



Personalization of Energy Consumption in Smart Homes using Machine Learning Technique

Fatemeh Taghvai^{1*}, Ramin Safa², Homayon Beheshti³

^{1*} Master Student in Computer Engineering, Department of Computer Engineering, Ayandegan Institute of Higher Education, Tonekabon, Iran.

fatemeh.taghvai2039@gmail.com

² Department of Computer Engineering, Ayandegan Institute of Higher Education, Tonekabon, Iran.
r.safa@outlook.com

³ Department of Computer Engineering, Ayandegan Institute of Higher Education, Tonekabon, Iran.
homayon.beheshti@gmail.com

Abstract

Since most of the energy consumption is related to buildings, energy management in smart homes is a major challenge. Personalized recommender systems are a solution to optimize energy consumption by analyzing building energy consumption behaviors. The NILM energy disaggregation technique has been considered in recent years. However, the combination of recommender systems and NILM has received less attention. This paper proposes a personalized NILM-based recommender system that has three main phases: DAE-based NILM, TF-IDF-based text classification, and personalized recommendation. Because of the noise in the energy data, the DAE-based NILM helps detect these noises from the signals. Households' requirements and interests are identified at this stage. In the second phase, the TF-IDF technique is used to extract meaningful keywords from the advertised optimal tags and assign them a label. Finally, in the third phase, the cosine similarity technique is used to provide some recommendations. This step generates a suggestion for each device that is on the requirement list. The proposed approach was tested using the REDD dataset. The results showed that the accuracy of the recommendation system was about 60%.

Keywords: Smart homes, Recommender systems, NILM, Deep learning, TF-IDF.



شخصی سازی مصرف انرژی در خانه های هوشمند با استفاده از تکنیک های یادگیری ماشین

فاطمه تقوائی^{۱*}، رامین صفا^۲، همایون بهشتی^۳

^{۱*} دانشجوی کارشناسی ارشد مهندسی کامپیوتر، گروه مهندسی کامپیوتر، موسسه آموزش عالی آیندگان، تنکابن، ایران.

fatemeh.taghvai2039@gmail.com

^۲ گروه مهندسی کامپیوتر، موسسه آموزش عالی آیندگان، تنکابن، ایران.

r.safa@outlook.com

^۳ گروه مهندسی کامپیوتر، موسسه آموزش عالی آیندگان، تنکابن، ایران.

homayon.beheshti@gmail.com

چکیده

به دلیل مصرف انرژی بالا ساختمان ها، مدیریت انرژی در خانه های هوشمند یک چالش اساسی است. سیستم های توصیه گر شخصی سازی شده یک راه حل برای بهینه سازی مصرف انرژی از طریق تحلیل رفتارهای مصرف انرژی ساختمان است. تکنیک تجزیه انرژی NILM یک راه حل بهینه است. با این حال، ترکیب سیستم های پیشنهاددهنده و NILM توجه کمتری را به خود جلب کرده است. این مقاله یک سیستم توصیه گر شخصی سازی شده مبتنی بر NILM پیشنهاد می کند که دارای سه فاز اصلی است: NILM مبتنی بر DAE، دسته بندی متون مبتنی بر TF-IDF و پیشنهاد شخصی سازی شده. به دلیل نويز در داده ها، NILM مبتنی بر DAE کمک می کند تا نویزها از سیگنال ها شناسایی شوند. نیازمندی های و علاقه مندی های خانوارها در این مرحله شناسایی می شوند. در فاز دوم از تکنیک TF-IDF برای استخراج کلمات پراهمیت از لوازم بهینه و اختصاص برچسب به آن ها استفاده می شود. در نهایت در فاز سوم، از تکنیک شبیه سازی کسینوسی برای ارائه پیشنهاد استفاده می شود. در این گام برای هر وسیله که در لیست نیازمندی های کاربر وجود دارد یک پیشنهاد تولید می شود. رویکرد پیشنهادی با استفاده از مجموعه داده REDD مورد بررسی قرار گرفت. نتایج نشان داد که دقت سیستم توصیه گر حدود ۶۰٪ بوده است.

کلمات کلیدی

خانه هوشمند، سیستم های توصیه گر، NILM، یادگیری ژرف، TF-IDF

۱- مقدمه

مربوط به الگوهای مصرف انرژی برای استفاده کنندگان انرژی و مدیران برای طراحی استراتژی های مدیریت مصرف و سفارشی سازی تقاضای مصرف انرژی ضروری است. تکنیک های NILM این اطلاعات را با تقسیم بار الکتریکی متمرکز شده در سطح خانوار فراهم می کند [۱]. رویکردهای جدید بهینه سازی مصرف انرژی ترکیبی از سیستم توصیه گر و NILM برای کاهش مصرف انرژی خانوار استفاده می کنند. در این رویکردها از تکنیک NILM به عنوان تجزیه بار استفاده می شود تا نیازمندی ها و علاقه مندی های

با توجه به کم شدن سوخت های فسیلی و افزایش تقاضای انرژی، بهینه سازی مصرف انرژی در خانه بر اساس رفتارهای مصرف مورد نیاز است. مسئله تقسیم انرژی با استفاده از نظارت بارگیری غیر سرزده (NILM) رویکرد جدید برای مسئله کاهش مصرف انرژی در خانه هوشمند است. اطلاعات



جایی که $y(t)$ مقدار انرژی تجمیع شده در زمان t است، N تعداد لوازم، $y_i(t)$ سهم دستگاه i در مصرف انرژی در زمان t است، و $e(t)$ نویز و یا انرژی ناخواسته است.

تجزیه و تحلیل داده‌های انرژی می‌تواند به سه دسته تقسیم شوند: (۱) نظارت شده (۲) نظارت نشده و (۳) الگوریتم‌های تکاملی. روش‌های یادگیری نظارت شده برای ساختن یک مدل به نمونه‌های دارای برچسب از هر دستگاه نیاز دارند. این برچسب‌ها با ثبت ویژگی‌های دستگاه به کمک مشتری یا نصب کنتورهای اضافی در داخل خانه جمع‌آوری می‌شوند.

استفاده از تکنیک‌های یادگیری ماشین در NILM برای اولین بار با استفاده از شبکه عصبی برای شناسایی مصرف انرژی لوازم خانگی مطرح شد [۳]. سپس تکنیک‌های رمزگذار تنک BP [۴]، LVQ [۵] و ANN برگشتی [۶] برای تجزیه انرژی ارائه شد. علیرغم فرایند دشوار آموزش، شبکه‌های عصبی عمیق عملکرد مؤثری نسبت به مدل‌های مارکوف پنهان دارند. به‌تازگی از معماری شبکه عصبی ژرف LSTM و خود رمزنگار انسدادی (DAE) [۷] برای شناسایی دستگاه‌های محبوب پیشنهاد شده است [۷]. در هر دستگاه هدف، یک شبکه برای هر یک از معماری‌ها آموزش داده می‌شود. استفاده از ماشین بولتزمن محدود (RBMs) [۸] و CNN [۱۰] از دیگر حوزه‌های کاربرد شبکه‌های عصبی برای NILM است. ماشین بولتزمن محدود یک شبکه عصبی مصنوعی تصادفی مولد است که می‌تواند توزیع احتمال را در ورودی‌های آن بیاموزد. دو نوع از RBM برای تجزیه انرژی توسعه داده شده‌اند: RBM شرطی و شرطی فاکتور شده. این مدل‌ها برای داده‌های سری زمانی و فعالیت‌های انسانی استفاده می‌شوند [۸]. داده‌های انرژی اغلب دارای مقداری نویز هستند که بر روی عملکرد تجزیه انرژی تأثیر می‌گذارد. تکنیک خود رمزگذار نویزی شده (DAE) برای کاهش این مسئله مفید است. این تکنیک به‌تازگی برای NILM ارائه شده است که در آن شبکه‌های عصبی برای استخراج سیگنال اصلی از نسخه نویزی شده آموزش داده می‌شود [۱۱].

برخلاف NILM نظارت شده، تکنیک‌های نظارت نشده نیازی به پیش آموزش ندارند و بنابراین برای NILM در زمان واقعی مناسب هستند و کم‌هزینه‌تر و قابل اطمینان‌تر هستند. رویکردهای نظارت نشده NILM می‌تواند به سه زیرگروه تقسیم شوند: (۱) رویکردهای نظارت نشده که نیاز به داده‌های آموزشی بدون برچسب برای ساخت مدل لوازم خانگی دارند. آن‌ها اغلب مبتنی بر مدل مارکوف پنهان (HMM) هستند و مدل‌های لوازم خانگی یا در مرحله آموزش به صورت دستی یا به طور خودکار تولید می‌شوند [۱۲]؛ (۲) رویکردهای نظارت نشده‌ای که از داده‌های برچسب خورده برای ساختن مدل‌های لوازم استفاده می‌کند و سپس از مدل برای تفکیک انرژی در ساختمان‌ها استفاده می‌کنند. این رویکردها نیاز به جمع‌آوری داده‌های لوازم

خانوارها شناسایی و با استفاده از سیستم توصیه‌گر لوازم بهینه پیشنهاد داده شود.

روش‌های مبتنی بر یادگیری ماشین توجه بیشتری را در حوزه NILM نسبت به مارکوف پنهان و فرا ابتکاری به خود جلب کرده‌اند. ایده مقاله در استفاده از NILM مبتنی بر یادگیری ژرف برای سیستم توصیه‌گر شخصی‌سازی شده برای بهینه‌سازی مصرف انرژی در خانه‌های هوشمند است. در این پژوهش از تکنیک تجزیه انرژی NILM مبتنی بر خود رمزگذار نویزی شده استفاده می‌شود. تکنیک‌های یادگیری ژرف همانند خود رمزگذارها توانایی شناسایی خودکار ویژگی‌های سطح بالا را دارند و نیاز به دخالت کاربر ندارد. به دلیل اینکه سیگنال‌های انرژی تجمیع شده در خانه‌های هوشمند اغلب دارای مقداری نویز هستند، استفاده از خود رمزگذار نویزی شده می‌تواند این نویزها را تا حد ممکن شناسایی و از بین ببرد و عملکرد سیستم NILM را بهبود دهد. تکنیک NILM به طور خودکار تفکیک داده‌های کنتور هوشمند در پروفایل‌های مختلف را انجام می‌دهد. در روش پیشنهادی، بر اساس نتایج NILM، الگوهای مصرف لوازم خانگی هر خانوار در یک پروفایل کاربر استخراج می‌شود. به موازات آن، سیستم توصیه‌گر شخصی‌سازی شده به طور خودکار تبلیغات مربوط به لوازم خانگی بهینه را جمع‌آوری می‌کند و از تکنیک‌های بازاریابی اطلاعات برای نمایش هر آگهی به‌عنوان پروفایل لوازم خانگی استفاده می‌کند. سپس یک اندازه‌گیری شباهت برای مقایسه مشخصات کاربر و پروفایل لوازم خانگی و رتبه‌بندی تبلیغات لوازم اعمال می‌شود. در نهایت توصیه‌های مناسب به کاربران ارائه می‌شود.

رئوس مطالب مقاله به شرح ذیل است. در بخش دوم انواع رویکردهای تجزیه انرژی در دسته‌های مختلف با تمرکز بر روی NILM مبتنی بر یادگیری ماشین بیان می‌شوند. بخش سوم یک روش جدید پیشنهاد می‌دهد که سه تکنیک NILM، TF-IDF و شباهت کسینوسی برای ایجاد یک سیستم توصیه‌گر استفاده می‌کند. در بخش چهارم، نتایج شبیه‌سازی و تجزیه و تحلیل بیان می‌شوند و سرانجام در بخش پنجم یک نتیجه‌گیری کلی و مختصر از مطالب مطرح شده در این پایان‌نامه ارائه می‌شود.

۲- کارهای مرتبط

تکنیک NILM برای اولین بار دهه ۱۹۸۰ توسعه داده شد [۲]. در یک ساختمان، انرژی مجموع مصرف برق تمام وسایل برقی است؛ بنابراین، مسئله این است که مشخص کنیم هر دستگاه چه مقدار برق مصرف می‌کند. انرژی تجمیع شده N دستگاه در زمان t می‌تواند مجموع انرژی‌های فعال تمام لوازم خانه باشد که به صورت زیر تعریف می‌شود:

$$y(t) = \sum_{i=1}^N y_i(t) + e(t) \quad (1)$$



توصیه‌گر مبتنی بر مدل مارکوف پنهان برای استخراج نیازمندی‌ها و علاقه-مندی‌های خانوارها ارائه شده است [۲۱]. در این روش، توصیه‌های مناسب بر اساس الگوهای به‌دست‌آمده از NILM به هر خانوار ارائه می‌شود. این روش به دلیل اینکه از مدل مارکوف پنهان برای مدل‌سازی استفاده می‌کند نمی‌تواند کارایی مناسبی برای سیستم توصیه‌گر داشته باشد و ممکن است منجر به شناسایی اشتباه لوازم شود و در نتیجه پیشنهادهای مناسبی ارائه نمی‌شود. در سیستم توصیه‌گر پیشنهادی در بخش بعدی این چالش به کمک NILM مبتنی بر DAE ارائه شده در [۱۱] کاهش داده می‌شود.

۳- متدولوژی پیشنهادی

سیستم‌های توصیه‌گر ابزارهای قدرتمندی برای بهبود بهره‌وری انرژی هستند که با تجزیه و تحلیل داده‌های مسکونی، می‌توانند ترجیحات و ضروریات کاربران را متوجه شوند و محصولات/خدمات مفید انرژی را به صورت شخصی به هر خانوار توصیه کنند. هدف از طراحی روش پیشنهادی این است که به طور ضمنی نیازها و ترجیحات کاربران در وسایل را از طریق تحلیل الگوهای مصرف انرژی استنباط کرده و کاربران را به سمت خرید لوازمی که در مصرف انرژی بهینه هستند تشویق کنیم تا به طور بالقوه باعث کاهش مصرف انرژی برای شبکه، کاهش هزینه‌های مصرف انرژی و در نتیجه رضایت‌مندی کاربران شود. شکل (۱) چارچوب پیشنهادی برای توصیه‌های شخصی‌سازی شده در خانه هوشمند را نشان می‌دهد. مدل پیشنهادی دارای هشت گام است: پیش‌پردازش، خود رمزگذار نوپزی شده، شناسایی بار، ایجاد ماتریس‌های علاقه‌مندی و نیازمندی، ایجاد پروفایل خانوار، ایجاد پروفایل فقره، محاسبه TF-IDF و پیشنهاد شخصی‌سازی شده.

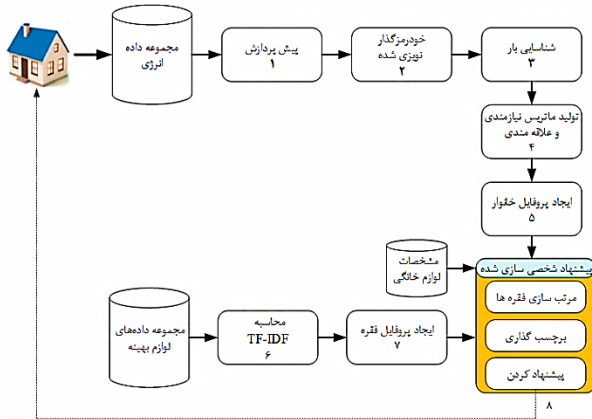
پیش‌پردازش: فرآیند پیش‌پردازش که شامل سه مرحله است: نرمال‌سازی، انتخاب لوازم و انتخاب نمونه‌ها. در مرحله نرمال‌سازی، تمام مقادیر که مقادیر ۰ و بیشتر را شامل می‌شوند به بازه بین ۰ و ۱ تبدیل می‌شوند. در گام بعدی بازه وسیله شامل ماکروویو، ماشین لباسشویی، ماشین ظرف‌شویی، یخچال، اجاق برقی، آبگرم کن، کولر، گرم‌کن برقی، کوره برقی، لوازم آشپزخانه و اجاق گاز انتخاب می‌شوند. در روش پیشنهادی از همه خانه‌ها برای آموزش و آزمایش استفاده می‌شود بطوریکه برای هر خانه اطلاعات چهار روز برای آزمایش و سایر داده‌ها برای آموزش استفاده می‌شود.

تکنیک NILM مبتنی بر خود رمزگذار نوپزی شده: مسئله NILM می‌تواند به عنوان یک مسئله نوپز زدایی از طریق بیان سیگنال تجمیع شده به عنوان مجموع انرژی مصرف شده لوازم فرموله سازی شود به همراه یک مقدار نوپز که تمام مقدار باقیمانده را تشکیل می‌دهد. به طور خاص، معادله (۲) می‌تواند به صورت زیر تنظیم شود:


دارند. از این داده‌ها برای ساخت مدل‌های لوازم‌خانگی استفاده می‌شود که سپس در ساختمان‌های جدید مورد استفاده قرار می‌گیرد. بیشتر تکنیک‌های NILM مبتنی بر یادگیری عمیق در این گروه قرار می‌گیرند؛ (۳) رویکردهای نظارت‌نشده‌ای که نیازی به آموزش قبل از تفکیک انرژی ندارند. این رویکردها می‌توانند تفکیک انرژی را بدون نیاز به داده‌های اندازه‌گیری شده یا دانش قبلی انجام دهند.

مدل پنهان مارکوف یکی از ابزارهای آماری برای مدل‌سازی سری‌های زمانی گسسته است. یک مدل پنهان مارکوف اطلاعات درباره تاریخچه یک سری زمانی را در یک مقدار متغیر چندجمله‌ای کدگذاری می‌کند. در مدل پنهان مارکوف، متغیر چندجمله‌ای به متغیرهای حالت چندگانه تبدیل شده و بنابراین به صورت توزیع شده نمایش داده می‌شود. مدل‌های پنهان مارکوف یکی از تکنیک‌های پرکاربرد برای تجزیه انرژی نظارت‌نشده است که مدل‌های بسیار خوبی برای یادگیری هستند، اما دو معایب اساسی دارند: (۱) توزیع‌های بازه وضعیت به یک شکل هندسی محدود می‌شود که برای بسیاری از داده‌های دنیای واقعی مناسب نیست و (۲) تعداد وضعیت‌های پنهان باید از قبل تنظیم شود تا پیچیدگی مدل به روش بیزی از داده‌ها استنباط نشود. به همین دلیل مدل‌های توسعه‌یافته همانند مارکوف بیزین [۱۳] و مارکوف نیمه پنهان سلسله مراتبی [۱۴] برای تجزیه انرژی در خانه‌های هوشمند ارائه شده است. در نتایج بررسی شده مدل پنهان مارکوف شرطی نسبت به سایر مدل‌ها تجزیه دقیق‌تری از اطلاعات مربوط به هر دستگاه نشان می‌دهد [۱۲].


الگوریتم ژنتیک که یک الگوریتم تکاملی است در تعدادی از پژوهش‌های NILM مورد استفاده قرار گرفته است. الگوریتم ژنتیک به طور معمول برای تشخیص ویژگی‌ها و الگوهای پروفایل‌های انرژی دستگاه و برای بهینه‌سازی پارامترهای موجود که در سیستم‌های فازی مورد استفاده قرار می‌گیرند، استفاده می‌شود [۱۵، ۱۶، ۱۷]. این الگوریتم‌ها می‌توانند وسایلی که به طور دائم، تکراری و دوره‌ای رفتار می‌کنند را شناسایی کنند. برخی از پژوهش‌ها ترکیبی از ANN و الگوریتم ژنتیک برای شناسایی نیازهای بار و بهبود دقت تشخیص استفاده کرده‌اند [۱۸]. الگوریتم تکامل تفاضلی یک رویکرد فرا ابتکاری ساده و قوی است که از عملگرهای الگوریتم ژنتیک همانند تقاطع، جهش و انتخاب استفاده می‌کند و برای NILM استفاده شده است [۱۹]. همچنین از الگوریتم بهینه‌سازی کلونی مورچگان برای فرآیند شناسایی بار استفاده شده است که در یک فضای ترکیبی که به عنوان یک مسئله کوله‌پشتی چندبعدی ۱-۰ فرمول‌بندی شده است اعمال می‌شود [۲۰]. تکنیک‌های NILM می‌توانند برای شناسایی لوازم پرمصرف نیز استفاده شود که این موضوع به سیستم‌های توصیه‌گر کمک می‌کند تا لوازم مناسب را در راستای کاهش مصرف انرژی در خانه‌های هوشمند به خانوارها ارائه دهند. این حوزه پژوهشی یکی از جدیدترین کاربردهای NILM است. یک سیستم



شکل (۱): چارچوب روش پیشنهادی



شکل (۲): شبکه رمزگذار: سیگنال ورودی مصرف انرژی تجمیع شده



شکل (۳): شبکه رمزگشا: سیگنال هدف مصرف انرژی هر وسیله

$$y(t) = y_j(t) + v_j(t), \quad (2)$$

$$v_j(t) = \sum_{i \neq j}^N y_i(t) + e(t), \quad (3)$$

رابطه (۳) نمایانگر نویز برای لوازم خانگی Z است؛ بنابراین، برای به دست آوردن $Z(t)$ ، لازم است که نویز $v_j(t)$ از اندازه گیری تجمیع شده خارج شود. در زمینه NILM، برای هر دستگاه یک خود رمزگذار برای بازسازی $y_i(t)$ با توجه به سیگنال تجمیع شده $y(t)$ آموزش داده می شود. یک DAE یک نوع از خود رمزگذار است که تلاش می کند تا ورودی بدون نویز را از ورودی نویزی شده بازسازی کند. توپولوژی عمومی شبکه ای که در اینجا برای NILM پیشنهاد شده است در شکل های (۲) و (۳) نشان داده شده است.

شبکه DAE آموزش داده شده می شود تا خطای بین ورودی و خروجی دستگاه را به حداقل برساند. آموزش با استفاده از الگوریتم نزول شیب تصادفی و با توقف زودهنگام برای جلوگیری از بیش برازش انجام می شود. در مرحله بعد پروفایل هر خانوار با استفاده از بردارهای علاقه مندی و نیازمندی که توسط تکنیک NILM استخراج می شوند تشکیل می شود. برای شناسایی علاقه مندی های کاربر از تشخیص رویداد (خاموش/روشن بودن) استفاده می کنیم. تعداد تشخیص های روشن شدن هر وسیله در بازه های زمانی مختلف روز محاسبه و پرتکرارترین آن ها به عنوان علاقه مندی های کاربر شناسایی می شود و نام وسیله به ماتریس علاقه مندی اضافه می شود.

برای ایجاد ماتریس نیازمندی، پس از هر بار پیش بینی مصرف انرژی یک وسیله در یک زمان، مقدار پیش بینی شده با مقدار حد آستانه تعریف شده مقایسه می شود و اگر بیشتر از حد آستانه بود به لیست لوازم پرمصرف اضافه می شود. سپس یک بردار واحد از اجتماع ماتریس های نیازمندی و علاقه مندی تشکیل می شود. لازم به ذکر است که میزان حد آستانه تعیین شده به معنی مقدار کمیته برای مصرف انرژی نیست، این مقدار به عنوان حد آستانه بهینه شناخته می شود که وسایلی که دارای مصرف انرژی بیشتر از این حد آستانه باشند به عنوان پرمصرف شناخته می شوند.

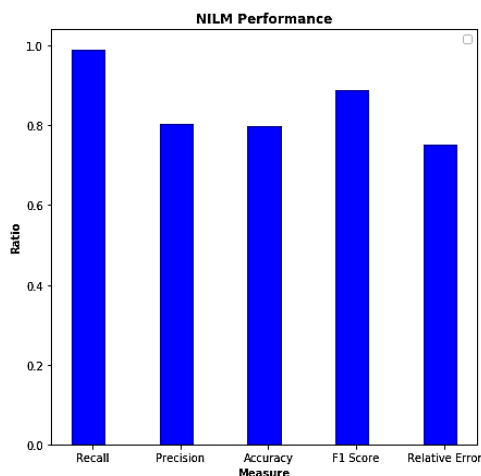
برای هر وسیله موجود در پایگاه داده ثانویه یک پروفایل ایجاد می شود. ابتدا وزن هر کلمه کلیدی که نشان دهنده اهمیت آن است با استفاده از TF-IDF محاسبه می شود. سپس وزن هر متون بر اساس وزن های اختصاص داده شده دست بندی می شوند. ابتدا تمام کلمات کلیدی به صورت نزولی وزن مرتب شده و بر اساس یکی از یازده نوع وسیله برچسب گذاری می شوند.

برای تطبیق وسیله مورد نظر در پروفایل یک خانواده با وسیله بهینه برای پیشنهاد، کلمات کلیدی وسیله مورد نظر استخراج و با تمامی وسایل بهینه پیش بینی شده با برچسب وسیله مورد نظر با استفاده از شباهت کسینوسی تطبیق داده می شود. شباهت کسینوسی بین دو متن به صورت زیر محاسبه می شود:

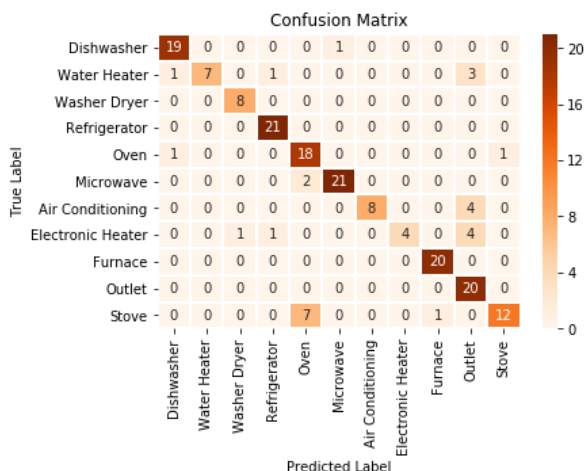
$$\text{Score}(d1, d2) = \text{Cos}(W_{d1}, W_{d2}) = \frac{W_{d1} \cdot W_{d2}}{\|W_{d1}\|_2 \cdot \|W_{d2}\|_2} = \frac{\sum_{i=1}^k W_{i,d1} \cdot W_{i,d2}}{\sqrt{\sum_{i=1}^k W_{i,d1}^2} \sqrt{\sum_{i=1}^k W_{i,d2}^2}} \quad (8)$$



۴- نتایج آزمایش‌ها



شکل (۴): عملکرد مدل NILM مبتنی بر DAE



شکل (۵): ماتریس آشفتگی برای دسته‌بندی متون

جدول (۱): لیست لوازم شناسایی شده برای هر خانه

خانه	لوازم شناسایی شده
اول	Oven - Outlets - Washer_Dryer - Stove - Microwave
دوم	Outlets - Outlets - Microwave - Water_Heater
سوم	Washer_Dryer - Refrigerator - Microwave - Air_Conditioning - Air_Conditioning
چهارم	Air_Conditioning - Air_Conditioning - Dishwasher - Outlets_Unknown - Furnace
پنجم	Microwave - Kitchen_Outlets - Refrigerator - Furnace
ششم	Air_Conditioning - Outlets - Stove - Washer_Dryer

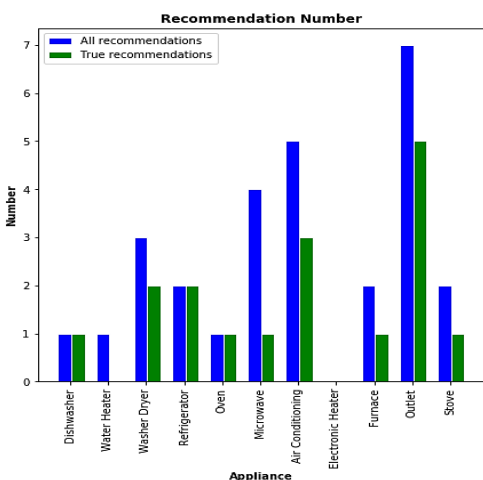
نتایج روش پیشنهادی پیاده‌سازی در سه بخش ارائه می‌شود: دسته‌بندی متن، تجزیه انرژی و پیشنهاد شخصی‌سازی شده. نتایج با Epoch ۲۰۰، بهینه‌ساز ADAM و تابع هزینه MSE با پایتون به دست آمد. برای ایجاد مدل NILM از مجموعه داده REDD [۲۲] استفاده شد. این مجموعه داده به‌طور خاص برای تفکیک انرژی جمع‌آوری شده است: مجموعه REDD شامل مصرف برق کل خانه و همچنین دستگاه‌ها برای شش‌خانه واقعی در طی چند ماه است. این داده‌ها در ۱۱۷ روز با ۲۶۸ مانیتور منحصر به فرد ذخیره شدند. برای ایجاد پروفایل‌های خانوار به دلیل اینکه برای تولید پیشنهادها توسط سیستم توصیه‌گر نیاز به مشخصات لوازم هر خانه داشتیم، برای هر وسیله یک فایل متنی از اینترنت که دارای مصرف انرژی برابر با وسیله موجود در REDD بود را جمع‌آوری و وارد پایگاه داده "مشخصات لوازم‌خانگی" کردیم. برای ایجاد پروفایل‌های فخره و دسته‌بندی متون، از یک روش خودکار برای جمع‌آوری داده برای لوازم مختلف استفاده کردیم که در نهایت حدود ۲۳۰ فایل متنی برای ۱۱ وسیله از سایت‌های Amazon، AlabamaPower و goodhousekeeping گردآوری شدند. این مجموعه داده به‌عنوان "مجموعه داده‌های لوازم بهینه" شناخته می‌شود.

شکل (۴) مقدار مقادیر به‌دست‌آمده صحت، دقت، فراخوانی، و F1-Score و خطای نسبی برای مدل NILM نشان می‌دهد. خود رمزگذار نویزی شده دارای عملکرد بهتری نسبت به FHMM است. برتری الگوریتم‌های یادگیری ژرف همانند DAE نسبت به الگوریتم‌های مدل مارکوف این است که می‌توانند با استفاده از یادگیری خودکار و تکراری ویژگی‌های سطح بالایی را استخراج کنند. مدل طراحی شده دارای نرخ فراخوانی ۹۹٪ و همچنین دقت و صحت ۸۰٪ است. همچنین میانگین کل خطای مطلق ۵۱.۲۷ است.


جدول (۱) لوازمی که با استفاده از NILM پیشنهادی و با تحلیل خروجی به‌دست‌آمده است. از بین ۶۸ وسیله‌ای که دارای یازده برجسب انتخاب شده هستند، ۲۸ وسیله انتخاب شد تا لوازم بهینه برای آن پیشنهاد شود (۴۰٪).

شکل (۵) عملکرد الگوریتم TF-IDF برای شناسایی لوازم‌خانگی بهینه را نشان می‌دهد که تعداد دسته‌بندی‌ها در قطر اصلی نشان‌دهنده دسته‌بندی‌های درست است. از مجموعه ۲۳۰ متن موردنظر، ۱۸۵ متن برجسب یکی از یازده کلاس را به خود اختصاص داده است. این نشان می‌دهد که الگوریتم توانسته است ۸۰٪ از متون را به‌عنوان یکی از لوازم بهینه دسته‌بندی کند؛ که از این تعداد ۱۵۸ متن به‌درستی تشخیص داده شدند، یعنی دقت ۸۵٪.

¹ <http://redd.csail.mit.edu>



شکل (۶): تعداد پیشنهادها در مقابل پیشنهادهای درست



شکل (۷): میزان بهینه‌سازی مصرف انرژی برای لوازم مختلف

جدول (۲): میانگین مقادیر مصرفی و پیشنهادی برای لوازم خانگی

پیشنهادی	مصرفی	بهینه	وسيله
۹۵	۱۱۰۵	۱۰۰	Oven
۴۳۶	۴۸۶	۵۰	Outlets
۱۸۶۰	۲۱۳۰	۲۵۰۰	Washer Drayer
۱۳۰۰	۱۳۸۴	۱۴۰۰	Stove
۸۳۵	۱۰۵۲	۹۰۰	Microwave
۹۳۰	۱۲۳۵	۱۰۰۰	Furnace
۲۰۸۷	۲۲۳۰	۲۰۰۰	Air Conditioning
۱۷۸	۲۲۵	۲۰۰	Refrigerator
۱۶۰۰	۱۷۵۰	۱۵۰۰	Dishwasher

شکل (۶) تعداد پیشنهادهای وسایل بهینه برای شش‌خانه را در مقابل تعداد پیشنهادهای درستی که به خانوار ارائه می‌شود را نشان می‌دهد. به دلایل گفته‌شده، مقادیر معیارها برای وسیله‌های Electronic Heater و Water Heater برابر با صفر است. از طرف دیگر، بیشترین تعداد پیشنهاد برای Outlet بوده است که ۷ عدد بوده است که ۵ پیشنهاد از آن درست بوده است.

شکل (۷) اختلاف عملکرد سیستم توصیه‌گر مصرف انرژی را در مقایسه با مقادیر بهینه و مقادیر مصرفی در خانه‌ها را نشان می‌دهد. برای به دست آوردن چارت راداری، میانگین مصرف برای هر وسیله در لیست پروفایل و همچنین میانگین مصرف انرژی وسایل پیشنهادشده را محاسبه می‌کنیم. همچنین از آنجایی که Electronic Heater در لیست پروفایل خانوارها نبود و پیشنهادی برای Water Heater وجود نداشت، از نشان دادن این لوازم در چارت صرف‌نظر کردیم. همان‌گونه که مشاهده می‌شود میانگین مصرف لوازم پیشنهادی کمتر از مصرفی و نزدیک به بهینه بوده است.

جدول (۲) میانگین مقادیر مصرفی و پیشنهادی برای ۹ وسیله موردنظر را نشان می‌دهد. همان‌گونه که نشان داده‌شده است میانگین مقدار مصرفی وسایل پیشنهادی برای ماشین ظرف‌شویی و کوره برقی نسبت به مقادیر بهینه بیشتر است. درحالی‌که کمترین مقدار برای لوازم آشپزخانه بوده است. روش پیشنهادی در مجموع توانسته مقدار مصرف انرژی برای خانوارها را به مقدار ۱۲۳۴.۵ وات نسبت به انرژی مصرفی خانه‌ها کاهش دهد. با این حال، در مقایسه با مقادیر بهینه تعیین‌شده، روش پیشنهادی توانست وسایل بهینه‌ای را پیشنهاد کند که حدود ۲۲۱ وات نسبت به میانگین مصرف بهینه تعیین‌شده برای خانوارها بهینه بوده است.

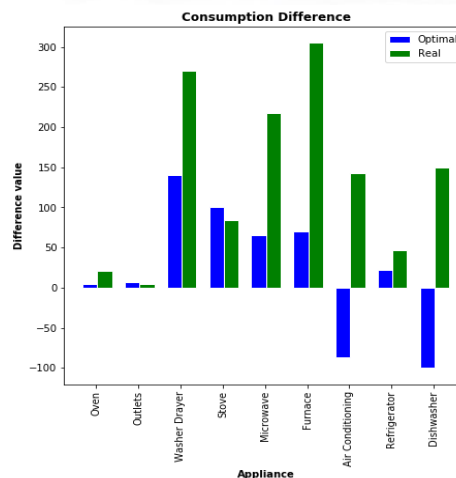
شکل (۸) مقدار میانگین اختلاف مصرف انرژی برای وسایل پیشنهادی نسبت به میانگین مصرف بهینه انرژی و میانگین مصرف لوازم موجود در پروفایل‌های کاربر را نشان می‌دهد. همان‌گونه که در شکل نشان داده‌شده است تنها برای دو وسیله کولر و ماشین ظرف‌شویی نتوانستیم وسایل بهینه‌تری نسبت به میانگین مصرف بهینه داشته باشیم. برای هفت وسیله دیگر پیشنهادهای مناسبی داشتیم.

۵- نتیجه‌گیری و کارهای آتی

در این مقاله، یک سیستم توصیه‌گر شخصی‌سازی شده مبتنی بر اجرای تکنیک‌های TF-IDF و NILM مبتنی بر DAE پیشنهاد شد. برای دستیابی



- [6] Lin, Y. H., Tsai, M. S., "A novel feature extraction method for the development of nonintrusive load monitoring system based on BP-ANN", Symposium on Computer, Communication, Control and Automation, pp. 215-218, 2010.
- [7] Kelly, J., Knottenbelt, W., "Neural NILM: Deep neural networks applied to energy disaggregation", Proc. of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments, pp. 55-64, 2015.
- [8] Mocanu, E., Nguyen, P. H., Gibescu, M., Kling, W. L., "Deep learning for estimating building energy consumption", Sustainable Energy, Grids and Networks, Vol. 6, pp. 91-99, 2016.
- [9] Mocanu, D. C., Mocanu, E., Nguyen, P.H., Gibescu, M., Liotta, A., "Big IoT data mining for real-time energy disaggregation in buildings", IEEE International Conference on Systems, Man, and Cybernetics (SMC), pp. 003765-003769, 2016.
- [10] Zhang, C., Zhong, M., Wang, Z., Goddard, N., Sutton, C., "Sequence-to-point learning with neural networks for non-intrusive load monitoring", Proc. of the Thirty-Second AAAI Conference on Artificial Intelligence, 2018.
- [11] Bonfigli, R., M., Squartini, S., Piazza, F., "Denoising autoencoders for non-intrusive load monitoring: improvements and comparative evaluation", Energy and Buildings, Vol. 158, pp. 1461-1474, 2018.
- [12] Kim, H., Marwah, M., Arlitt, M., Lyon, G., Han, J., "Unsupervised disaggregation of low frequency power measurements", SIAM international conference on data mining, pp. 747-758, 2011.
- [13] Johnson, M. J. Willsky, A. S., "Bayesian nonparametric hidden semi-Markov models", Journal of Machine Learning Research, Vol. 14, No. 1, pp. 673-701, 2013.
- [14] Parson, O., Ghosh, S., Weal, M., Rogers, A. "Non-intrusive load monitoring using prior models of general appliance types", 26th AAAI Conference on Artificial Intelligence, 2012.
- [15] Egarter, D., Sobe, A., Elmenreich, W., "Evolving non-intrusive load monitoring", Proc. of the European Conference on the Applications of Evolutionary Computation, pp. 182-191, 2013.
- [16] Egarter, D., Elmenreich, W., "EvoNILM: Evolutionary appliance detection for miscellaneous household appliances", 15th annual conference companion on Genetic and evolutionary computation, pp. 1537-1544, 2013.
- [17] Trung, K. N., Dekneuevel, E., Nicolle, B., Zammit, O., Van, C. N., Jacquemod, G., "Event detection and disaggregation algorithms for nialm system", 2nd International Non-Intrusive Load Monitoring (NILM) Workshop, 2014.
- [18] Chang, H. H., Chien, P. C., Lin, L. S., Chen, N., "Feature extraction of non-intrusive load-monitoring system using genetic algorithm in smart meters", 8th International



شکل (۸): میانگین اختلاف مصرف انرژی لوازم پیشنهادی

به بهترین کارایی، پارامترهای شبکه با یک لایه CNN و لایه ادغام انجام شده است تا اندازه خروجی را فشرده کند. میانگین نتایج به دست آمده برای NILM عملکرد ۸۵٪ را نشان داد. دقت عملکرد TF-IDF برای دسته بندی متون ۸۰٪ بوده است. در مرحله توصیه، روش پیشنهادی ۲۸ وسیله را شناسایی کرد که تعداد ۱۷ توصیه موفقیت آمیز داشته است یعنی دقت ۶۰٪ را به دست آوردیم. استفاده از ریشه یابی و زنجیره لغوی کلمات برای بهبود عملکرد تکنیک TF-IDF، استفاده از توصیه مشارکتی برای سیستم توصیه گر و استفاده از یک مکانیسم یادگیری تکراری برای سیستم از پیشنهادهای ما برای آینده است.

مراجع

- [1] Cominola, A., Giuliani, M., Piga, D., Castelletti, A., Rizzoli, A. E., "A hybrid signature-based iterative disaggregation algorithm for non-intrusive load monitoring", Applied energy, Vol. 185, pp. 331-344, 2017.
- [2] Hart, G. W., "Nonintrusive appliance load monitoring", Proc. of the IEEE, Vol. 80, no. 12, pp. 1870-1891, 1992.
- [3] Yoshimoto, K., Nakano, Y., Amano, Y., Kermanshahi, B., "Non-intrusive appliances load monitoring system using neural networks", Growth, Vol. 2, pp. 2-5, 2000.
- [4] Kolter, J. Z., Batra, S., Ng, A. Y., "Energy disaggregation via discriminative sparse coding", Advances in Neural Information Processing Systems, pp. 1153-1161, 2010.
- [5] Yang, H. T., Chang, H. H., Lin, C. L., "Design a neural network for features selection in non-intrusive monitoring of industrial electrical loads", 11th IEEE International Conference on Computer Supported Cooperative Work in Design, pp. 1022-1027, 2007.



- Conference on e-Business Engineering, pp. 299-304, 2011.
- [19] Hassan, T., "Bi-level characterization of manual setup residential non-intrusive demand disaggregation using enhanced differential evolution", 1st International Workshop Non-Intrusive Load Monitoring, 2012.
- [20] Lin, Y. H., Tsai, M. S., "Development of an improved time-frequency analysis-based nonintrusive load monitor for load demand identification", IEEE Transactions on Instrumentation and Measurement, Vol. 63, No. 6, pp. 1470-1483, 2013.
- [21] Luo, F., Ranzi, G., Kong, W., Dong, Z. Y., Wang, S., Zhao, J., "Non-intrusive energy saving appliance recommender system for smart grid residential users", IET Generation, Transmission & Distribution, Vol. 11, No. 7, pp. 1786-1793, 2017.
- [22] Kolter, J. Z., Johnson, M. J., "REDD: A public data set for energy disaggregation research", Workshop on Data Mining Applications in Sustainability, pp. 59-62, 2011.

زیرنویس

-
- ⁱ Non-Intrusive Load Monitoring (NILM)
ⁱⁱ Sparse Auto-encoder
ⁱⁱⁱ Denoising Auto-encoder
^{iv} Restricted Boltzmann Machine (RBM)
^v Overfitting