birden fazla yöntemin eş zamanlı olarak uygulanmasıyla olay tespiti gerçekleştirilir. Afzalan'ın geliştirdiği yöntem, kümeleme yöntemi ve yapay sinir ağları tabanlı bir yaklaşım, bu çalışmada önerilmiştir [25]. Ek olarak, elektriksel ölçümler ve bu ölçümlere dair analizler, olay tespiti çalışmalarında genel olarak temel olarak kullanıldığı şekilde, Şekil 3'te gösterilmiştir.



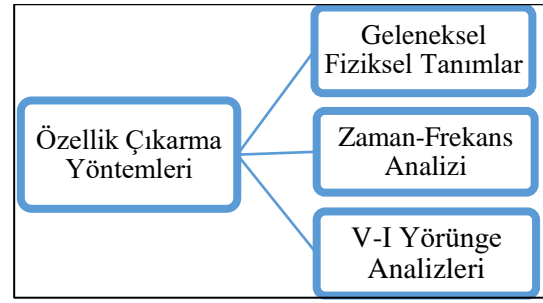
Şekil 3. Olay tespiti temel analiz yöntemleri

(Fundamental analysis methods of event detection)

MYİ çalışmalarında, özellik çıkartma aşaması, şebekede olan cihazların kendine özgü elektriksel karakteristik imzalarını veya özelliklerini elde etmek amacıyla kullanılmaktadır. Bu sebeple, özellik çıkartma yöntemleri MYİ alanında büyük bir öneme sahiptir.

1.3. Özellik Çıkartma (Feature Extraction)

Genel olarak, özellik çıkartma yöntemleri, gerilim ve akım sinyallerinden bilgi elde etmek amacıyla kullanılmaktadır. Literatürde kullanılan özellik çıkartma yöntemleri Şekil 4'te verilmiştir. [26].




Şekil 4. Özellik çıkarma yöntemleri (Feature extraction methods)

Geleneksel fiziksel tanımlara dayalı özellik tabanlı çalışmalar genellikle, elektrikli cihazların elektriksel karakteristik özelliklerine odaklanır. Powers'ın çalışmasında, aktif güç değişimi kullanılmıştır. Öte yandan, Hart reaktif ve aktif güçlerin birleşimine dayalı yöntemler üzerinde çalışmıştır [24-27]. Özellik tabanlı zaman-frekans analiz yöntemleri, akım ve gerilim sinyallerinden yüksek frekansta daha fazla bilgi çıkarılabileceği fikriyle geliştirilmektedir [25-27]. V-I yörünge analizine dayalı özellik tabanlı yöntemler ise, Lam tarafından cihazların elektriksel karakteristiklerini tanımlamak amacıyla önerilmiştir. Bu tür çalışmalarda, V-I yörüngeleri için döngü yönü ve orta segmentin eğimi gibi parametreler kullanılmaktadır [27-28]. Bu çalışmalar sırasında başlıca zorluk, bilgi kaybıdır. Bu sebeple De Baets, güçlendirilmiş V-I yörünge yöntemini önermiş ve bu bağlamda, V-I yörünge yöntemi için bölgesel ağırlık değerlerinin kullanıldığı sonuçlar elde edilmiştir [28-29].

1.4. Yük Belirleme (Load Identification)

Yük belirleme, MYİ yönteminin kritik aşamalarından biridir. Bu aşamada, şebekeye bağlı olan elektrikli cihazların özelliklerinin sınıflandırılması için uygulanmaktadır. Bu amaçla, enerji tüketim verileri kullanılarak cihazların durumları belirlenir ve elde edilen sonuçlar analiz edilerek değerlendirilmektedir. Şekil 5'te yük belirleme yöntemleri gösterilmektedir.



Şekil 5. Yük belirleme yöntemleri (Load identification methods)

Fiziksel analiz yöntemleri genellikle dalga formlarının ayrıntılı bir şekilde incelendiği çalışmaları içerir. Bu yaklaşımlarda, geleneksel dalga formlarının yapısı dikkatlice analiz edilir ve bu analizler sonucunda çeşitli sonuçlar elde edilir. Dalga analizi, sinyal analizi, sayısal analiz ve görüntü işleme gibi bir dizi yöntem, uzun yıllardır literatürde kullanılan etkili araçlardan birkaçıdır. Ancak, MYİ çalışmaları genellikle sinyal analizi temelli yayınlarla daha çok öne çıkmaktadır [28-31].

Makine öğrenmesi tabanlı yöntemler, MYİ çalışmalarında özellik çıkarımından sonra kullanılır. Zheng, elektriksel karakteristiklere dayalı bir sınıflandırma yaklaşımı benimsemiştir. Hassan, güçlendirilmiş SVM (destek vektör makinesi), yapay sinir ağları ve uyarlanabilir destek yöntemlerini karşılaştırmıştır. Mario ise K-En Yakın Komşuluk (KNN) yöntemini literatüre katkı sunmak için kullanmıştır, bu genellikle makine öğrenmesi çalışmalarında kullanılır. Mathis, karar ağacı ve naive bayes sınıflandırma algoritmalarını birleştirerek makine öğrenmesi tabanlı bir yaklaşım sunmuştur. Ayrıca, MYİ uygulamalarında SVM kullanılmış bir çalışma da bulunmaktadır. SVM, çeşitli alanlarda yaygın olarak kullanıldığından MYİ içinde uygulanması sürpriz olmamaktadır. SVM çalışmalarında genellikle sınıflandırma tabanlı yaklaşımlar kullanılmaktadır [30-32].

Şablon eşleme temelli yük belirleme yöntemleri, genellikle önceden tanımlanmış bir sinyali anlık ölçülen sinyalle karşılaştırarak çalışır. İki türü bulunur: direkt şablon eşleme ve kombinasyon tabanlı şablon eşleme. Doğrudan şablon eşleme, ölçülen ve şablon sinyalleri arasındaki mesafeyi doğrudan ölçerek sonuç üretir. Kombinasyon tabanlı algoritmalar ise genellikle genetik algoritma veya doğrusal programlama gibi yöntemlerin kombinasyonunu içerir [48-53]. Derin öğrenme tabanlı yöntemler, literatürde makine öğrenmesi tabanlı çalışmalar gibi kabul edilir. Yapay sinir ağları ise bu alanların daha geniş bir kapsamını oluşturur. MYİ çalışmalarında, her katman farklı algoritmaların çalıştırılmasını sağlayarak esneklik ve tanımlamaları kolaylaştırır. Bir çalışmada, CNN (Evrişimsel Sinir Ağları) algoritması kullanılarak yük belirleme yöntemi uygulanmış ve %84 doğruluk elde edilmiştir [30-33]. Başka bir çalışmada, LSTM (Uzun Kısa Süreli Bellek) yöntemi MYİ yük belirleme için kullanılmış ve %80 kesinlik sağlanmıştır. HMM (Gizli Markov

Modeli), zaman serilerinde kullanılan bir yöntemdir. MYİ yük belirleme yöntemleri, zaman serileri çalışmalarına benzer düşünceyle, HMM'nin denendiği alanlardandır. Parson, Kolter ve Makonin [31-33], yük belirleme aşamalarında HMM kullanmıştır.

MYİ çalışmaları için yeni verilerin sürekli olarak toplanması mümkün olmayabilmektedir. Bu durumda, cihazların güç tüketimindeki farklılıklar, veri toplamanın yüksek maliyeti veya verilerin uyumsuzluğu gibi nedenlerle hazır veri setleri kullanılarak çalışmalar yürütülebilmektedir. Bu tür çalışmalar için genellikle açık erişimli veri tabanları bulunmaktadır. Bu veri tabanları, farklı algoritmaların denenmesi amacıyla bazı referans verilerini içermektedir. Çalışmaların yöntem aşamalarının değerlendirilmesi ise belirli bir ölçüt temelinde gerçekleştirilmektedir. Bu çalışmada kullanılan değerlendirme ölçütleri, regresyon-sınıflandırma ölçütlerine dayanmaktadır. Regresyon ölçütleri, MYİ algoritmasının her bir cihaz tarafından ne kadar iyi tahmin edildiğini ölçmek için kullanılmaktadır. Ortalama Mutlak Hata (MAE), literatürde en yaygın kullanılan ölçütlerden biridir ve diğer makalelerle karşılaştırma yapılması gerektiğinde önemli bir rol oynamaktadır. Kök Ortalama Kare Hata (KOKH) ise tahmin edilen değer ile ölçülen gerçek değer arasındaki farkı hesaplamaktadır. Ancak bu ölçüt bazı sorunlarla karşılaşmaktadır. Ölçüm değerlerinin bir ölçek üzerinde ifade edilmesi gerektiği durumlarda, bu ölçütte bir ölçek bulunmadığından değerler birbirinden bağımsız gibi kabul edilir ve karşılaştırılmazlar. Bununla birlikte, literatürde değerlendirme kriteri olarak kullanılmaktadırlar. Regresyon Katsayısı ise doğrusal bir regresyon tahmininin kalitesini ölçmek için kullanılmaktadır. Bu ölçüt 0 ile 1 arasında değer alır ve 1'e ne kadar yakınsa modelin o kadar iyi olduğu ifade edilmektedir. Sınıflandırma ölçütleri, MYİ algoritmalarının cihazlara özgü gerçek ve tahmin edilen değerler arasındaki farkları tespit etmek için kullanılır. Bu ölçütler Tablo 1'de görülmektedir.

Tablo 1. Sınıflandırma değerlendirme ölçütleri

(Classification evaluation criteria)

Ölçüt	Matematiksel Eşitlik
Kesinlik	$\frac{TP}{FP + TP}$
Doğruluk	$\frac{TN + TP}{TN + FN + TP + FP}$
Hassasiyet	$\frac{TP}{TP + FN}$
F-Puan	$\frac{2 * TP}{2 * FN + TP + FP}$

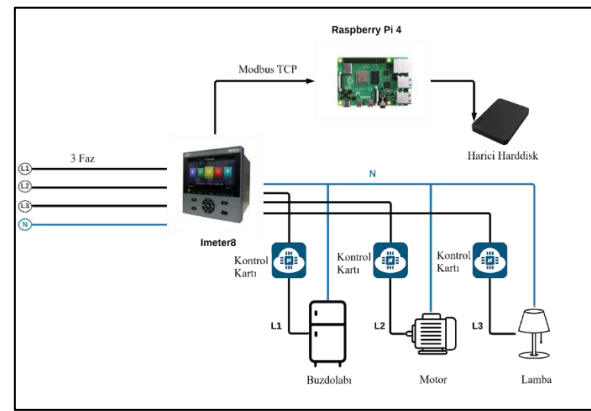
TP (Doğru Pozitif), doğru pozitif tahmin edilen değerleri ifade etmektedir. Bu durumda gerçek sınıf değeri 1 (mantıksal olarak doğru) ve tahmin edilen sınıf değeri de 1'dir (mantıksal olarak doğru). TN (Doğru Negatif), doğru negatif tahmin edilen değerleri ifade etmektedir. Bu durumda gerçek sınıf değeri 0 (mantıksal olarak yanlış) ve tahmin edilen sınıf değeri de 0'dır (mantıksal olarak yanlış). FP (Yanlış Pozitif), yanlış pozitif tahmin edilen değerleri ifade etmektedir. Bu durumda gerçek sınıf değeri 0 (mantıksal olarak yanlış), ancak tahmin edilen sınıf değeri 1'dir. FN (Yanlış Negatif), yanlış negatif tahmin edilen değerleri ifade etmektedir. Bu durumda gerçek sınıf değeri 1 (mantıksal olarak doğru), ancak tahmin edilen sınıf değeri 0'dır.

Bu çalışmada, elektrik şebekesinden elde edilen cihaz verileriyle bir veri toplama alt yapı sistemi tasarlanmaktadır. Toplanan veriler, ana şebeke ve cihaz özelinde akım, gerilim, aktif-reaktif-görünür güç ve faz farkı gibi bilgileri içermektedir. Bu veriler, 50 kHz örnekleme zamanına sahiptir ve açık erişim veri setlerinden farklılık göstermektedir. Elde edilen veriler, bir arayüz programında görselleştirilerek şebekeye bağlı cihazların uzaktan kontrol edilmesini sağlamaktadır. MYİ algoritması aşamaları, toplanan verilerin işlenmesiyle olay tespitini ve özellik çıkarma işlemini gerçekleştirmektedir. Ayrıca, toplanan veri setleri kullanılarak SVM, KNN, karar ağacı ve rastgele orman gibi sınıflandırma algoritmaları denenmektedir. Bu algoritmaların performanslarını ölçmek için karşılaştırma tabloları sunulmaktadır. Toplanan veri setlerinin performansları değerlendirilerek SVM sınıflandırma ve rastgele orman algoritmalarıyla yeni bir hibrit algoritma önerilmektedir. Bu önerilen hibrit algoritma, veri analizinde daha iyi bir performans sergileme potansiyeline sahiptir.


2. MATERYAL VE METOD (MATERIALS AND METHODS)

2.1. Veri Toplama (Data Collection)

MYİ yöntemi çalışmaları, düşük ve orta güç tüketen yerlerin giriş şebekelerine takılan sensörler aracılığıyla veri elde ederek gerçekleştirilir. Bu aşamada verilerin çeşitli yöntemlerle toplanması mümkündür. Bazı çalışmalarda sensörler aracılığıyla alternatif akım ölçümleri gerçekleştirilirken, bu sayede temel ölçümler yapılabilir. Diğer çalışmalarda ise güç faktörü, harmonik bozulma ve reaktif güç ölçümleri gibi farklı parametrelerin ölçümü gerçekleştirilebilir. Bu çalışmada, Şekil 6'da sunulan blok diyagrama uygun bir tasarım gerçekleştirilmiştir.



(a)



(b)

Şekil 6. (a)Çalışmada gerçekleştirilen yapının blok diyagramı, (b)Deneyel veri toplama düzeneği


((a)Block diagram of the structure realised in the study,

(b)Experimental data collection setup)

Yapılan çalışmada, yüksek örnekleme özelliğine sahip Imeter8 enerji analizörü kullanılmıştır. Bu sistemin temel amacı, yüksek doğruluk seviyesinde veri elde etmektir. Şekil 6'da görüldüğü gibi, Imeter8 enerji analizörü aracılığıyla veri toplama işlemi gerçekleştirilmektedir. Bu amaçla, farklı

karakteristik özelliklere sahip dört cihazdan veri almak için bir deney düzeneği oluşturulmuştur: Buzdolabı, saç kurutma makinesi, çamaşır makinesi ve bulaşık makinesi. Akım, hat ve faz gerilimi, aktif-reaktif-görünür güç, şebeke frekansı ve güç faktörü gibi bilgiler elde edilen verilerde bulunmaktadır. Bu cihazlardan alınan veriler belirli bir senaryoya göre kaydedilmektedir. Senaryoların seçiminde, MYİ algoritmasının uygulanabilmesi için bazı kısıtlamalar dikkate alınmaktadır. Bu sınırlamalar, bir cihazın anlık durumunun değiştirilmemesi ve kaydedilen iki cihazın başlangıç zamanlarının eş zamanlı olarak başlamaması gibi etkenlere dayalıdır.

Çalışmanın diğer makalelerden ayıran bir diğer özellik, cihaz kontrol kartlarının tasarlanmasıdır. Bu kontrol kartları sayesinde cihazlar, bir arayüz üzerinden uzaktan kontrol edilebilme imkanı sağlamaktadır. Tasarlanan kontrol kartları, belirli senaryoların eklenmesiyle cihazların tepkilerinin gözlemlenmesini sağlamaktadır. Her faz için temel elektriksel değerler (aktif-reaktif güç, akım-gerilim-frekans) ve kontrol kartlarının durumu gerçek zamanlı olarak elde edilerek tasarlanan arayüz programında gösterilmektedir. Örnek olarak verilen cihazların akım grafiği Şekil 7'de görülmektedir.



Şekil 7. Kaydedilen buzdolabı-bulaşık makinesi grafiği (Recorded fridge-dishwasher graph)

Şekil 7'deki gösterim, bulaşık makinesinin belirli bir süre boyunca çalıştırdıktan sonra buzdolabının etkin hale geldiği anı göstermektedir. Ardından, bulaşık makinesinin 30 dakikalık programının tamamlanmasının ardından buzdolabı tek başına çalışmasına devam etmektedir.


2.2. Olay Tespiti (Event Detection)

Olay tespiti, şebekeye bağlı her bir cihazın anahtarlama zamanlarının saptanmasıyla gerçekleştirilir. Genellikle, olay tespiti aktif gücün değişimi temel alınarak yapılır. İlk çalışmalardan

birinde, George W. Hart tarafından rüzgâr enerjisi verileri analiz edilmiş ve standart sapma ile önceden belirlenmiş eşik değerleri kullanılarak olay tespiti gerçekleştirilmiştir. Olasılıksal modeller ise toplam güç tüketiminin değiştiği zamanlarda meydana gelen olayları inceler. Sistemlerin devreye giriş ve çıkış zamanlarına yönelik çalışmalar yapılmaktadır. Ancak bu süreçler bazen çeşitli etkenlerden etkilenebilir. Geliştirilen sistemde, olay tespiti olasılıksal yöntemler kullanılarak gerçekleştirilir. Genellikle sistemlerin devreye girdiği anlarda aktif toplam güç değişiklikleri üzerine odaklanılır. Bu amaçla matematiksel olarak ifade edilen Eş. (1) formülü kullanılmaktadır.

$$\Delta P = P_{tk} - P_{tl} \quad (1)$$

ΔP , aktif gücün değişim miktarını temsil etmektedir. P_{tk} , t+1 anındaki aktif güç değerini, P_{tl} ise, t anındaki aktif gücü ifade etmektedir. Bu çalışmada olay tespiti, sistemlerin anlık değişimlerini analiz ederek gerçekleştirilmektedir. Eş. (1) kullanılarak elde edilen verilerle bir buzdolabı üzerinde olay tespiti gerçekleştirilmiş ve Şekil 8'de bu çalışmanın sonucunu gösteren bir grafik gösterilmektedir.



Şekil 8. Toplanan veri seti ile yapılan buzdolabının olay tespit grafiği (Event detection graph of the refrigerator made with the collected data set)

2.3. Özellik Çıkartma (Feature Extraction)

MYİ çalışmaları, cihazların benzersiz elektriksel karakteristik imzalarını veya özelliklerini analiz etmeye odaklanmaktadır. Bu nedenle, özellik çıkarma yöntemleri MYİ çalışmalarının önemli bir parçasıdır. Genel olarak, gerilim, akım, aktif güç gibi sinyallerden cihazların kimlik bilgisini elde etmek için özellik çıkarma yöntemleri kullanılmaktadır. Bu çalışmada ise özellik çıkarma aşamasında V-I yörünge tabanlı bir analiz kullanılarak cihazların sınıflandırılması amaçlanmaktadır. Bu çalışmada kullanılan yöntem SVM'dir. SVM, sıklıkla denetimli bir makine öğrenme algoritması olarak sınıflandırma

çalışmalarında kullanılmaktadır. Algoritmanın temel prensibi, iki nokta kümesi arasında ayırım yapabilme yeteneğidir. Bu ayırım sayesinde bir düzlem oluşturularak sınıflandırma işlemi gerçekleştirilebilir. Çalışmada elde edilen V-I bilgileri uygun bir resim formatına dönüştürülerek işlenir. Cihazlar kararlı duruma geçtikten sonra, alınan akım ve gerilim verileri kullanılarak en yüksek ve en düşük akım ile gerilim değerleri belirlenir. Görüntü çözünürlüğü önceden belirlenir ve V-I genişlikleri hesaplanır. Sınıflandırmak için elde edilen görüntüler bu çözünürlük formatına çevrildikten sonra çalışılacak olan dosya şekline dönüştürülür. Görüntü aşamasının islenmesi için son aşama V-I değerlerini ikilik sisteme dönüştürülmesidir. SVM sınıflandırma algoritması için girdi değerlerine ihtiyaç duyulmaktadır. SVM algoritması için, görüntülerden elde edilen ölçümler ve değerlendirmeler sonucunda girdi olarak kullanılırlar. Çevresinde bağlantılı alan sayısı, bu değerlendirme aşamalarındandır. Bu ölçüt, resimlerin en küçük yapı birimi olan piksellerle matematiksel değerlendirmeler yapmak için gereklidir. Her piksel, 4-8 arasında komşu pikseli bulunmaktadır. İki piksel bir noktadan birleşirse, bu durumda piksellerin iletişim halinde olduğu söylenir. Tüm noktaların birbirlerine bağlı oldukları piksel noktalarına ise bağlantılı alan denir ve bu alan P_c olarak kullanılır. Euler numarası ise ikilik tabanda yapılan görüntü analizlerinde önemli bir rol oynamaktadır. Euler numarası, Eş. (2) kullanılarak hesaplanır.

$$E = P_c - P_h \quad (2)$$

P_h bir görüntüdeki bağlı noktadaki delik veya boşlukları temsil etmektedir. Değişen alan oranı ise, görüntünün ikilik tabanda dönüştürülmesi sonrasında genişlemesini ifade etmektedir. Genişletilmiş görüntü ile bir önceki görüntü arasındaki alan oranı hesaplanarak P ile gösterilmektedir. Özellik çıkarma aşamaları, bir cihazın özelliklerini saptamak için gerilim-akım grafiğini görsel olarak farklı çözünürlük değerleriyle kaydetmekle başlamaktadır. Çalışmalarda farklı seçenekler olsa da en tutarlı sonuçların üretildiği 16x16, 28x28 ve 50x50 çözünürlükleri bu çalışmada kullanılmaktadır. Seçilen çözünürlüklerdeki resimler, ikilik tabanda ve 0-1 aralığında kaydedilmektedir. Cihaz seçimleri yapılırken ise kararsız durum gösteren V-I grafiğine sahip cihazlardan kaçınılmıştır. Bu sayede algoritmanın ön elemeyi geçirmesi sağlanmıştır. Bilimsel araştırmalarda, VI yörünge analizinin yüksek ayırım gücü sağladığı ve yük planlaması için kritik öneme sahip olduğu ifade edilmektedir. Bu kriterlere dayalı olarak yük seçimlerinin yapılması beklenmektedir. Algoritmanın bir sonraki adımında, resimlerin çözünürlükleri değiştirilip kaydedilmektedir. İkilik tabanında ve gerçek çözünürlükte elde edilen verilerin resimleri Tablo 2'de paylaşılmıştır.

Tablo 2. Gerçek I-V ile farklı çözünürlüklere dönüştürülmüş I-V grafikleri (Real I-V and I-V graphs converted to different resolutions)

Cihaz Türü	Gerçek Görüntü	16 x 16	28 x 28	50 x 50
Buzdolabı				
Bulaşık Makinesi				
Saç Kurutma Makinesi				
Çamaşır Makinesi				

2.1. Yük Belirleme (Load Identification)

Yük belirleme, MYİ aşamalarının bir parçası ve bu çalışmada kullanılan son aşamayı temsil eder. Bu

aşamada, cihazların özgül özelliklerinin sınıflandırılması amaçlanır. Cihazların işletim durumları ve enerji tüketim verileri kullanılarak

hesaplamalar gerçekleştirilir. Çalışmada ise, makine öğrenmesi tabanlı bir yaklaşım benimsenmiştir. Makine öğrenmesi, cihazların özellikleri çıkartıldıktan sonra sınıflandırma aşamasında kullanılan bir yöntemdir. Çalışmada karar ağaçları, rastgele ormanlar ve KNN gibi farklı tipte makine öğrenmesi tabanlı algoritmalar uygulanmıştır. Algoritmaların değerlendirilmesi genellikle doğruluk ve f-puanı gibi metrikler üzerinden yapılmaktadır. Elde edilen sonuçlar doğrultusunda yeni bir hibrit algoritma önerisiyle literatüre katkı sağlanmaktadır.

Karar Ağaçları Algoritması

Karar ağaçları, eski bir sınıflandırma ve regresyon yöntemi olup 1986 yılından beri kullanılmaktadır. Bu yöntemde entropiden faydalanılmaktadır. Entropi, beklenmedik bir durumun gerçekleşme olasılığını ifade eder. Rastgelelik ve belirsizliğin olasılıkla gösterildiği bir kavramdır. Bir sistem ne kadar homojen bir yapıya sahipse, entropisi o kadar düşük olur. Sınıflandırma işlemi sırasında karar ağaçları kullanılır ve bilgi kazancı bu süreçte hesaplanır. Bilgi kazancı, veri setinin özel özelliklere göre ayrıştırıldıktan sonra elde edilen entropi değerinden çıkarılarak hesaplanır. Genel formülü Eş. (3)'te verilmiştir.

$$\text{Bilgi Kazancı}(X, T) = \text{inf}(T) - \sum_{i=1}^s \frac{|T_i|}{T} x \text{inf}(T_i) \quad (3)$$

T, bir veri kümesi örnekleme setini temsil etmektedir. Inf(T), T veri kümesinin entropisini ifade eder ve X özniteliği yapısına göre T veri kümesini alt kümelerine bölmek için kullanılır. Entropinin düşük değerleri, algoritmanın performansını doğrudan etkiler. Bu çalışmada, karar ağaçları algoritmasının uygulanması için toplanan veri kümesi kullanılmıştır. Toplanan veri kümesindeki veriler ön işlemde geçirilmiş ve eğitim ve test için %80-%20 kuralına göre ayrılmıştır. Daha sonra, şebekeden alınan ana sinyalle cihazlara özgü sınıflandırma gerçekleştirilmiştir.

KNN Algoritması

KNN (K-En Yakın Komşu) algoritması, ilk kez 1967 yılında önerilen bir sınıflandırma ve regresyon yöntemidir. Bu yöntem, eğitim verilerinin analiz aşamasında kullanıldığı için pasif öğrenme yöntemi olarak kabul edilir. Temelde, KNN algoritması veriye özgü en yakın noktaları bulma üzerine

kurulmuştur. Bu algoritmada K değeri, bilinmeyen bir noktanın veri setindeki en yakın noktaları seçmek için kullanılır. K değeri değiştirilerek algoritmanın performansı ölçülebilir, en iyi sonuç elde edilen K değeriyle işlemler gerçekleştirilir. Bu ölçüm eşitlikleri Tablo 3'te gösterilmektedir.

Tablo 3. Mesafe ölçüm eşitlikleri (Distance measurement equations)

Mesafe Ölçüm Adı	Matematiksel Eşitliği
Öklid	$\sqrt{\sum_{i=1}^k (X_i - Y_i)^2}$
Manhattan	$\sum_{i=1}^k X_i - Y_i $
Minkowski	$(\sum_{i=1}^k (X_i - Y_i ^a))^{1/a}$

Tablo 3'te verilen eşitlikler de X_i ve Y_i verilerin apsis ve ordinatlarını gösterirken k veri sayısını ve a ise parametre değerini simgelemektedir. KNN sınıflandırma yöntemleri, komşuluk seçiminde mesafe ölçümlerini kullanır. Genellikle üç farklı türde mesafe ölçümü kullanılır: Öklid, Manhattan ve Minkowski. Bu çalışmada, cihazlar ve aynı anda ölçülen ana şebeke aktif güç verisi veri seti olarak kullanılmıştır. Aktif güç verisi ile her cihaz arasında bir vektör oluşturulmuş ve bu vektörlere Manhattan mesafe ölçümü kullanılarak ağırlık değerleri atanmıştır. Ağırlık değerleri arasında karşılaştırma yapılarak KNN sınıflandırması gerçekleştirilmiştir.

Rastgele Orman Algoritması

Rastgele orman algoritması, ilk olarak 2001 yılında önerilen ve makine öğrenmesi tabanlı bir sınıflandırma ve regresyon yöntemi olarak geliştirilen bir algoritmadır. Algoritmada, karar ağaçlarının bir araya getirilerek oluşturduğu sınıflandırma yaklaşımı olarak kullanılmaktadır. Rastgele orman algoritması, yüksek doğruluk payıyla sonuçlar üretme potansiyeline sahiptir. Bu algoritmanın özelliği, kullanılan her bir karar ağacının rastgele alt kümelerden oluşmasıdır. Her karar ağacı, bağımsız olarak çalışarak veri setinin farklı özniteliklerini kullanır ve tahminler yapar. Ardından bu tahminler bir araya getirilerek final sonuç oluşturulur. Rastgele orman algoritması, veri setinin büyüklüğüne ve seçilen karar ağacı sayısına


bağlı olarak hızlı ve tutarlı sonuçlar üretebilir. Bu çalışmada, rastgele orman algoritması kullanarak toplanan veri seti üzerinde uygulama yapılmıştır. Algoritmanın performansı, veri setindeki özneliklerin sınıflandırılması ve tahminlerin doğruluğu üzerinden değerlendirilmiştir. Bu çalışma, rastgele orman algoritmasının etkili bir sınıflandırma yöntemi olduğunu göstermektedir.

Hibrit Algoritma

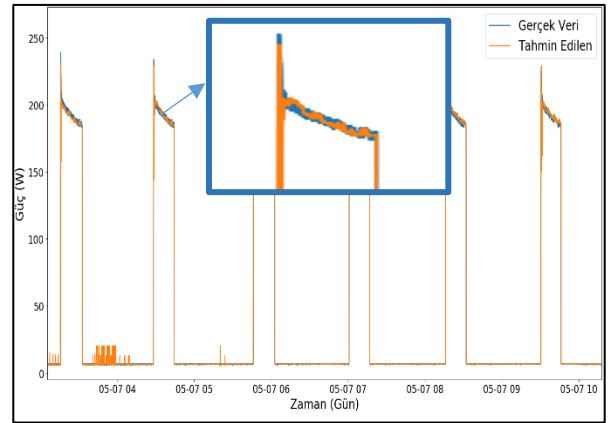
Karşılaştırmalı analizlerden elde edilen bulgularla, rastgele orman algoritmasının çalışılan diğer algoritmalara kıyasla daha yüksek f-puanı ve doğruluk elde ettiği gözlemlenmiştir. Dolayısıyla, toplanan cihaz verileriyle rastgele orman algoritmasıyla değerlendirilmektedir. Veriler, daha önce SVM algoritmasıyla da test edilmiş ve sonuçlar elde edilmiştir. Bu iki algoritmanın birlikte kullanılmasıyla yeni bir hibrit algoritma önerisi sunulmaktadır. Gerçekleştirilen algoritma sayesinde ana şebeke aktif güç sinyalinden cihaz sinyali tespit edilebilmektedir. Bu çalışma, cihazların tespit edilmesi ve sınıflandırılması konusunda etkili bir yöntem sunmaktadır. Hibrit algoritma, güç sistemleri ve enerji verimliliği alanında yeni bir yaklaşım sunarak, kullanışlı bir araç olabilir. Elde edilen sonuçlar, algoritmanın güvenilirlik ve performansının yanı sıra, enerji yönetimi ve otomasyon sistemlerinde de potansiyel uygulamalarının olabileceğini göstermektedir.

3. BULGULAR VE TARTIŞMA (RESULTS AND DISCUSSION)

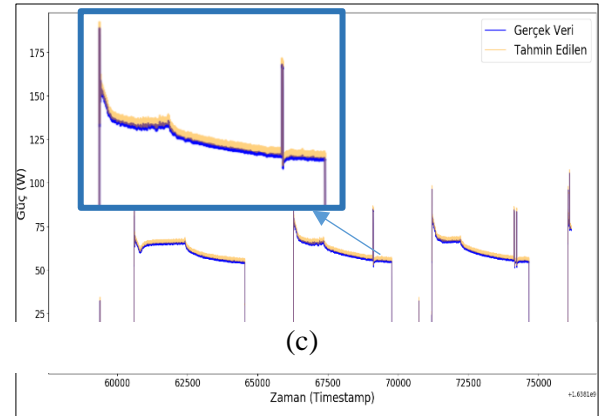
Gerçekleştirilen bu çalışmada, MYİ yönteminin uygulanan birkaç aşamasına odaklanılmıştır. Çalışmanın ilk aşamasında, verilerin lokal ortamda toplanması gerçekleştirilmiştir. Bu aşamada, kontrol kartlarının entegrasyonu ile birlikte otomatik senaryoların gerçekleştirilmesi sağlanmıştır. Olay tespiti, özellik çıkarma ve yük belirleme aşamalarında ise çeşitli yöntemler deneyimlenmiştir. Özellik çıkarma işlemi SVM yöntemiyle gerçekleştirilirken, yük belirleme aşamasında KNN, karar ağacı ve rastgele orman algoritmaları kullanılmıştır. Olay tespiti ise güç değişimi izlenerek tepki anları belirlenmiştir. Algoritmaların toplanan veri seti üzerinde çalıştırılması sonucunda elde edilen buzdolabı verisinin anlık grafikleri Şekil 9'da sunulmaktadır.



(a)



(b)



(c)

Şekil 9. (a) Karar ağaçları gerçek ve tahmin edilen buzdolabı veri grafiği, (b) KNN gerçek ve tahmin edilen buzdolabı veri grafiği, (c) Hibrit algoritma gerçek ve tahmin edilen buzdolabı veri grafiği ((a) Decision trees real and predicted refrigerator data graph, (b) KNN real and predicted refrigerator data graph, (c) Hybrid algorithm real and predicted refrigerator data graph)

Algoritmaların veri setlerine göre değerlendirme sonuçları ise Tablo 4 ve Tablo 5'te gösterilmektedir.

Tablo 2. Veri seti ile algoritmaların değerlendirilme sonuçları (Results of the evaluation of the algorithms with the data set)

Algoritmalar	Cihaz Tipi	Doğruluk	F-Puan
Karar Ağacı	Buzdolabı	0.86	0.85
	Çamaşır Makinesi	0.88	0.87
	Bulaşık Makinesi	0.52	0.53
	Saç Kurutma Makinesi	0.81	0.84
KNN	Buzdolabı	0.88	0.86
	Çamaşır Makinesi	0.89	0.87
	Bulaşık Makinesi	0.51	0.83
	Saç Kurutma Makinesi	0.85	0.86
Rastgele Orman	Buzdolabı	0.91	0.94
	Çamaşır Makinesi	0.94	0.96
	Bulaşık Makinesi	0.60	0.62
	Saç Kurutma Makinesi	0.91	0.94

Tablo 3. Veri seti ile SVM değerlendirilme sonuçları (SVM evaluation results with data set)

Algoritma	Cihaz Tipi	Doğruluk	F-Puanı
SVM	Buzdolabı	0.67	0.47
	Bulaşık Makinesi	0.75	0.84
	Çamaşır Makinesi	0.81	0.85
	Saç Kurutma Makinesi	0.94	0.83

Tablo 4 ve Tablo 5 verileri temel alınarak yapılan doğruluk ve F puanı analizleri sonuçlarına göre, KNN ve karar ağacı algoritmalarının rastgele orman makine öğrenimi algoritmasına kıyasla daha düşük doğruluk ve kesinlik sonuçları üretmiş görünmektedir. Bu bulgular, bulaşık makinesi özelinde bu sınıflandırma algoritmalarının doğru bir çıktı sağlama konusunda etkin olmamış olduğunu göstermektedir. Özellik çıkarma aşamasında, kullanılan SVM algoritmasının farklı çözünürlük seviyelerinde performansının değiştiği tespit

edilmektedir. En iyi sınıflandırma sonuçlarının 16 x 16 çözünürlüğe sahip veri setleriyle elde edildiği belirlenmektedir. Bununla birlikte, buzdolabı gibi cihazların bu yöntemle doğru bir şekilde kategorize edilemeyeceği ortaya konulmuştur. SVM sınıflandırma algoritması ve rastgele orman algoritması kullanılarak Tablo 6'da sunulmuştur.

Tablo 4. Veri seti ile SVM-Rastgele Orman değerlendirilme sonuçları (SVM-Random Forest evaluation results with data set)

Algoritma	Cihaz Tipi	Doğruluk	F-Puanı
Rastgele Orman + SVM	Buzdolabı	0.94	0.96
	Bulaşık Makinesi	0.89	0.96
	Çamaşır Makinesi	0.98	0.95
	Saç Kurutma Makinesi	0.93	0.94
	Saç Kurutma Makinesi	0.93	0.94

Tablo 6'daki verilerin analizi sonucunda, algoritmaların yüksek değerlere sahip olan özelliklerinin kullanılmasıyla cihazların yüksek doğruluk ve F puanına ulaştığı görülmektedir. Tablo 6'da verilen değerler [34] makalesi ile karşılaştırıldığında buzdolabı, bulaşık ve saç kurutma makinesinde F-puanı açısından geliştirildiği görülmektedir. Ayrıca çamaşır makinesi karşılaştırıldığında, doğruluk olarak bu çalışmanın daha iyi sonuç verdiği belirlenmektedir. Çalışmalarda direkt olarak aynı cihazlar kullanılsa da yük özellikleri benzer oldukları için karşılaştırma yapılabilmektedir. [34] çalışmada verilen grafikler ile bu çalışmanın grafikleri karşılaştırılması sonucunda iyileştirmenin sonucu gözlemlenebilmektedir. Naderian'ın yaptığı çalışmanın sonuçları Tablo 7'de gösterilmektedir.

Tablo 5. [34] Çalışmasının sonuçları ([34] Results of the study)

Algoritma	Cihaz Tipi	Doğruluk	F-Puanı
Hibrit Algoritma	Buzdolabı	0.94	0.90
	Bulaşık Makinesi	0.95	0.96
	Çamaşır Makinesi	0.97	0.95
	Su Isıtma Cihazı	0.93	0.76

4. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)

Yük belirleme sürecinin etkinliğini artırmak için farklı algoritmaların birleşik kullanımı, literatürde önemli bir konu olarak öne çıkmaktadır. Elde edilen sonuçlar, çeşitli veri kümelerinin analizi sonucunda, algoritmaların kendi içindeki güçlü yönlerinin birleştirilmesiyle daha yüksek doğruluk ve F puanı değerlerine ulaşıldığını göstermektedir. Özellikle hibrit algoritmanın uygulanmasıyla, bu yaklaşımın daha yüksek performansı beraberinde getirdiği gözlemlenmiştir. Bununla birlikte, bu alanda daha fazla gelişmeye yönelik fırsatlar bulunmaktadır. Çalışmanın gelecekteki potansiyeli, mevcut algoritmaların yanı sıra yeni veri toplama yöntemleri ve kontrollü kartlar kullanılarak daha kesin sonuçların elde edilebileceğini göstermektedir. Özellikle, ekonomik veri toplama kartlarının kullanımı ve geliştirilmiş sınıflandırma algoritmalarının entegrasyonu, bu alandaki araştırmaların yeni bir aşamaya taşınabileceğini işaret etmektedir. Bu şekilde, enerji verimliliği, cihazların kullanım ömrü tahmini gibi alanlarda daha kesin sonuçlar ve daha etkili yaklaşımlar elde edilebilecektir. Elde edilen sonuçlar, bu çalışmanın temel amacının ötesine geçerek, gelecekteki araştırmalar için bir temel oluşturmaktadır. Ancak, işlem sürelerinin daha da kısaltılması ve algoritmaların daha büyük veri kümeleri üzerinde test edilmesi, bu alandaki çalışmaların daha da gelişmesine katkı sağlayacaktır. Bu bağlamda, daha yüksek işlemci kapasitelerine sahip bilgisayarlar kullanılarak daha hızlı ve verimli sonuçlar elde edilmesi öngörülmektedir.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Çalışmayı gerçekleştirirken 07/2020-15 proje numarası ile maddi destek sağlayan Gazi Üniversitesi Bilimsel Araştırma Projeleri'ne teşekkür ederim.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The authors of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

AUTHORS' CONTRIBUTIONS (YAZARLARIN KATKILARI)

Fethi Batıncan GÜRBÜZ: Deneyleri yapmış, sonuçlarını analiz etmiş ve maklenin yazım işlemini gerçekleştirmiştir.

He conducted the experiments, analyzed the results and performed the writing process.

Seyfettin VADİ: Deneyleri yapmış, sonuçlarını analiz etmiş ve maklenin yazım işlemini gerçekleştirmiştir.

He conducted the experiments, analyzed the results and performed the writing process.

Ramazan BAYINDIR: Deneyleri yapmış, sonuçlarını analiz etmiş ve maklenin yazım işlemini gerçekleştirmiştir.

He conducted the experiments, analyzed the results and performed the writing process.

CONFLICT OF INTEREST (ÇIKAR ÇATIŞMASI)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Shi, K., Chen, Y., Yu, B., Xu, T., Yang, C., Li, L., Huang, C., Chen, Z., Liu, R., and Wu, J. (2016). Detecting spatiotemporal dynamics of global electric power consumption using DMSP-OLS nighttime stable light data. *Applied Energy*, 184, 450–463.
- [2] Liu, H., Wu, H., and Yu, C. (2019). A hybrid model for appliance classification based on time series features. *Energy and Buildings*, 196, 112–123.
- [3] Hart, G. W. (1992). Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 80(12), 1870–1891.
- [4] Gillis, J. M., Alshareef, S. M., & Morsi, W. G. (2016). Nonintrusive load monitoring using wavelet design and machine learning. *IEEE Transactions on Smart Grid*, 7(1), 320–328.
- [5] J. Wang, C. Pang, X. Zeng and Y. Chen, "Non-Intrusive Load Monitoring Based on Residual U-Net and Conditional Generation Adversarial Networks," in *IEEE Access*, vol. 11, pp. 77441–77451, 2023.
- [6] Du, Y., Du, L., Lu, B., Harley, R., and Habetler, T. (2010). A review of identification and monitoring methods for electric loads in commercial and residential buildings. *IEEE Energy Conversion Congress and Exposition*, 4527–4533, Atlanta, USA
- [7] A. F. M. Jaramillo et al., "Distributed Energy Resources Electric Profile Identification in Low

- Voltage Networks Using Supervised Machine Learning Techniques," in *IEEE Access*, vol. 11, pp. 19469-19486, 2023
- [8] M. Ghaffar, S. R. Sheikh, N. Naseer, S. A. Usama, B. Salah and S. A. K. Alkhatib, "Accuracy Improvement of Non-Intrusive Load Monitoring Using Voting-Based Consensus Clustering," in *IEEE Access*, vol. 11, pp. 53165-53175, 2023
- [9] Paradiso, F., Paganelli, F., Luchetta, A., Giuli, D., and Castrogiovanni, P. (2013). ANN-based appliance recognition from low-frequency energy monitoring data. *IEEE 14th International Symposium on "A World of Wireless, Mobile and Multimedia Networks"*, 1-6, Madrid, Spain.
- [10] Wichakool, W., Avestruz, A. T., Cox, R. W., and Leeb, S. B. (2009). Modeling and estimating current harmonics of variable electronic loads. *IEEE Transactions on power electronics*, 24(12), 2803-2811.
- [11] Dong, M., Meira, P. C., Xu, W., and Freitas, W. (2012). An event window-based load monitoring technique for smart meters. *IEEE transactions on smart grid*, 3(2), 787-796.
- [12] Roos, J. G., Lane, I. E., Botha, E. C., and Hancke, G. P. (1994). Using neural networks for non-intrusive monitoring of industrial electrical loads. *IEEE Instrumentation and Measurement Technology Conference*, 1115-1118, Hamamatsu, Japan.
- [13] Srinivasan, D., Ng, W. S., and Liew, A. C. (2006). Neural-network-based signature recognition for harmonic source identification. *IEEE Transactions on Power Delivery*, 21(1), 398-405.
- [14] Yang, H. T., Chang, H. H., and Lin, C. L. (2007). Design a neural network for features selection in non-intrusive monitoring of industrial electrical loads. *11th International Conference on Computer Supported Cooperative Work in Design*, 1022-1027, Melbourne, Australia.
- [15] Makonin, S. W. (2014). Real-time embedded low frequency load disaggregation, (Doctoral Dissertation, Simon Fraser University, 2014), *Dissertation Abstracts International*, 40-55.
- [16] He, D. (2016). An advanced non-intrusive load monitoring technique and its application in smart grid building energy management systems, (Doctoral Dissertation, Georgia Institute of Technology University, 2016), *Dissertation Abstracts International*, 32-47.
- [17] Basu, K., Hably, A., Debusschere, V., Bacha, S., Driven, G. J., and Ovalle, A. (2016). A comparative study of low sampling non intrusive load disaggregation. *IECON 2016-42nd Annual Conference of the IEEE Industrial Electronics Society*, 5137-5142, Florence, Italy.
- [18] Larcher, D., and Tarascon, J. M. (2015). Towards greener and more sustainable batteries for electrical energy storage. *Nature Chemistry*, 7(1), 19-29.
- [19] Kelly, J., and Knottenbelt, W. (2015). The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific Data*, 2(1), 1-14.
- [20] Yang, C. C., Soh, C. S., and Yap, V. V. (2014). Comparative study of event detection methods for non-intrusive appliance load monitoring. *Energy Procedia*, 61, 1840-1843.
- [21] Leeb, S. B., Shaw, S. R., and Kirtley, J. L. (1995). Transient event detection in spectral envelope estimates for nonintrusive load monitoring. *IEEE Transactions on Power Delivery*, 10(3), 1200-1210.
- [22] Afzalan, M., Jazizadeh, F., and Wang, J. (2019). Self-configuring event detection in electricity monitoring for human-building interaction. *Energy and Buildings*, 187, 95-109.
- [23] Zoha, A., Gluhak, A., Imran, M. A., and Rajasegarar, S. (2012). Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. *Sensors*, 12(12), 16838-16866.
- [24] Norford, L. K., & Leeb, S. B. (1996). Non-intrusive electrical load monitoring in commercial buildings based on steady-state and transient load-detection algorithms. *Energy and Buildings*, 24(1), 51-64.
- [25] Tabatabaei, S. M., Dick, S., and Xu, W. (2016). Toward non-intrusive load monitoring via multi-label classification. *IEEE Transactions on Smart Grid*, 8(1), 26-40.
- [26] Gray, M., and Morsi, W. G. (2015). Application of wavelet-based classification in non-intrusive load monitoring. *IEEE 28th Canadian conference on electrical and computer engineering (CCECE)*, 41-45, Halifax, Canada.
- [27] He, K., Stankovic, L., Liao, J., and Stankovic, V. (2018). Non-intrusive load disaggregation using graph signal processing. *IEEE Transactions on Smart Grid*, 9(3), 1739-1747.
- [28] De Baets, L., Ruysinck, J., Develder, C., Dhaene, T., and Deschrijver, D. (2018). Appliance classification using VI trajectories and convolutional neural networks. *Energy and Buildings*, 158, 32-36.
- [29] Zheng, Z., Chen, H., and Luo, X. (2018). A supervised event-based non-intrusive load

- monitoring for non-linear appliances. *Sustainability*, 10(4), 1001.
- [30] Mathis, M., Rumsch, A., Kistler, R., Andrushevich, A., and Klapproth, A. (2014). Improving the recognition performance of NIALM algorithms through technical labeling. 12th IEEE international conference on embedded and ubiquitous computing, 227-233, Milan, Italy.
- [31] Shen, D., and Ip, H. H. (1999). Discriminative wavelet shape descriptors for recognition of 2-D patterns. *Pattern Recognition*, 32(2), 151-165.
- [32] Luo, S., Hu, Q., He, X., Li, J., Jin, J. S., and Park, M. (2009). Automatic liver parenchyma segmentation from abdominal CT images using support vector machines. *ICME International Conference on Complex Medical Engineering*, 1-5, Tempe, USA.
- [33] Debnath, R., and Takahashi, H. (2004). Kernel selection for the support vector machine. *IEICE Transactions on Information and Systems*, 87(12), 2903-2904.
- [34] S. Naderian, "A Novel Hybrid Deep Learning Approach for Non-Intrusive Load Monitoring of Residential Appliance Based on Long Short Term Memory and Convolutional Neural Networks," *arXiv preprint arXiv:2104.07809*, 2021.