

EVLERDE TÜKETİM AYRIŞTIRMASI PROBLEMİNİN İNCELENMESİ

Emre ERYİĞİT^A, Rabia Şeyma YILMAZ^A, Şafak BAYKAL^A, Erman TERCİYANLI^A

^AT4E Enerji A.Ş., Ankara

ÖZET

Enerji ayrıştırması, ev kullanıcılarının enerji tüketimlerini ev içerisindeki temel yükler bazında ayrıştırılmasını sağlayan bir yöntemdir. Bu bildiride ilk olarak, literatürde Nonintrusive Load Monitoring olarak da geçen enerji ayrıştırması ve literatürde geçen algoritmalar ile ilgili genel bilgi verilmiştir. Saklı Markov Modellerinin yoğunlukla kullanıldığı bu problemin çözümü için Derin Öğrenme (DL) yöntemleri de kullanılmaya başlanmıştır. Bu bildiride, Konvolüsyonel Sinir Ağı (CNN) ve Uzun Kısa Süreli Bellek (LSTM) modellerinin soruna nasıl uygulandığı anlatılmaktadır. Model performansı, eğitim verilerine dahil edilmemiş farklı bir ev verileri kullanılarak ölçülmüştür. Performans ölçütü olarak ev içerisindeki cihazların açık kapalı durumu için F-1 skoru ve tüketim tahmini için ortalama mutlak hata kullanılmıştır. Performansın, mevcut Gizli Markov Modellerini ve literatürdeki bazı DL modellerini geride bıraktığı tespit edilmiştir.

Anahtar Kelimeler: Enerji Ayrıştırması, Makine Öğrenmesi, Nonintrusive Load Monitoring, Derin Öğrenme

1. GİRİŞ

Dünya genelindeki enerji talebi hızla artarken; elektrik enerjisi aralarında en hızlı artan enerji kaynağıdır [1]. International Energy Agency (IEA)'nin 2018 yılındaki raporuna göre, elektrik enerjisi talebi 2040 yılına gelindiğinde günümüzdeki talebin 2 katına çıkacaktır. Dünyadaki ülkelerin karşılaşmış olduğu enerji ile ilgili problemler; fosil yakıt rezervlerinin azalması, sürdürülebilir enerji tedarikinin sağlanması ve küresel ısınmanın etkilerinin artmasıdır [2]. Elektrik enerjisinin kullanımının, diğer enerji kaynaklarının kullanımını 25 yılda katlayacağını belirten IEA, elektrik üzerine ayrıca odaklanmaktadır [1]. International Electrotechnical Commission (IEC) birinci enerji kaynağı olan elektriğin, akıllı ve ekonomik kullanımının, enerji problemlerini çözmek

için en önemli faktör olduğunu belirtmekte ve bunun da yenilenebilir enerji kaynaklarından enerji üretiminin yanı sıra verimli enerji kullanımı ile de olacağını söylemektedir [3]. Ayrıca IEC, enerji verimliliği konusunun sadece daha az elektrik kullanımı ile değil; aynı zamanda sistemlerin ve sosyal davranışların değişmesi ile de bağlantılı olduğunu altını çizmiştir. Pozitif davranış değişiminin ev sakinlerine evdeki cihazların ne kadar enerji kullandığını gösteren bildirimler sağlanarak başarılabileceği belirtilmektedir [4]. Kim ve diğerleri [5], cihaz bazında kullanım bilgisine dayanan enerji tüketimi stratejisi uygulayarak enerji korunumunun %9 ile %20 aralığında elde edilebileceğini göstermiştir. Enerji korunumu sağlanmaya başlanması ile düşen aylık elektrik faturalarının yanında, cihaz kullanım kayıtları cihazların durumlarını kontrol

etme ve hatalı çalışan cihazları tespit etme noktasında faydalıdır [6].

Bu bildiriye, ilk olarak farklı modellere ve bunların enerji ayrıştırma problemine uygulanabilirlikleri anlatılmaktadır. İlk çalışmada, CNN kullanılmaktadır. Daha sonrasında, veri kümesinin zaman serisi doğasına odaklanılarak LSTM modeli anlatılmaktadır. Modeller, UK Domestic Appliance-Level Electricity or UK-DALE [14] adlı halka açık veri seti kullanarak değerlendirilmektedir.

2. İLGİLİ ÇALIŞMALAR

Enerji korunumu ve enerji verimliliği konusunda yardımcı olan cihaz bazındaki tüketim verisini elde etme işlemi literatürde Appliance Load Monitoring (ALM) olarak geçmektedir. ALM teknikleri, kullanılan sensör ve akıllı sayaçlar bazında iki ana kategoriye ayrılmaktadır: Intrusive Load Monitoring (ILM) ve Nonintrusive Load Monitoring (NILM). Daha eski bir yöntem olan ILM tekniklerinde her bir cihazda tüketiminin izlenip kaydedilebildiği sensörler bulunmaktadır. Bu yöntemin çok sayıda sensör ve akıllı sayaç gerektirmesi pahalı ve elverişsiz bir yaklaşım olduğunu göstermektedir [7].

Cihaz bazındaki yük izleme tekniklerinden olan NILM, literatürde enerji ayrıştırması (energy disaggregation) olarak da geçmektedir [8]. NILM, ILM ile kıyaslandığında veri toplama anlamında daha basit donanım ancak veri işleme ve analiz etme anlamında daha karmaşık yazılım gerektirmektedir [9]. NILM metodolojisinde, her bir cihazın tüketim eğrileri belirlenirken eve ait toplam

elektrik yükü ölçülür ve sinyaller analiz edilir. Farklı çözüm yaklaşımlarına sahip NILM metotlarında veri toplama, veriden cihazlara ait ölçülebilen özelliklere, başka bir deyişle imzalara ulaşma ve cihazları sınıflandırma olarak üç ana adım bulunmaktadır. Veri toplama işlemi evin girişinde bulunan tek bir sensör ile yapılmaktadır. Cihazlara ait imzaları evin toplam tüketiminden tespit etmek için matematiksel bir algoritma kullanıldığı için NILM literatürde makine öğrenmesi problemi olarak geçmektedir [7]. Makine öğrenmesi algoritmalarında öğrenme ve test etme aşamaları bulunmaktadır. NILM algoritmaları öğrenme aşamasına göre denetlenen (supervised) ve denetlenmeyen (unsupervised) olarak iki ana sınıfa ayrılmaktadır. Denetlenen algoritmalara ait veri setleri cihazların ayrı ayrı tüketim verilerini içerirken, denetlenmeyen algoritmalar ne öncü bilgi ne de cihaz verisi kullanmaktadır.

Literatürdeki ilk NILM metodu Hart tarafından 1985 yılında geliştirilmiştir ve MIT(Massachusetts Institute of Technology) metodu olarak geçmektedir. [9] Bu metot, temelde 4 ana adımdan oluşan denetlenen bir algoritmadır. Birinci adım olarak geçen uç belirleme (edge detection) aşamasında kararlı haldeki güç seviyeleri belirlenir. Sadece kararlı hallere ait değerler Hart'ın yöntemi için gerekli olduğundan, çalışmasında kullandığı veri seti düşük frekansa (1 Hz veya daha düşük) sahiptir. Güç seviyelerine ait aktif ve reaktif güç değerleri iki boyutlu imza uzayına bir tür gruplama algoritması yardımıyla yerleştirilir. Üçüncü aşamada pozitif ve negatif yönde benzer değerlere sahip gruplar eşleştirilir. Anomali çözümü

olarak geçen son aşamada maksimum olabilirlik çıkarımı kullanılarak eşleştirilmemiş gruplar diğer gruplar ile ilişkilendirilir. Eşleştirilen gruplar sayısı tespit edilen cihaz sayısını vermektedir. Cihazların etiketleme işlemi el ile yapılmaktadır [10]. Bu yöntemin dezavantajı, düşük tüketimli ve sürekli değişken cihazları tespit edememesi ve sonlu durum makinelerine ait sonuçların yetersiz olmasıdır. Bu nedenle daha sonraki araştırmalarda, yüksek frekanslı veriler kullanılmaya ve imzalar el ile çıkarılmaya başlanmıştır; başka bir deyişle, araştırmacılar cihazların durum geçişlerine bakarak algoritmalarında kullanmaya başlamışlardır [12], [13]. Araştırmacılar özellikleri el ile çıkarmaya başladıktan sonra, bu işlemin algoritmada nasıl otomatik olarak yapılabileceğini araştırmışlardır. Bu nedenle, mevcut literatürdeki gelişmelerden örnekler kullanılıp enerji ayrıştırması problemine uyarlanmıştır. Görüntü sınıflandırma yönteminde 2012 yılına kadar el ile çıkarılan imzalar Krizhevsky ve diğerlerinin [14] ImageNet Large Scale Visual Recognition Challenge kapsamında geliştirdikleri algoritma ile otomatik hale dönüştürülmüştür. Bu sayede o zamana kadar ki en iyi hata oranı olan %26'yı %15'ten daha düşük hata oranlarına çekerek derin öğrenme alanında çok büyük bir gelişmeye imza atmışlardır [15]. Hatta geliştirilen derin öğrenme algoritması günümüzde insandan daha iyi performans göstermektedir. Bu da derin öğrenmenin ne kadar önemli ve etkili olduğuna işaret etmektedir. Özellik çıkarımının otomatik hale gelmesinden sonra, enerji ayrıştırma probleminde derin

sinir ağının kullanılması popüler hale gelmiştir. Elektrik enerjisi tüketim verileri zaman serileri olduğundan, Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN) kullanılarak problemi çözmek için farklı katman yapılı yaklaşımlar geliştirilmiş ve Mauch ve Yang [16] bu konuda derin sinir ağını kullanan ilk çalışmalardan birini literatüre katmıştır. Burada, cihazların bireysel tüketim gücünü elde etmek için iki katmanlı Uzun Kısa Süreli Bellek (LSTM) - RNN mimarisi kullanılmıştır. Daha sonraki bir çalışmada, Mauch ve Yang [17], iki aşamalı olaysız yük profillerinin çıkarılmasında ayırıcı ve üretken modellerin bir kombinasyonunu kullanmıştır. Benzer şekilde, He ve Chai [18] konvolüsyonel (convolutional) Gürültü Arındırma Otomatik Kodlayıcıları (Denoising Autoencoders-DAE) ve RNN'i ayrıştırma problemi üzerine uygulamışlardır. Kelly ve diğerleri [19] ise üç farklı mimariyi araştırmışlardır. İlk olarak, içlerinden biri konvolüsyonel katman olan altı katmanlı iki yönlü LSTM – RNN uygulamışlardır. Ayrıca teorik olarak konvolüsyonel katman eklemek için geçerli bir nokta bulunmadığını, ancak performansı arttırdığını belirtmişlerdir. Diğer bir model olarak, Gürültü Arındırma Otomatik Kodlayıcılarını (DAE) altı katmanlı olarak uygulamışlardır. Son olarak, üç skaler değer olan başlangıç zamanı, bitiş zamanı ve cihazın ortalama güç talebini tahmin etmek için derin sinir ağı kullanmışlardır.

Enerji ayrıştırması problemine denetlenen algoritmaların yanı sıra, denetlenmeyen algoritmalar da uygulanmaya başlanmıştır. Kolter ve diğerleri [23],

eklemeli faktöriyel saklı markov modelinin algoritmasını (FHMM) cihaz bazlı yük ayrıştırma problemine uygulayarak denetlenmeyen ilk modeli geliştirmiştir. Toplam tüketimdeki güç değerlerinden çıkarılan cihazlara ait imzaların en yakın k komşu veya spektral kümeleme yöntemleri ile cihaz bazlı geçiş matrislerinin oluşturulduğu anlatılmaktadır. Her bir cihaz için saklı markov modelin geliştirildiği ve bileşke fonksiyondaki çıktı değerlerinin birbirinden bağımsız olan cihazların saklı hallerinden oluştuğu anlatılmaktadır. Kolter, amaç fonksiyonuna bileşke fonksiyonların dışında ayrıştırılamayan cihazlar için ceza maliyeti ekleyerek hatayı enazlamayı amaçlamıştır. Ancak, makalede önerilen model cihaz etiketleme işleminin el ile yapılmasını gerektiğini söylemektedir.

Bu bildiride anlatılan metot performansının daha yüksek olması nedeniyle derin öğrenme temellidir.

3. ÖNERİLEN METOT

Giriş bölümünde daha önce de belirtildiği gibi, iki derin sinir ağı mimarisi, yani Konvolüsyonel Sinir Ağı ve Uzun-Kısa Dönemli Bellek Tekrarlayan Sinir Ağı kullanılmıştır. Bu bölümde modeller açıklanırken soruna nasıl yaklaşıldığı ve nasıl bir çözüm getirildiği anlatılmaktadır.

3.1. Konvolüsyonel Sinir Ağı

Enerji ayrıştırması problemi, iki ana parçaya bölünerek incelenmiştir. İlk parçada, cihazın çalışıp çalışmadığı tahmin edilirken, ikinci parçada o cihazın tüketimi tahmin edilmektedir. Bu iki parça için iki bağımsız model geliştirilmiştir.

İlerleyen bölümlerde, bu iki model ayrıntılı olarak incelenmektedir.

3.1.1. Açık/Kapalı Durumu

Bir cihazın açık olup olmadığı, çalışma zamanının yüzde 80'inden daha fazlası için tahmin edebilirse, cihazın tüketim değerleri tahmin edilebilir. Bu nedenle, cihazların açık/kapalı durumunu belirleyen etiketleme modeli, tüketim tahmini için oldukça iyi bir kontrol yöntemidir.

Model, dakikada 10 örnek yani 6 saniyelik zaman aralıklı veri ile çalışmaktadır. Model, şu farklı katmanlara sahiptir:

- ReLU aktivasyon fonksiyonlu dört CNN katmanı (her katmanda 2x2 filtre büyüklüğünde 32 filtre) ve “He - Xavier” başlatma [20].
- Her katmandan sonra bir toplu normalleştirme [21] katmanı.
- CNN katmanlarından sonra, biri ReLU aktivasyon fonksiyonlu, diğeri Softmax fonksiyonlu iki tam bağlı katman.

Kayıp fonksiyonu olarak kategorik-çapraz entropi kullanılmaktadır. Model eğitimindeki batch büyüklüğü 200 ve Adam Optimizer [22] ile öğrenme oranı $5e-4$ 'tür.

3.1.2. Tüketim Tahmini

Her bir cihazın tüketim değerlerini tahmin etmek için CNN modeli kullanılmaktadır. Bunun için aynı model mimarisini, sadece son katmanda softmax fonksiyonu ile kullanmak yerine ortalama kare hata kaybı kullanılmakta ve daha sonra kayıp fonksiyonu olarak kategorik-çapraz

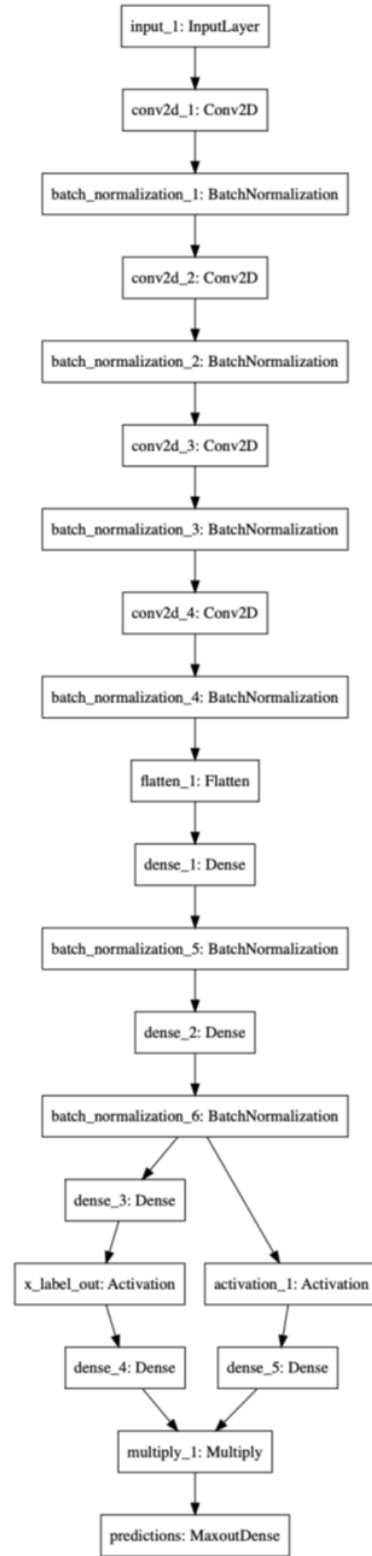
entropi kullanılmaktadır. Etiketleme modelinin sonuçlarının iyi olması nedeniyle, tüketim tahmin modelinin sonuçlarının da başarılı olması beklenmekte iken; öğrenme oranı, düzenleme oranı, farklı optimizeler, epoch sayısı ve window boyutu gibi hiper-parametre değişiklikleri yapılmasına rağmen modelden iyi sonuç alınamamıştır. Bu problemin çözülmesi için iki modelin bir araya getirilmesine karar verilmiş ve bu da üçüncü modeli oluşturmuştur.

3.1.3. Kombinasyon Modeli

Bu kombinasyon modelinde, etiketleme ve tüketim tahminini içerecek şekilde model mimarisi değiştirilmiştir. Model mimarisi Şekil 1'de bulunmaktadır. Modele ait katman detayları aşağıdaki gibidir:

- Filter boyutu 32 olan 4 konvolüsyonel katman, “He-Xavier” başlatma, düzenleyici olarak L2 kayıp fonksiyonu
- Her konvolüsyonel katmandan sonra Batch Normalleştirme
- Biri etiketleme biri tahmin için olan iki farklı çıktı katmanı

Böylece model hem etiketleme hem de tahmin için eğitilmiş olup, model 2'den çok daha iyi sonuç alınmıştır. Cihazların bazı tüketim değerlerinin altında tüketmediği bilgisine sahip olduğundan, modelde faydalı olan max-out [24] katmanı kullanılmıştır.



Şekil 1: Kombinasyon Modelinin Mimarisi

3.2. LSTM

Enerji ayrıştırması verilerinin zaman serisi olması nedeniyle, LSTM algoritması tüketim tahmini için seçilmiş ve aşağıdaki mimari ile uygulanmıştır.

- 500 saklı node'lu 4 LSTM katman [25] ve ReLU aktivasyonu
- 500 saklı node'lu 2 tam bağlı katman

Kayıp fonksiyonu olarak ortalama karesel hatanın kullanılması ve farklı hiper parametrelerin denenmesi (L2 düzenleme, farklı sayıda saklı node'lar vs.) yeterli sonuç vermemiştir. Bunun yanında eğitim süresinin çok yüksek olması hiper parametre ayarlaması için yapılan denemelere engel olmuştur.

4. DENEY

Bildirinin bu bölümünde ne tür deneyler yapıldığı, kullanılan veri setleri ve sonuçları ölçme veya değerlendirme yöntemleri yanında deney sonuçları ayrıntılı olarak anlatılmaktadır. Deneyler, 2007'den 2017'ye kadar 5 evin verilerini içeren halka açık bir veri seti olan UK-DALE ile yapılmıştır. Buzdolabı, çamaşır makinesi, bulaşık makinesi ve dizüstü bilgisayar, su ısıtıcısı gibi bazı küçük cihazlar da dahil olmak üzere 52 cihaza veriler bu veri setinde bulunmaktadır. Bu 52 cihaz için, her 6 saniyelik zaman aralıklı güç değerleri bulunmaktadır. Ancak, veri setindeki tüm evlerde aynı sayıda cihaz bulunmamaktadır. Örneğin, ev 1 tüm cihazlara sahipken, ev 2 sadece bir bölümüne sahiptir. Bir evi modeli eğitmek diğerini testte kullanmak için bu önemlidir. Bu nedenle, cihaz modelleri oluştururken evlerde ortak olan cihazlar

seçilmiştir. Bu yöntem literatürde bulunmakta birlikte Kelly ve diğ. al [19], üç evin verisini eğitim bir evin verisini test için kullanmıştır. Ev 1'in verisi tüm cihazlara sahip olduğu için eğitim evi olarak seçilmiştir. Böylece diğer evlere yeni bir cihaz eklendiğinde modelin bunu tespit etmesi kolay hale gelmiştir.

Eğitim ve test için 5 cihaz seçilmiştir. Bunlar çamaşır makinesi, bulaşık makinesi, buzdolabı, kombi ve kettledir. Her evde oldukları ve tüketim davranışları birbirinden farklı olduğu için bu cihazlar seçilmişlerdir. Örneğin, kombi ve buzdolabı sürekli güç tüketirken, çamaşır makinesi ve bulaşık makinesi sadece kullanıldıkları zaman güç tüketir. Bu cihazlar için uygulanabilir bir sonuç elde edilmesi, modelin her cihaza kolayca genellenebileceğini göstermektedir. Her cihaz için eğitilen beş ayrı modelde en iyi sonucu veren farklı hiper parametreler ayarlanmıştır.

Cihazlar için modeller geliştirildikten sonra, farklı evler için tüketim değerleri tahmin edilmiştir. Etiketleme için; F1 score, precision ve recall performans metrikleri kullanılırken, esas amaç olan tüketim eğrilerini belirlemek için kombinasyon modelinde ortalama mutlak hata (MAE) kullanılmıştır. MAE formülü aşağıda bulunmaktadır.

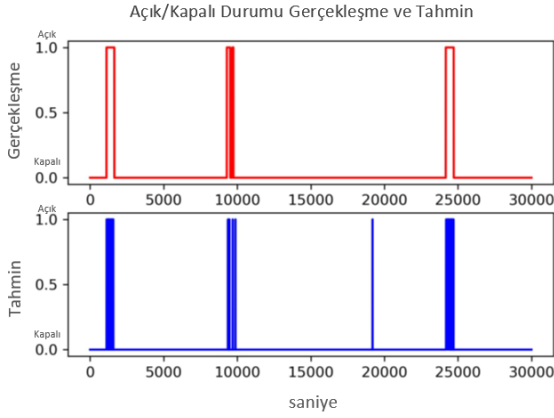
$$\frac{1}{N} \sum_{i=1}^N |y - x| \quad (1)$$

4.1. CNN Modeli Sonuçları

Model 1 ve 2'ye ait detaylı sonuçlar bu kısımda anlatılmaktadır.


Cihazın çalışıp çalışmadığını tahmin etmek için kullanılan model 1'in çamaşır

makinesi için vermiş olduğu tahmin değerleri Şekil 2'deki grafikte gösterilmektedir.



Şekil 2: Çamaşır Makinesi için Etiketleme Modeli

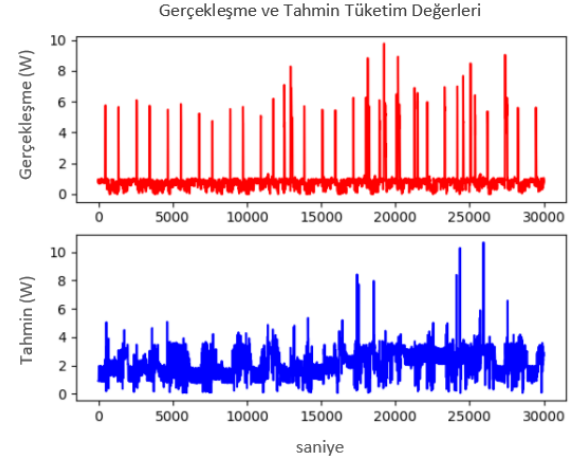
Cihazın açık/kapalı etiketini gösteren model 1'in performansı çamaşır makinesinde %95 hassasiyet ile çalışarak modelin başarısını göstermektedir. Çamaşır makinesinin tüketim eğrisini tahmin etmeye çalışan Model 2'nin performansı Şekil 3'teki grafikte bulunmaktadır.



Şekil 3: Çamaşır Makinesi için Tüketim Tahmini


Modelin kayıp değeri 583.6054, ortalama mutlak hata ise 1.7222 çıkmıştır. Sonuçlar bazen açık bazen kapalı çalışan cihazlar için oldukça başarılı çıksa da her zaman

açık cihazlarda başarı oranı daha düşüktür. Kombi ve buzdolabı için alınan sonuçlar aşağıda gösterilmiştir.



Şekil 4: Kombi için Tahmin Sonuçları

Modelin daha doğru olması için ekstra işlemler yapılmıştır. Bulaşık makinesi gibi cihazlarda, çekilen güç kullanımının pik güç kullanımının %80'inden fazla değişmemesi gerektiği varsayılmıştır. (Çünkü bir bulaşık makinesinin bir çalışma döngüsünde diğerinden daha fazla enerji kullanabileceğini düşünmek anlamsızdır.) Eşik değeri eklenerek elde edilen sonuçlar aşağıdaki grafikte gösterilmektedir.



Şekil 5: Bulaşık Makinesi için Tüketim Tahmini

5. SONUÇ

Bu proje için sıfırdan bir model oluşturmak yararlı olmuştur. Çünkü burada kullanılan algoritma yapıları biliniyor olsa da veri temizleme ve işleme aşamaları, veri setinin modellere uygun olarak hazırlanması ve her cihaz için parametrelerin ayarlanması son derece zordur. Ayrıca, LSTM'in CNN'den daha iyi çalışacağı düşünülürken, LSTM mimarisi ile iyi sonuç alınamamıştır. Bunun yanında, literatürdeki LSTM yaklaşımı enerji ayrıştırma problemi için oluşturulduğunda bazı bellek ve işlem sınırlamaları ile karşılaşmıştır. İleri çalışmalarda, bu problemin LSTM ile çözülmesi düşünülmektedir.

Yapılan deneylerden, şebekeden çekilen enerji değerleri ile cihaz bazlı enerji ayrıştırması probleminin, modern bir evdeki farklı özelliklere sahip çok sayıda elektrikli cihaz için zorlayacağı bir problem olduğu söylenebilir. İleride güç değerlerinin yanı sıra, diğer güç parametrelerini de modele ekleyerek sonuç almak istenmektedir. “Dikkat modellemesi” gibi zaman serisi tahmini alanındaki diğer çalışmalar da ileride denenmesi düşünülmektedir [26]. Ayrıca, zaman serilerinde Fourier spektrogramını almak gibi, özellik çıkarımında çalışmalar bulunmaktadır. Son olarak, rastgele orman veya gradient güçlendirilmiş ağaçlar gibi klasik modelleme teknikleriyle birlikte yoğun katmanlı CNN ve LSTM'ler ile hibrit yaklaşımlı modellerin oluşturulması da düşünülmektedir. Kombi ve buzdolabı gibi her zaman açık cihazlar için performans iyileştirilmesi de gelecekteki çalışmalarda yapılacaktır.

KAYNAKLAR

- [1] International Energy Agency, World Energy Outlook 2018, White Paper, IEA, 2015.
- [2] David J C MacKay. Sustainable Energy - without the hot air. UIT Cambridge, UK, 2008.
- [3] International Electrotechnical Commission, Report to WTO TBT Committee, White Paper, IEC, 2017.
- [4] Tsuyoshi Ueno, Ryo Inada, Osamu Saeki, and Kiichiro Tsuji. Effectiveness of an energy consumption information system for residential buildings. Applied Energy, 83(8):868-883, 2006.
- [5] H. Kim, M. Marwah, M. Arlitt, G. Lyon, J. Han, Unsupervised disaggregation of low frequency power measurements, Proceedings of the 11th SIAM International Conference on Data Mining, SDM 2011, 2011, pp. 747-758.
- [6] T. Schwartz, S. Deneff, G. Stevens, L. Ramirez, V. Wulf, Cultivating energy literacy: results from a longitudinal living lab study of a home energy management system, Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, ACM, Paris, 2013.
- [7] B. Najafi, S. Moaveninejad, F. Rinaldi, Chapter 17 - Data Analytics for Energy Disaggregation: Methods and Applications, Big Data Application in Power Systems, 2018, pp. 377-408.
- [8] Hart, G.W., Kern, E. C. & Schweppe, F. C. 1989. Non-intrusive appliance monitor apparatus. Google Patents.
- [9] G.W. Hart, Nonintrusive appliance load monitoring, Proc. IEEE 80 (1992) 1870-1891.
- [10] G.W. Hart, Prototype nonintrusive appliance load monitor, MIT Energy Laboratory and Electric Power Research Institute, 1985.
- [11] J. Kelly and W. Knottenbelt. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. Scientific Data, 2(150007), 2015.
- [12] N. Amirach, B. Xerri, B. Borloz, and C. Jauffret. A new approach for event detection and

feature extraction for nilm. Electronics, Circuits and Systems (ICECS) IEEE International Conference, 2014.

[13] S. B. Leeb, S. R. Shaw, and J. L. Kirtley Jr. Transient event detection in spectral envelope estimates

for nonintrusive load monitoring.

[14] D. G. Lowe. Object recognition from local scale-invariant features. Computer vision, 1999. The proceedings of the seventh IEEE international conference, 2(10), 1999.

[15] Alex Krizhevsky and Sutskever, Ilya and Hinton, Geoffrey E. Imagenet classification with deep convolutional neural networks. pages 1097–1105, 2012.

[16] L. Mauch and B. Yang. A new approach for supervised power disaggregation by using a deep recurrent lstm network. In proceedings of the 3rd IEEE Global Conference on Signal and Information Processing (GlobalSIP), pages 63 - 67, 2015.

[17] L. Mauch and B. Yang. A novel dnn-hmm-based approach for extracting single loads from aggregate power signals. In proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), page 2384-2388, 2016.

[18] W. He and Y. Chai. An empirical study on energy disaggregation via deep learning. The 2016 2nd International Conference on Artificial Intelligence and Industrial Engineering (AIIE2016), Beijing, ChinaNov., 2016.

[19] J. Kelly and W. Knottenbelt. Neural nilm: Deep neural networks applied to energy disaggregation. arXiv, 2015.

[20] K. He, X. Zhang, S. Ren, and J. Sun. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), ICCV '15, pages 1026–1034, Washington, DC, USA, 2015. IEEE Computer Society.

[21] S. Ioffe and C. Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In Proceedings of the 32Nd International Conference on International Conference on Machine Learning- Volume 37, ICML'15, pages 448–456. JMLR.org, 2015.

[22] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. CoRR, abs/1412.6980, 2014.

[23] J. Z. Kolter and T. Jaakkola. Approximate Inference in Additive Factorial HMMs with Application to Energy Disaggregation. In Proceedings of the 15th International Conference on Artificial Intelligence and Statistics, pages 1472{1482, La Palma, Canary Islands, 2012.

[24] I. J. Goodfellow, D. Warde-Farley, M. Mirza, A. Courville, and Y. Bengio. Maxout networks. In Proceedings of the 30th International Conference on International Conference on Machine Learning- Volume 28, ICML'13, pages III– 1319–III–1327. JMLR.org, 2013.

[25] S. Hochreiter and J. Schmidhuber. Long short-term memory. Neural Comput., 9(8):1735–1780, Nov. 1997.

[26] D. Bahdanau, K. Cho, and Y. Bengio. Neural machine translation by jointly learning to align and translate. CoRR, abs/1409.0473, 2014.