

Proposing a Novel Approach Non-Intrusive Load Monitoring Based on Feature Extraction Matrix and KNN Machine Learning Model

Behrooz Taheri¹, *PhD Student*, Mostafa Sedighizadeh², *Associate Professor*, Mohammad Reza Nasiri¹
Assistant Professor, Alireza Sheikhi Fini³, *Assistant Professor*

¹ Department of Electrical Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran

² Faculty of Electrical Engineering, Shahid Beheshti University, Evin, Tehran, Iran

³ Power System Operation and Planning Research Department, Niroo Research Institute, Tehran, Iran

Abstract:

In recent years, the interest in conducting research on non-intrusive load monitoring is increasing strongly due to the increase in electrical energy consumption. Numerous studies have underscored that the implementation of non-intrusive load monitoring methods, apart from various advantages such as load response, increasing the accuracy of load prediction, etc., will increase the level of cost savings for occupants of residential structures. Recently, with the adoption of techniques grounded in deep learning, the use of these methods has also increased in order to load disaggregation. However, the most important problem with these methods is the need for complex hardware in order to train and examine the techniques. For this reason, it is necessary to transfer the power signal sampled from the smart meter to data processing centers and be analyzed. In addition to the need for high-speed communication networks, this also endangers data security. Accordingly, in this article, a non-intrusive load monitoring method is presented based on extracting the feature matrix from the instantaneous frequency signal obtained from the power signal of household appliances. The most important feature of the presented method is to increase the accuracy of the classical KNN model. The presented method has been analyzed using EMBED open-access data, which includes the consumption dataset from three different apartments. The results show that the KNN model attains significantly enhanced accuracy when using the feature matrix data introduced in this article compared to other feature extraction methods.

Keywords: NILM, Extracting features, Feature matrix, Instantaneous frequency, Hilbert transform, KNN.

Received: 05 August 2023

Revised: 08 October 2023

Accepted: 20 October 2023

Corresponding Author: Dr. Mostafa Sedighizadeh, m_sedighi@sbu.ac.i

DOI: <http://dx.doi.org/10.30486/teeges.2023.1995779.1093>



ارائه یک رویکرد جدید پایش غیر مداخله‌گر بار بر اساس استخراج ماتریس ویژگی و مدل یادگیری ماشین KNN

بهرروز طاهری^۱، دانشجوی دکتری، مصطفی صدیقی زاده^۲، دانشیار، محمدرضا نصیری^۱، استادیار، علیرضا شیخی فینی^۳، استادیار

۱- گروه مهندسی برق، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

۲- دانشکده مهندسی برق، دانشگاه شهید بهشتی، تهران، ایران

۳- گروه پژوهشی برنامه‌ریزی و بهره‌برداری سیستم قدرت، پژوهشگاه نیرو، تهران، ایران

چکیده: در سال‌های اخیر علاقه به انجام تحقیقات بر روی پایش غیر مداخله‌گر بار به دلیل افزایش مصرف انرژی الکتریکی به شدت در حال افزایش است. تحقیقات مختلف نشان داده‌اند که در صورت پیاده‌سازی روش‌های پایش غیر مداخله‌گر بار به‌غیر از مزایای مختلفی چون پاسخگویی بار، افزایش دقت پیش‌بینی‌های مصرف و غیره موجب افزایش سطح صرفه‌جویی در ساکنان ساختمان‌های مسکونی خواهد شد. در سال‌های اخیر با پیشرفت روش‌های مبتنی بر یادگیری عمیق استفاده از این روش‌ها نیز به‌منظور تفکیک بار مصرفی بسیار افزایش پیدا کرده است. با این وجود مهم‌ترین مشکل این روش‌ها نیاز به سخت‌افزار پیچیده به‌منظور آموزش و بررسی روش‌ها است. به همین دلیل نیاز است تا سیگنال توان نمونه‌برداری شده از کنتور هوشمند به مراکز پردازش داده منتقل شده و مورد تجزیه و تحلیل قرار گیرد. این کار علاوه بر نیاز به شبکه‌های ارتباطی پرسرعت امنیت داده‌ها را نیز به خطر می‌اندازد. با توجه به نکات بیان شده در این مقاله یک روش پایش غیر مداخله‌گر بار بر اساس استخراج ماتریس ویژگی از سیگنال فرکانس لحظه‌ای به‌دست‌آمده از سیگنال توان لوازم‌خانگی ارائه شده است. مهم‌ترین ویژگی روش ارائه شده افزایش دقت مدل نزدیک‌ترین همسایه (KNN) کلاسیک است. روش ارائه شده با استفاده از داده‌های دسترسی آزاد با نام EMBED که شامل اطلاعات مصرف سه آپارتمان مختلف است مورد تجزیه و تحلیل قرار گرفته است. نتایج به‌خوبی نشان می‌دهد که مدل KNN در زمان استفاده از داده‌ها ماتریس ویژگی مورد استفاده در این مقاله از دقت بسیار بالاتری در مقابل دیگر روش‌های استخراج ویژگی برخوردار است.

واژه‌های کلیدی: پایش غیر مداخله‌گر بار، استخراج ویژگی، ماتریس ویژگی، فرکانس لحظه‌ای، تبدیل هیلبرت، KNN.

تاریخ ارسال مقاله: ۱۴۰۲/۰۵/۱۴

تاریخ بازنگری مقاله: ۱۴۰۲/۰۷/۱۶

تاریخ پذیرش مقاله: ۱۴۰۲/۰۷/۲۹

نویسنده‌ی مسئول: دکتر مصطفی صدیقی‌زاده، m_sedighi@sbu.ac.i

DOI: <http://dx.doi.org/10.30486/teeges.2023.1995779.1093>





۱- مقدمه

امروزه محصولات الکتریکی به‌طور گسترده در زندگی ما مورد استفاده قرار می‌گیرند. بر هیچ‌کس پوشیده نیست که انرژی الکتریکی به یک بخش ضروری از زندگی مدرن تبدیل شده است. با ظهور بحران انرژی به علت افزایش تقاضا مسائل مربوط به صرفه جویی در انرژی توجه بسیاری از محققان را به خود جلب کرده است. از آنجایی که بیشترین انرژی الکتریکی در ساختمان‌ها مصرف می‌شود (حدود ۷۴ درصد در مرجع [۱] ذکر شده است)، علاقه به بهینه‌سازی مصرف در ساختمان‌ها به شدت افزایش پیدا کرده است [۲]. به‌منظور بهینه‌سازی مصرف لازم است تا درک در مناسبی از میزان مصرف انرژی هر یک از لوازم خانگی داشته باشیم [۴-۱]. به این منظور استفاده از روش پیش غیرمداخله‌گر بار^۱ به علت هزینه پیاده‌سازی کمتر، عدم نقض حریم خصوصی ساکنان منزل و افزایش سطح آگاهی از بار به‌عنوان یک فناوری مهم برای استخراج اطلاعات بار مورد استفاده قرار گرفت [۵]. پیش غیر مداخله‌گر بار بر این اساس کار می‌کند که هر وسیله برقی مورد استفاده در منازل مسکونی امضای مخصوص به خود را دارا می‌باشد. پیش غیر مداخله‌گر بار از اطلاعات جمع‌آوری شده توسط سنسورهای نصب شده (کنتورهای هوشمند) در ورودی منازل مسکونی برای پیش بار استفاده می‌کند. در سال‌های اخیر برنامه‌های مختلفی برای استفاده در پیش غیر مداخله‌گر بار ارائه شده است که در ادامه به بررسی آن‌ها خواهیم پرداخت.

یکی از راه‌حل‌های اولیه ارائه شده به‌منظور استفاده در برنامه‌های پیش غیر مداخله‌گر بار استفاده از شیوه‌هایی به‌منظور تشخیص رویداد بوده است. طبق [۵] روش‌های تشخیص رویداد را می‌توان به مدل تطبیق الگو، مدل‌های احتمالی، مدل‌های اکتشافی خیره و مدل‌های مبتنی بر فیلتر همگرا تقسیم کرد. برخی روش‌ها مانند روش‌های ارائه شده در [۹-۶] از استخراج ویژگی برای تشخیص نوع مصرف‌کننده استفاده می‌کنند. استخراج ویژگی یک گام اساسی برای یادگیری درباره گذراهای لوازم خانگی است. از جمله این ویژگی‌ها می‌توان به ویژگی‌هایی مانند تغییر در توان، زمان و فرکانس‌های دامنه فرکانسی، مسیرهای ولتاژ و جریان و همچنین بررسی وجود نویز در سیگنال اشاره کرد [۸]. برخی دیگر از روش‌ها از ویژگی‌های موجود در سیگنال توان مانند مقدار موثر، توان ظاهری، توان راکتیو، توان اکتیو و ضریب توان برای تفکیک بار مصرفی استفاده می‌کنند [۱۰]. مهم‌ترین مزیت این روش‌ها عدم نیاز به نرخ نمونه‌برداری بالا به‌منظور تشخیص لوازم خانگی است. اما با این وجود این روش‌ها دارای یک مشکل اساسی هستند. در این مشکل به دلیل تشابه ویژگی‌های برخی از لوازم خانگی به یکدیگر ممکن است چند وسیله خانگی با یکدیگر اشتباه گرفته شوند. دسته‌ای دیگر از روش‌ها برای جلوگیری از بروز چنین مشکلاتی از منحنی‌های ولتاژ و جریان به‌منظور استخراج ویژگی استفاده کرده‌اند [۱۲، ۱۱]. دسته‌ای دیگر از تحقیقات از روش‌های پردازش سیگنال مانند تبدیل فوریه [۱۳] و تجزیه و تحلیل حالت تجربی به‌منظور شناسایی موثر لوازم برقی استفاده شده است.

به‌منظور رفع مشکلات موجود در روش‌های قبلی و همچنین افزایش دقت مدل‌ها علاقه به استفاده از روش‌های هوشمند در سال‌های اخیر بسیار افزایش یافته است. به‌طور مثال مراجع [۱۵، ۱۴] از روش‌های یادگیری عمیق در برنامه‌های پیش غیر مداخله‌گر بار استفاده کرده‌اند. همچنین مرجع [۱۶] یک مدل بهبودیافته از Long short-term memory (LSTM) ارائه داده است. باینکه روش‌های یادگیری عمیق نتایج قابل قبولی از خود به‌جا گذاشته‌اند [۱۷] اما همچنان نیاز به سخت‌افزارهای پیچیده به‌منظور آموزش این شبکه‌ها یک مشکل اساسی به حساب می‌آید. مرجع [۱۸] از مدل یادگیری ماشین k-nearest neighbors (KNN) برای تفکیک بار مصرفی استفاده می‌کند. مهم‌ترین مشکل این مرجع استفاده از ۹۰ درصد داده‌ها برای آموزش و ۱۰ درصد داده‌ها به‌منظور تست مدل است. این کار موجب افزایش بیش از حد دقت در مدل و در نتیجه ارائه دقت‌های غیر واقعی می‌شود. علاوه بر این شیوه ارائه شده توسط این مرجع ۵۰ درصد خطا را در تشخیص لوازم الکتریکی نشان می‌دهد. مرجع [۱۹] نیز یک روش پیش غیر مداخله‌گر بار بر اساس منحنی‌های ولتاژ - جریان و مدل KNN ارائه داده است. بررسی تعداد کم لوازم خانگی و پیچیدگی روش استخراج ویژگی را می‌توان مهم‌ترین مشکلات این روش بیان کرد.

با توجه به‌مرور انجام‌شده بر روی روش‌های پیش غیر مداخله‌گر بار می‌توان موارد زیر را به‌عنوان مهم‌ترین مشکلات موجود در روش‌های پیش غیر مداخله‌گر بار نام برد:

۱. نیاز به سخت‌افزارهای پیچیده و قوی به‌منظور آموزش روش‌های هوشمند مختلف (به‌خصوص روش‌های یادگیری عمیق).





۲. عدم تامین امنیت و حفظ حریم خصوصی ساکنان منازل مسکونی به دلیل نیاز به جابه‌جایی داده‌های توان با نرخ نمونه‌برداری بالا (امکان انجام حملات سایبری و دستیابی افراد متخاصم به داده‌های کنترلر هوشمند وجود دارد).

۳. ایجاد مشکلات مختلف برای شبکه اینترنت به دلیل ایجاد کلان داده و نیاز به جابه‌جایی داده با نرخ بالا.


۴. عدم دسترسی لحظه‌ای به اطلاعات بارهای مصرفی به دلیل نیاز به انتقال به مرکز پایش.


با توجه به موارد فوق می‌توان بیان کرد که ارائه راهکارهای جدید به‌منظور پایش غیر مداخله‌گر بار بسیار اهمیت دارد. از این‌رو در این مقاله یک روش پایش غیر مداخله‌گر بار بر اساس استخراج ماتریس ویژگی از سیگنال فرکانس لحظه‌ای به‌دست‌آمده از سیگنال توان مصرفی لوازم‌خانگی به‌منظور افزایش دقت مدل یادگیری ماشین نزدیک‌ترین همسایه^۲ ارائه شده است. مدل KNN یک مدل کلاسیک است که به دلیل پیچیدگی‌های زیاد و تفاوت بسیار کم داده‌های لوازم‌خانگی از دقت مناسبی برای استفاده در مسائل پایش غیر مداخله‌گر بار برخوردار نیست. اما مهم‌ترین ویژگی KNN سرعت بسیار بالا در آموزش و همچنین نیاز نداشتن به سخت‌افزار پیچیده برای آموزش است. به همین دلیل با افزایش دقت مدل KNN می‌توان آن را به‌طور مستقیم بر روی کنترلرهای هوشمند^۳ پیاده‌سازی کرد.

برای استخراج ویژگی در این مقاله ابتدا فرکانس لحظه‌ای سیگنال توان با استفاده از تبدیل هیلبرت استخراج شده و سپس ماتریس ویژگی که شامل مقادیر RMS، MEAN، DIFFERENCE و MAX است از سیگنال فرکانس لحظه‌ای استخراج می‌شود. این کار برای تمامی لوازم‌خانگی موجود در دیتابیس مورد استفاده انجام خواهد شد. استخراج ماتریس ویژگی برای شرایط مختلف نویز نیز تکرار خواهد شد تا مدل KNN همزمان با داده‌های بدون نویز و با نویز آموزش ببیند. در این صورت در زمانی که داده‌های توان نویزی شوند تاثیر چندانی بر روی خروجی مدل نخواهد داشت. روش ارائه شده با استفاده از دیتابیس دسترسی آزاد A dataset for energy monitoring through building electricity disaggregation (EMBED)^۴ مورد بررسی قرار گرفته است. نتایج بررسی به‌خوبی نشان می‌دهند که دقت مدل KNN در زمان استفاده از روش استخراج ویژگی ارائه شده دقت به‌مراتب مناسب‌تری نسبت به زمان استفاده از روش‌های استخراج ویژگی دیر دارد. علاوه بر این دقت روش ارائه شده با دقت روش یادگیری ماشین درخت دسته‌بندی^۵ نیز مقایسه شده است. نتایج این مقایسه نیز عملکرد بهتر مدل KNN را نسبت به مدل CT نشان می‌دهد.

۲- شرح مشکل

همان‌طور که بیان شده مراجع متفاوتی از جمله [۲۰، ۱۶-۲۱] از مدل‌های مختلف یادگیری عمیق به‌منظور بهبود عملکرد برنامه‌های پایش غیر مداخله‌گر بار استفاده کرده‌اند. با وجود اینکه نتایج این مدل‌ها بهبود قابل‌ملاحظه‌ای در دقت برنامه‌های پایش غیر مداخله‌گر بار را نشان می‌دهد اما همچنان مهم‌ترین چالش این روش‌ها زمان و حجم سخت‌افزاری مورد نیاز برای آموزش است. مراجع مختلفی از جمله مرجع [۲۲] بیان کرده‌اند که حجم سخت‌افزار مورد نیاز برای آموزش روش‌های یادگیری عمیق بسیار زیاد است. در این مطالعه نیز ابتدا به بررسی تفاوت سطح سخت‌افزاری مورد نیاز برای آموزش بین مدل معروف یادگیری عمیق یعنی مدل LSTM^۶ و مدل KNN پیشنهادی پرداخته شده است. شکل (۱) مقادیر متوسط مصرف CPU و RAM برای آموزش مدل LSTM و KNN را که در مدت‌زمان صد ثانیه نمونه‌برداری شده است را نشان می‌دهد. همان‌طور که مشخص است مدل LSTM حدود ۳۶ درصد حجم CPU بیشتری برای آموزش نیاز دارد. علاوه بر این مدت‌زمان آموزش مدل LSTM می‌تواند تا چند صد برابر مدل KNN افزایش پیدا کند. با توجه به این بررسی می‌توان بیان کرد که استفاده از مدل LSTM به‌خصوص در سطح یک شهر بزرگ با داده‌های بسیار زیاد می‌تواند چالشی جدی به وجود آورد. در نهایت لازم به ذکر است که برای انجام این آزمایش از زبان برنامه نویسی پایتون و کتابخانه Psutil این زبان برنامه نویسی استفاده شده است.





شکل (۱): مقایسه سخت‌افزار موردنیاز برای آموزش مدل KNN و LSTM

۳- روش پایش غیر مداخله‌گر بار پیشنهادی

۳-۱- تبدیل هیلبرت و فرکانس لحظه‌ای

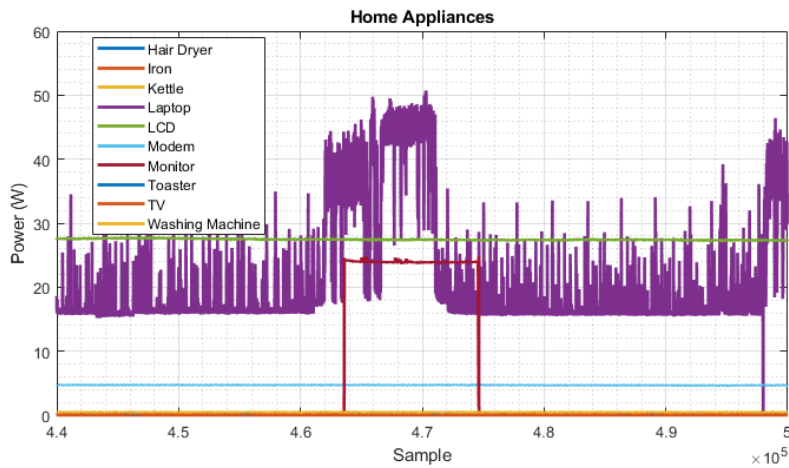
در سال‌های اخیر مراجع مختلفی از جمله [۲۳، ۲۴] اقدام به استفاده از تبدیل هیلبرت و فرکانس لحظه‌ای در برنامه‌های حفاظت از سیستم قدرت کرده‌اند. اما هدف اصلی این مقاله استفاده از فرکانس لحظه‌ای در برنامه‌های پایش غیر مداخله‌گر بار و استخراج ویژگی از این سیگنال است. بر اساس موارد بیان شده در مراجع [۲۳، ۲۴] می‌توان بیان کرد که برای به دست آوردن فرکانس لحظه‌ای لازم است ابتدا از سیگنال پایه (در این مقاله سیگنال توان لوازم خانگی) تبدیل هیلبرت گرفته شود. تبدیل هیلبرت برای داده‌های پیوسته از رابطه (۱) به دست می‌آید [۲۵].

$$H[X(t)] = \tilde{x}(t) = \pi^{-1} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (1)$$

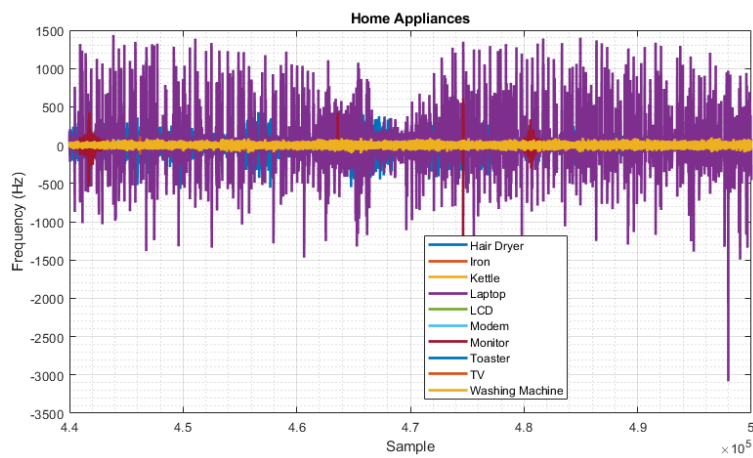
کاملاً مشخص است که رابطه (۱) مناسب استفاده در داده‌های پیوسته است. برای استفاده از تبدیل هیلبرت برای داده‌های گسسته باید از الگوریتم ارائه شده در مرجع [۲۶] استفاده کرد. در این الگوریتم ابتدا داده‌های گسسته خود را به کمک تبدیل فوریه سریع به فضای دامنه و فرکانس منتقل می‌کنیم. بعد از تبدیل سیگنال پایه، اعداد مختلف را در دامنه و فرکانس ضرب می‌کنیم. برای دستیابی به تبدیل هیلبرت این مرحله شامل ضرب در یک تابع همگون با مقدار ثابت عمودی است. در نهایت به منظور برگشت به حالت دامنه و زمان از تابع معکوس تبدیل فوریه استفاده می‌شود. در نهایت بعد از اعمال تبدیل هیلبرت به سیگنال فرکانس لحظه‌ای می‌تواند از رابطه (۲) محاسبه شود [۲۳، ۲۴].

$$IF = \frac{F_s}{2\pi} \times \text{diff}(\text{angle}(\bar{X}(t))) \quad (2)$$

که در آن F_s فرکانس نمونه‌برداری، $\bar{X}(t)$ سیگنال به‌دست‌آمده از تبدیل هیلبرت و در نهایت IF سیگنال فرکانس لحظه‌ای است. شکل (۲) داده‌های توان نمونه‌برداری شده از هریک از انواع لوازم خانگی را نشان می‌دهد. همچنین شکل (۳) فرکانس لحظه‌ای به‌دست‌آمده از این داده‌های توان را نشان می‌دهد. همان‌طور که از شکل (۲) مشخص است ویژگی‌های داده‌های توان چند نمونه از لوازم خانگی موجود در دیتابیس مورد استفاده بسیار به هم نزدیک هستند. اما با توجه به شکل (۳) می‌توان دریافت که سیگنال فرکانس لحظه‌ای به‌دست‌آمده موجب شده تا لوازم متفاوت ویژگی متفاوت تری نسبت به هم داشته باشند.



شکل (۲): داده‌های توان به دست آمده برای انواع لوازم خانگی



شکل (۳): فرکانس لحظه‌ای به دست آمده برای انواع لوازم خانگی

۲-۳- محاسبه ماتریس ویژگی

همان‌طور که بیان شد این فصل از سیگنال فرکانس لحظه‌ای توان به منظور محاسبه ماتریس ویژگی استفاده می‌کند. ماتریس ویژگی شامل مقدار Mean, RMS, Difference و مقدار ماکزیمم در هر پنجره سیگنال است. به منظور محاسبه Mean, RMS, Difference و مقدار ماکزیمم می‌توان از روابط (۳) تا (۶) استفاده کرد.


$$Mean = \frac{abs(IF)}{lentgh(IF)} \quad (۳)$$

$$RMS = \sqrt{\sum_{i=n}^N \frac{IF^2}{N}} \quad (۴)$$

$$Difference = \sum_{i=n}^N (IF(i) - IF(i-1)) \quad (۵)$$

$$Max = \max(IF) \quad (۶)$$

در نهایت ماتریس ویژگی بر اساس رابطه (۷) تشکیل خواهد شد. از این ماتریس به منظور آموزش مدل KNN پیشنهادی که در قسمت بعد ارائه خواهد شد استفاده می‌شود.

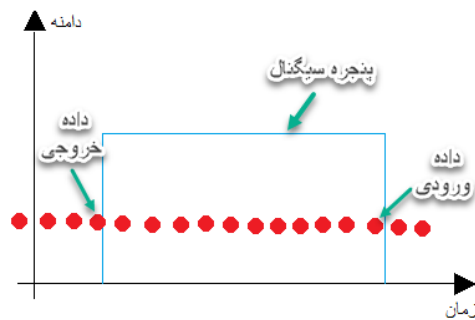


$$\text{Feature Matrix} = \begin{bmatrix} \text{Mean} \\ \text{RMS} \\ \text{Diff} \\ \text{Max} \end{bmatrix} \quad (7)$$

برای استخراج ویژگی در طول زمان و همچنین اضافه کردن قابلیت تشخیص بر خط لوازم‌خانگی در این مقاله از یک پنجره سیگنال مطابق شکل (۴) استفاده می‌شود. طول این پنجره سیگنال بر اساس رابطه (۸) محاسبه می‌شود [۲۷].

$$\text{windows length} = \frac{F_s}{F_f} \quad (8)$$


که در آن F_s فرکانس نمونه‌برداری و F_f فرکانس پایه سیستم است.



شکل (۴): پنجره سیگنال

۳-۳- روابط مدل KNN

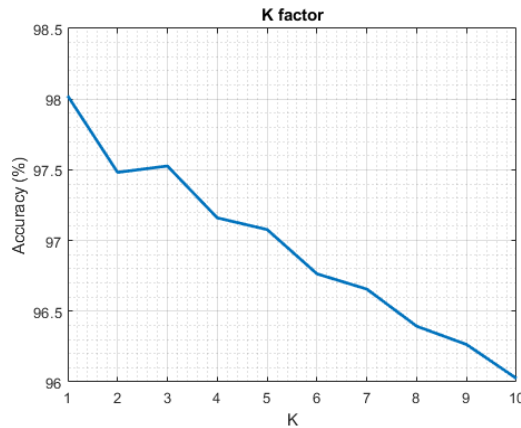
همان‌طور که بیان شد مدل KNN یک روش دسته‌بندی کلاسیک است که از نظر مدت‌زمان آموزش و همچنین سخت‌افزار موردنیاز بسیار بهینه‌تر از مدل LSTM است. مدل KNN با وجود عملکردی ساده در بسیاری از مسائل می‌تواند موثر واقع شود [۲۸]. اساس کار الگوریتم KNN به این شکل است که هر نمونه جدید را بر اساس نوع اکثریت نزدیک‌ترین نمونه در همسایگی نمونه جدید طبقه می‌کند. عملکرد این الگوریتم به شدت به معیارهای فاصله برای شناسایی نزدیک‌ترین همسایه (یا دسته‌ای از همسایه‌ها) بستگی دارد. برای محاسبه فاصله داده‌ها از Euclidean metrics استفاده می‌شود. شکل (۵) به خوبی تعریف درستی از فاصله Euclidean را نشان می‌دهد [۲۹]. همچنین این فاصله می‌تواند توسط رابطه (۹) محاسبه شود.



شکل (۵): نحوه محاسبه فاصله Euclidean در مدل KNN

$$\text{Euclidean distance}(d) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (9)$$

مدل KNN دارای یک پارامتر تنظیمی (k) است. میزان k تعیین می‌کند که مدل KNN برای دسته‌بندی درست باید چه تعداد از همسایه‌های نقطه جدید را در نظر بگیرد. به‌منظور محاسبه دقیق مقدار k در این مقاله مدل KNN با مقادیر k مختلف آموزش داده‌شده و میزان دقت برای هر کدام محاسبه شده است. شکل (۶) تغییرات دقت مدل را به ازای مقادیر k مختلف نشان می‌دهد. همان‌طور که از این شکل مشخص است در زمانی که مقدار k برابر ۱ قرار داده‌شده میزان دقت مدل KNN به بیشترین حالت خود یعنی کمی بیشتر از ۹۸ درصد رسیده است.



شکل (۶): تغییرات مقدار دقت مدل KNN بر اساس مقادیر مختلف k

۳-۴- الگوریتم روش استخراج ویژگی و تست مدل KNN

شکل (۷) الگوریتم استخراج ماتریس ویژگی و آموزش مدل KNN را نشان می‌دهد. همان‌طور که از این شکل مشخص است، ابتدا از توان هر دستگاه خانگی نمونه‌برداری می‌شود. سپس از سیگنال توان به‌دست‌آمده تبدیل هیلبرت گرفته‌شده و در ادامه با استفاده از رابطه (۲) مقدار IF به دست خواهد آمد. در ادامه ماتریس ویژگی‌ها برای هر پنجره سیگنال استخراج‌شده و در یک دیتابیس ذخیره خواهد شد. از ۸۰ درصد داده‌های این دیتابیس برای آموزش مدل KNN و ۲۰ درصد داده‌ها برای تست این مدل استفاده‌شده است. درنهایت بعد از اعمال داده‌های تست لوازم‌خانگی تشخیص داده‌شده و عملکرد مدل موردبررسی قرار خواهد گرفت. به‌منظور بررسی دقت مدل KNN از دو پارامتر مقایسه‌ای معمول در بررسی دقت روش‌های دسته‌بندی یعنی Accuracy و F1-Score استفاده می‌کنیم. مقدار این دو پارامتر از روابط (۱۰) و (۱۱) قابل محاسبه است [۵].

$$\text{Accuracy} = \frac{\text{Number of correctly classified samples}}{\text{Total number of samples}} \times 100 \quad (10)$$

$$F1 = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (11)$$

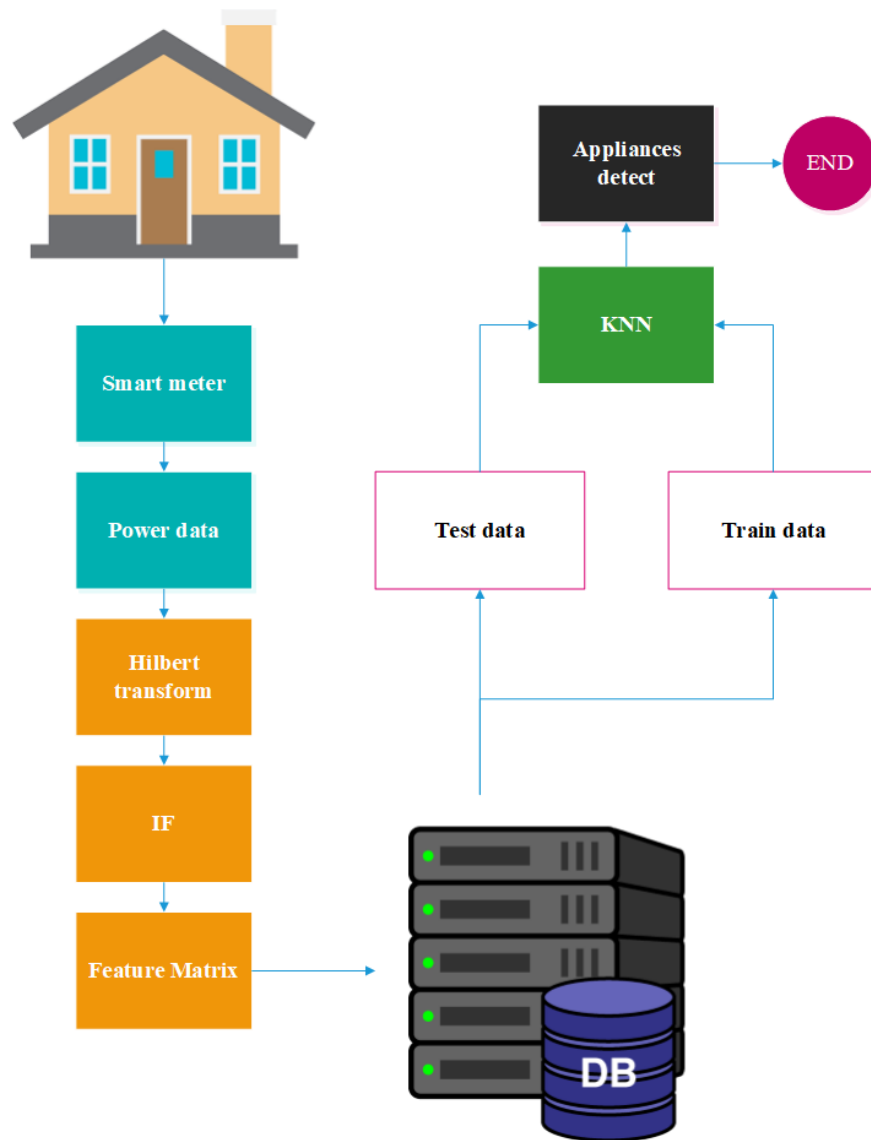
که مقادیر Precision و Recall از روابط (۱۲) و (۱۳) به دست می‌آید [۵].

$$\text{Precision} = \frac{TP}{TP + FP} \quad (12)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (13)$$

که در آن TP تعداد نمونه‌های true positive، FP تعداد نمونه‌های false positive و FN تعداد نمونه‌های false negative است.





شکل (۷): الگوریتم استخراج ماتریس ویژگی و آموزش مدل KNN

۴- نتایج شبیه‌سازی

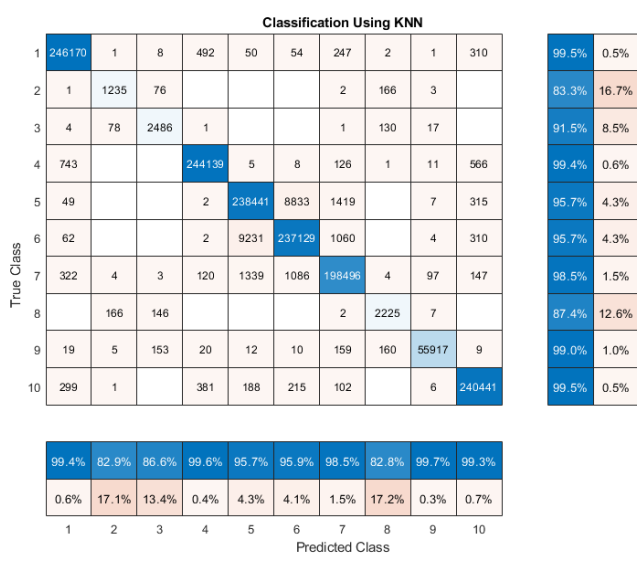
۴-۱- دیتابیس مورد استفاده

به منظور ارزیابی روش ارائه شده از یک مجموعه داده کنتور هوشمند واقعی با دسترسی آزاد تحت عنوان EMBED ارائه شده در مراجع [۳۰، ۱] استفاده شده است. داده‌های موجود در این دیتابیس شامل موارد مختلفی از لوازم خانگی می‌شود که از سه آپارتمان مختلف نمونه‌برداری شده است. در ابتدا شبیه‌سازی‌ها به صورت مجزا بر روی داده‌های موجود در هر آپارتمان به صورت مجزا انجام می‌شود. سپس شبیه‌سازی‌های انجام شده یک‌بار دیگر با داده‌های تجمیع شده انجام خواهد شد. لازم به ذکر است برای پیاده‌سازی استخراج ماتریس ویژگی ارائه شده و همچنین آموزش مدل KNN از نرم‌افزار متلب استفاده شده است. کلیه شبیه‌سازی‌ها در یک سیستم با پردازنده Intel core i7 و RAM 16 GB انجام شده است.

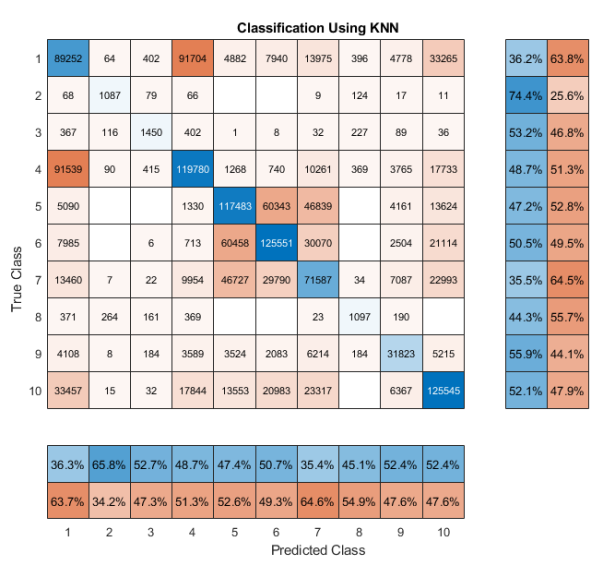
۴-۲- بررسی نتایج در آپارتمان شماره ۱

شکل (۸) ماتریس درهم‌ریختگی^۷ مربوط به مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی (شکل (۸-الف))، مدل KNN آموزش دیده فقط با ویژگی RMS به دست آمده از سیگنال اصلی توان (شکل (۸-ب)) و مدل CT آموزش دیده فقط با ویژگی RMS

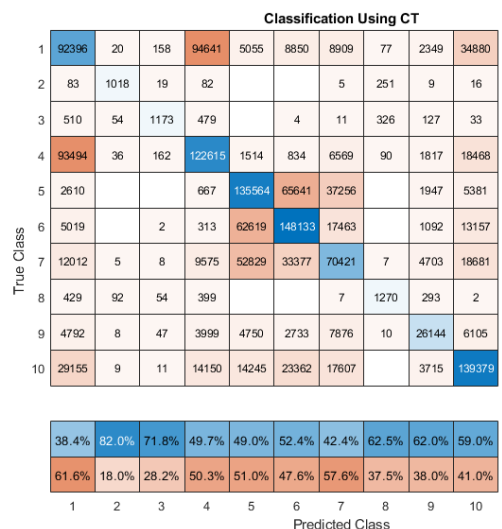
به دست آمده از سیگنال اصلی توان (شکل ۸-ج)) را نشان می دهد. CM به ماتریسی گفته می شود که در آن عملکرد الگوریتم های مربوطه را در بحث دسته بندی را نشان می دهند. در مباحث هوش مصنوعی از این جدول برای تعیین مقدار شاخص های ارزیابی مانند Precision و Recall استفاده می شود. دقت عبارت است از اینکه "چه میزان از نمونه های انتخاب شده اند" دلالت دارند. همان طور که از شکل (۸) مشخص است، مدل KNN آموزش دیده با ماتریس ویژگی عملکرد به مراتب بهتری نسبت به دو مدل دیگر دارد. علاوه بر این بر اساس شکل های (۹) و (۱۰) می توان بیان کرد مدل KNN آموزش دیده با ماتریس ویژگی ارائه شده از مقدار Accuracy و F1-Score بالاتری در هر یک از لوازم خانگی موجود در آپارتمان شماره ۱ مجموعه داده مورد بررسی برخوردار است. در نهایت مقدار Accuracy کلی برای مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی برابر با ۹۸/۰۲۳۱٪ شده است. همچنین این مقدار برای مدل KNN دوم و CT به ترتیب برابر با ۴۵/۷۵۷۸٪ و ۴۹/۳۳۰۶٪ شده است. همان طور که مشخص است در صورت استفاده از ماتریس ویژگی پیشنهادی برای آموزش مدل KNN میزان دقت این مدل به طور قابل ملاحظه ای افزایش پیدا خواهد کرد.



(الف)




(ب)




(ج)


شکل (۸): CM مدل های مختلف آموزش دیده مربوط به داده های آپارتمان شماره ۱، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی



(الف)

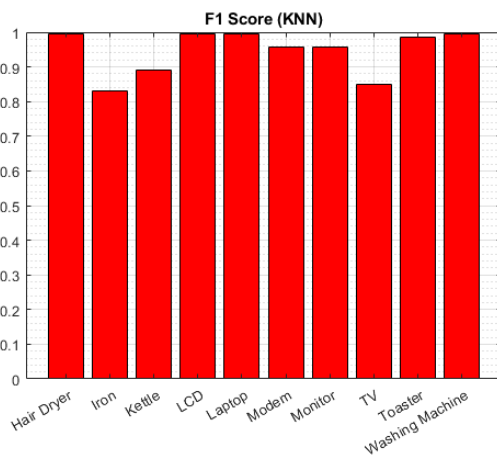


(ب)




(ج)

شکل (۹): مقدار Accuracy مدل‌های مختلف آموزش دیده مربوط به داده‌های آپارتمان شماره ۱، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی




(الف)



(ب)





(ج)

شکل (۱۰): مقدار F1-Score مدل های مختلف آموزش دیده مربوط به داده های آپارتمان شماره ۱، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی

۴-۳- بررسی نتایج در آپارتمان شماره ۲

شکل (۱۱) CM مربوط به مدل های مختلف استفاده را نشان می دهد. همان طور که از شکل (۱۱) مشخص است، مدل KNN آموزش دیده با ماتریس ویژگی عملکرد به مراتب بهتری نسبت به دو مدل دیگر دارد. علاوه بر این مقدار Accuracy و F1-Score هر مدل در شکل های (۱۲) و (۱۳) نشان داده شده است. بر این اساس می توان بیان کرد مدل KNN آموزش دیده با ماتریس ویژگی ارائه شده از مقدار Accuracy و F1-Score بالاتری در هر یک از لوازم خانگی موجود در آپارتمان شماره ۲ دارد. در نهایت مقدار Accuracy کلی برای مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی برابر با ۹۶/۲۷۲۴٪ شده است. همچنین این مقدار برای مدل KNN دوم و CT به ترتیب برابر با ۳۳/۷۴۲۱٪ و ۳۷/۱۲۸۱٪ شده است.

True Class	1	2	3	5	6	7	8	9	10	11	12	Accuracy	F1-Score
1	119273	342	265	5	457	303	2952	632	17	282	682	95.3%	4.7%
2	172	411437	5491		5492	1435	879	2058		42	1668	96.0%	4.0%
3	190	5157	402833	946	5331	2140	801	2401	5	39	2907	95.3%	4.7%
5	3		1106	120504	409	5477	8	8		2	80	94.4%	5.6%
6	201	4924	5546	429	359743	3512	525	1631	2	154	5633	94.1%	5.9%
7	140	1706	2526	5950	3505	411261	655	45		105	2038	96.1%	3.9%
8	1227	1546	1626	13	684	1606	238203	3540	216	177	1128	95.3%	4.7%
9	499	1618	2360	8	1588	67	2835	417317		320	378	97.7%	2.3%
10	24		4				238		2479	1	1	90.2%	9.8%
11	202	72	76	4	191	136	273	321	1	403124	125	99.7%	0.3%
12	292	1640	2993	86	5552	1334	513	366		35	350395	96.5%	3.5%

Predicted Class	1	2	3	5	6	7	8	9	10	11	12
1	97.6%	96.0%	94.8%	94.2%	93.9%	96.3%	96.1%	97.4%	91.1%	99.7%	96.0%
2	2.4%	4.0%	5.2%	5.8%	6.1%	3.7%	3.9%	2.6%	8.9%	0.3%	4.0%

(الف)

True Class	1	2	3	5	6	7	8	9	10	11	12	Accuracy	F1-Score
1	16346	5534	9535	10639	12326	34408	11466	8456	315	10556	6296	13.0%	87.0%
2	5450	158104	26814	3	46036	36529	19327	55938		37537	43773	36.8%	63.2%
3	9388	26504	142758	6172	44982	39415	18061	18591	17	40349	76265	33.8%	66.2%
5	10381	4	6337	57211	3660	37030	4671	88	201	5145	3047	44.8%	55.2%
6	12328	45654	44693	3686	72542	47601	19966	51764	22	39558	43672	19.0%	81.0%
7	34228	36505	39502	36773	47386	134463	23017	2379	185	32607	40765	31.4%	68.6%
8	9799	19293	17906	4615	19484	22827	87809	26345	9867	18463	13176	35.2%	64.8%
9	8731	54994	18667	80	52118	2392	26525	199559		44253	20097	46.7%	53.3%
10	53		17	195	17	150	216		2026	65	11	73.7%	26.3%
11	8962	31592	34099	4769	33427	29929	16269	34542	83	181676	28688	45.0%	55.0%
12	6311	43910	75684	3040	44276	40387	13516	20146	6	33993	81880	22.5%	77.5%

Predicted Class	1	2	3	5	6	7	8	9	10	11	12
1	13.4%	37.5%	34.3%	45.0%	19.3%	31.6%	36.5%	47.8%	15.9%	40.9%	22.9%
2	86.6%	62.5%	65.7%	55.0%	80.7%	68.4%	63.5%	52.2%	84.1%	59.1%	77.1%

(ب)



Classification Using CT

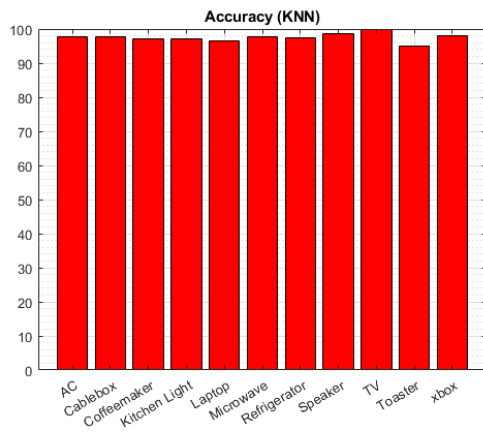
1	15519	7165	9926	11495	9925	38657	10907	10011	13	7819	4330	12.3%	87.7%
2	2967	211424	18341	5	35254	36750	8168	54788		31589	28852	49.4%	50.6%
3	7134	33916	174745	4684	34213	31815	9966	21171	9	32571	72348	41.4%	58.6%
5	8126	6	6287	67582	1788	37951	2435	7	13	2422	1099	52.9%	47.1%
6	9500	59705	47521	3430	67894	48339	12233	59160	2	34621	38714	17.8%	82.2%
7	31209	46997	40552	40762	38640	130705	17400	1676	19	23341	36942	35.2%	64.8%
8	9191	24518	18120	4968	16442	24533	95847	31220	50	14837	9913	38.4%	61.6%
9	4658	69447	10281	87	41670	1198	14298	237849	1	39250	7542	55.8%	44.2%
10	42		7	260	6	195	345			1753	48	65.9%	34.1%
11	8320	47975	42536	5364	36446	33669	13862	50190	65	138156	28797	34.1%	65.9%
12	4093	56799	86514	2876	35365	35666	6099	21263		29131	86731	23.8%	76.2%

15.4%	37.9%	38.4%	47.8%	21.4%	34.3%	50.0%	48.8%	91.1%	39.1%	27.5%
84.6%	62.1%	61.6%	52.2%	78.6%	65.7%	50.0%	51.2%	8.9%	60.9%	72.5%
1	2	3	5	6	7	8	9	10	11	12


Predicted Class

(ج)

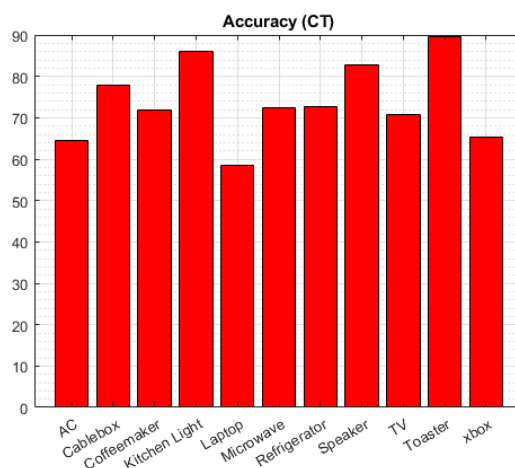
شکل (۱۱): CM مدل های مختلف آموزش دیده مربوط به داده های آپارتمان شماره ۲، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی



(الف)




(ب)




(ج)

شکل (۱۲): مقدار Accuracy مدل های مختلف آموزش دیده مربوط به داده های آپارتمان شماره ۲، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی






(الف)



(ب)




(ج)

شکل (۱۳): مقدار F1-Score مدل‌های مختلف آموزش دیده مربوط به داده‌های آپارتمان شماره ۲، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی


۴-۴- بررسی نتایج در آپارتمان شماره ۳

شکل (۱۴) CM مربوط به مدل‌های مختلف استفاده را نشان می‌دهد. همان‌طور که از شکل (۱۴) مشخص است، مدل KNN آموزش دیده با ماتریس ویژگی عملکرد به مراتب بهتری نسبت به دو مدل دیگر دارد. علاوه بر این مقدار Accuracy و F1-Score هر مدل در شکل‌های (۱۵) و (۱۶) نشان داده شده است. بر این اساس می‌توان بیان کرد مدل KNN آموزش دیده با ماتریس ویژگی ارائه شده از مقدار Accuracy و F1-Score بالاتری در هر یک از لوازم‌خانگی موجود در آپارتمان شماره ۳ دارد. در نهایت مقدار Accuracy کلی برای مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی برابر با ۹۵/۳۱۴٪ شده است. همچنین این مقدار برای مدل KNN دوم و CT به ترتیب برابر با ۳۸/۰۳۶۰٪ و ۴۱/۱۵۳۹٪ شده است.

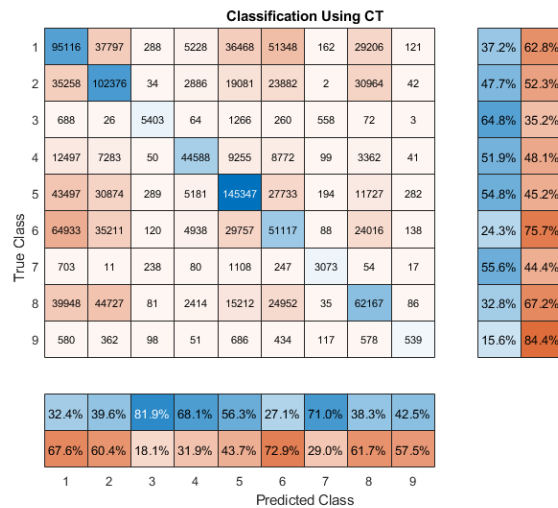




(الف)




(ب)

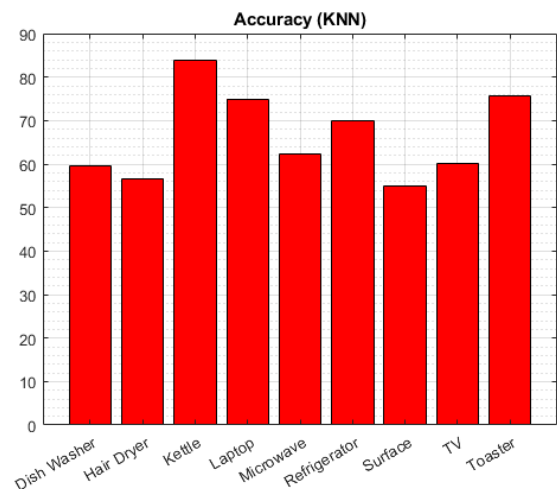


(ج)

شکل (۱۴): CM مدل‌های مختلف آموزش‌دیده مربوط به داده‌های آپارتمان شماره ۳، الف) مدل KNN آموزش‌دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش‌دیده تنها با یک ویژگی، ج) مدل CT آموزش‌دیده تنها با یک ویژگی

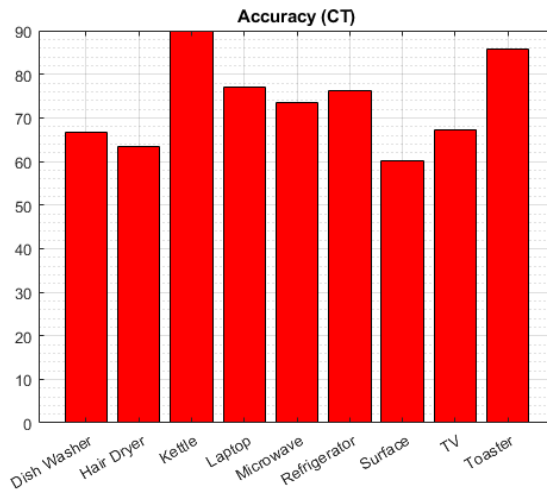


(الف)



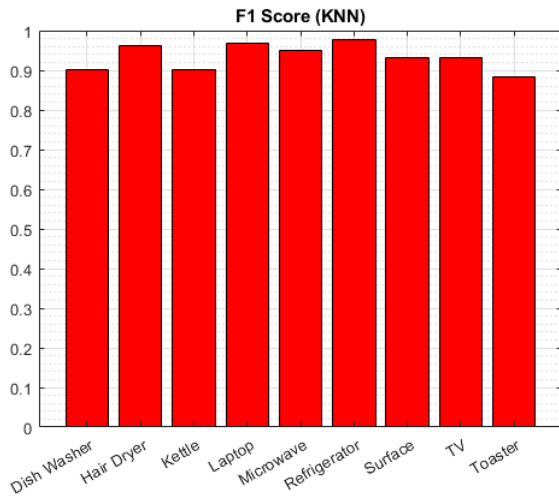
(ب)






(ج)


شکل (۱۵): مقدار Accuracy مدل‌های مختلف آموزش دیده مربوط به داده‌های آپارتمان شماره ۳، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی



(الف)




(ب)



(ج)

شکل (۱۶): مقدار F1-Score مدل‌های مختلف آموزش دیده مربوط به داده‌های آپارتمان شماره ۳، الف) مدل KNN آموزش دیده با ماتریس ویژگی پیشنهادی، ب) مدل KNN آموزش دیده تنها با یک ویژگی، ج) مدل CT آموزش دیده تنها با یک ویژگی





۵- مقایسه با روش‌های دیگر استخراج ویژگی

همانطور که بیان شد، در روش‌های پیش غیر مداخله‌گر بار استخراج ویژگی یک بخش مهم است [۶]. مطالعات مختلفی بر روی استخراج ویژگی انجام شده است. روش‌ها ویژگی‌های مد نظر خود را از سیگنال‌های ولتاژ و جریان استخراج می‌کنند. استخراج ویژگی از ولتاژ و جریان به شدت به نرخ نمونه‌برداری بستگی دارد [۳۱]. جدول (۱) یک مقایسه بین روش استخراج ویژگی مورد استفاده در این مقاله و روش‌های موجود را نشان می‌دهد. این دسته بندی بر اساس اطلاعات ارائه شده در مرجع [۶] انجام شده است. به عنوان مثال برخی از مراجع موجود (به جز مراجع [۳۹، ۴۰]) از توان اکتیو و راکتیو برای استخراج ویژگی استفاده می‌کنند. همچنین این مراجع تغییرات در توان اکتیو و راکتیو را به عنوان ویژگی اصلی در نظر می‌گیرند. با توجه به اینکه رفتار برخی از لوازم خانگی شباهت زیادی به هم دارد برخی از این مراجع مانند مراجع [۳۳-۳۵] از یک ویژگی سوم (Macro) نیز استفاده کرده‌اند. با توجه به جدول ۱ می‌توان بیان کرد که روش‌های پردازش سیگنال توان اکتیو از محنی V-I نیز به منظور استخراج ویژگی استفاده شده است. مرجع [۳۹] علاوه بر استفاده از تغییرات توان اکتیو از مقدار MAX و RMS توان اکتیو نیز به عنوان دو ویژگی اضافه استفاده می‌کند. مرجع [۴۰] از تغییرات توان اکتیو و مقدار ضریب توان به عنوان ویژگی لوازم خانگی استفاده می‌کند. کلیه این مراجع همانطور که در مقدمه نیز ذکر شد به علت رفتار یکسان برخی از لوازم خانگی دچار ضعف آشکاری هستند. این در صورتی است که در روش ارائه شده در این مقاله به دلیل استفاده از فرکانس لحظه ای بدست آمده از توان اکتیو و همچنین ماتریس ویژگی این رفتار یکسان تاثیر چندانی در دقت مدل‌های یادگیری ماشین مورد استفاده نخواهد داشت.

جدول (۱): مقایسه بین روش‌های موجود استخراج ویژگی و روش ارائه شده در این مقاله


مرجع	سیگنال استخراج ویژگی	$\Delta P, \Delta Q$	RMS, MEAN, MAX	Macro	FFT	Shape	STFT	WT
[۳۲]	P-Q	✓	×	×	×	×	×	×
[۳۳]	P-Q	✓	×	Shape	✓	×	×	×
[۳۴]	P-Q	✓	×	Duration	✓	×	×	×
[۳۵]	P-Q	✓	×	Shape	✓	×	×	×
[۳۶]	P-Q	✓	×	×	×	×	✓	×
[۱۳]	P-Q	✓	×	×	×	×	✓	×
[۳۷]	P-Q	✓	×	×	×	×	✓	×
[۳۸]	P-Q	✓	×	✓	×	×	×	×
[۳۹]	V-I, P	ΔP	RMS, MAX	×	×	×	×	×
[۴۰]	V-I, P	✓, PF	×	×	×	×	✓	×
[۴۲، ۴۱]	P-Q	✓	×	×	×	×	×	✓
[۴۳]	P-Q	✓	×	×	×	×	×	✓
[۴۴]	P-Q	✓	×	×	×	×	×	✓
مقاله ارائه شده	IF(P)	$\Delta IF(P)$	RMS, MEAN, MAX	×	Hilbert	×	×	×

۶- نتیجه‌گیری

در این مقاله، یک روش پیش غیر مداخله‌گر بار بر اساس استخراج ماتریس ویژگی از سیگنال فرکانس لحظه‌ای به‌دست‌آمده از سیگنال توان لوازم‌خانگی ارائه شده است. مهم‌ترین ویژگی روش ارائه شده افزایش دقت مدل KNN کلاسیک است. روش ارائه شده با استفاده از داده‌های دسترس‌پذیر آزاد EMBED که شامل اطلاعات مصرف سه آپارتمان مختلف است مورد تجزیه و تحلیل قرار گرفته است. نتایج شبیه‌سازی‌های ارائه شده به خوبی نشان می‌دهد که مدل KNN آموزش‌دیده شده با ماتریس ویژگی به‌دست‌آمده از سیگنال فرکانس لحظه‌ای در آپارتمان شماره ۱ حدود ۵۳/۳۱۹۳٪ بهبود داشته است. این مقدار بهبود برای آپارتمان شماره ۲ و آپارتمان شماره ۳ به ترتیب ۶۴/۹۵۱۴٪ و ۶۰/۰۹۴٪ شده است.




- [1] M. Afzalan, F. Jazizadeh, and J. Wang, "Self-configuring event detection in electricity monitoring for human-building interaction," *Energy and Buildings*, vol. 187, pp. 95-109, 2019, doi: 10.1016/j.enbuild.2019.01.036.
- [2] R. Gopinath, M. Kumar, C. P. C. Joshua, and K. Srinivas, "Energy management using non-intrusive load monitoring techniques—State-of-the-art and future research directions," *Sustainable Cities and Society*, vol. 62, p. 102411, 2020, doi: 10.1016/j.scs.2020.102411.
- [3] J. Froehlich, E. Larson, S. Gupta, G. Cohn, M. Reynolds, and S. Patel, "Disaggregated end-use energy sensing for the smart grid," *IEEE pervasive computing*, vol. 10, no. 1, pp. 28-39, 2010, doi: 10.1109/mprv.2010.74.
- [4] R. G. Pratt *et al.*, "The smart grid: An estimation of the energy and CO2 benefits," Pacific Northwest National Lab.(PNNL), Richland, WA (United States), 2010, doi: 10.2172/971103.
- [5] X. Yang, L. Yang, X. Xiao, Y. Wang, and S. Zhang, "An adaptive lightweight seq2subseq model for non-intrusive load monitoring," *IET Generation, Transmission & Distribution*, vol. 16, no. 18, pp. 3706-3718, 2022, doi: 10.1049/gtd2.12558.
- [6] N. Sadeghianpourhamami, J. Ruyssinck, D. Deschrijver, T. Dhaene, and C. Develder, "Comprehensive feature selection for appliance classification in NILM," *Energy and Buildings*, vol. 151, pp. 98-106, 2017, doi: 10.1016/j.enbuild.2017.06.042.
- [7] G. Cui, B. Liu, W. Luan, and Y. Yu, "Estimation of target appliance electricity consumption using background filtering," *IEEE Transactions on Smart Grid*, vol. 10, no. 6, pp. 5920-5929, 2019, doi: 10.1109/tsg.2019.2892841.
- [8] H. Liu, *Non-intrusive Load Monitoring: Theory, Technologies and Applications*. Springer Nature, 2019, doi: 10.1007/978-981-15-1860-7.
- [9] B. M. Mulinari *et al.*, "A new set of steady-state and transient features for power signature analysis based on VI trajectory," in *2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)*, 2019: IEEE, pp. 1-6, doi: 10.1109/isgt-la.2019.8895360.
- [10] A. Faustine, N. H. Mvungi, S. Kaijage, and K. Michael, "A survey on non-intrusive load monitoring methodologies and techniques for energy disaggregation problem," *arXiv preprint arXiv:1703.00785*, 2017, doi: 10.48550/arXiv.1703.00785.
- [11] W. Lee, G. Fung, H. Lam, F. Chan, and M. Lucente, "Exploration on load signatures," in *International conference on electrical Engineering (ICEE)*, 2004, vol. 152.
- [12] T. Hassan, F. Javed, and N. Arshad, "An empirical investigation of VI trajectory based load signatures for non-intrusive load monitoring," *IEEE Transactions on Smart Grid*, vol. 5, no. 2, pp. 870-878, 2013, doi: 10.1109/pesgm.2014.6938824.
- [13] C. Laughman *et al.*, "Power signature analysis," *IEEE power and energy magazine*, vol. 1, no. 2, pp. 56-63, 2003, doi: 10.1109/mpae.2003.1192027.
- [14] A. M. Ahmed, Y. Zhang, and F. Eliassen, "Generative adversarial networks and transfer learning for non-intrusive load monitoring in smart grids," in *2020 IEEE international conference on communications, control, and computing technologies for smart grids (SmartGridComm)*, 2020: IEEE, pp. 1-7, doi: 10.1109/smartgridcomm47815.2020.9302933.
- [15] J. Kelly and W. Knottenbelt, "Neural nilm: Deep neural networks applied to energy disaggregation," in *Proceedings of the 2nd ACM international conference on embedded systems for energy-efficient built environments*, 2015, pp. 55-64, doi: 10.1145/2821650.2821672.
- [16] H. Wu and H. Liu, "Non-intrusive load transient identification based on multivariate LSTM neural network and time series data augmentation," *Sustainable Energy, Grids and Networks*, vol. 27, p. 100490, 2021, doi: 10.1016/j.segan.2021.100490.
- [17] Y. Zhang *et al.*, "A novel non-intrusive load monitoring method based on ResNet-seq2seq networks for energy disaggregation of distributed energy resources integrated with residential houses," *Applied Energy*, vol. 349, p. 121703, 2023, doi: 10.1016/j.apenergy.2023.121703.
- [18] M. M. R. Khan, M. A. B. Siddique, and S. Sakib, "Non-intrusive electrical appliances monitoring and classification using K-nearest neighbors," in *2019 2nd International Conference on Innovation in Engineering and Technology (ICIET)*, 2019: IEEE, pp. 1-5, doi: 10.1109/iciet48527.2019.9290671.





- [19] M. Hu, S. Tao, H. Fan, X. Li, Y. Sun, and J. Sun, "Non-intrusive load monitoring for residential appliances with ultra-sparse sample and real-time computation," *Sensors*, vol. 21, no. 16, p. 5366, 2021, doi: 10.3390/s21165366.
- [20] H. Liu, C. Yu, H. Wu, C. Chen, and Z. Wang, "An improved non-intrusive load disaggregation algorithm and its application," *Sustainable cities and society*, vol. 53, p. 101918, 2020, doi: 10.1016/j.scs.2019.101918.
- [21] A. Harell, S. Makonin, and I. V. Bajić, "Wavenilm: A causal neural network for power disaggregation from the complex power signal," in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 8335-8339, doi: 10.1109/icassp.2019.8682543.
- [22] S. Salehimehr, B. Taheri, and M. Sedighizadeh, "Short-term load forecasting in smart grids using artificial intelligence methods: A survey," *The Journal of Engineering*, vol. 2022, no. 12, pp. 1133-1142, 2022, doi: 10.1049/tje2.12183.
- [23] H. Abniki, M. Hajati Samsi, B. Taheri, and S. A. Hosseini, "High Impedance Fault Detection in Power Transmission Lines Using Hilbert Transform and Instantaneous Frequency," *International Journal of Industrial Electronics Control and Optimization*, vol. 6, no. 1, pp. 1-11, 2023, doi: 10.22111/ieco.2022.42814.1439.
- [24] A. A. Nazari, F. Razavi, and A. Fakharian, "A novel method to differentiate internal faults and inrush current in power transformers using adaptive sampling and Hilbert transform," *Iranian Electric Industry Journal of Quality and Productivity*, vol. 11, no. 1, pp. 97-110, 2022.
- [25] M. Feldman, "Hilbert transform in vibration analysis," *Mechanical systems and signal processing*, vol. 25, no. 3, pp. 735-802, 2011, doi: 10.1002/9781119991656.
- [26] B. Taheri, S. Salehimehr, F. Razavi, and M. Parpaei, "Detection of power swing and fault occurring simultaneously with power swing using instantaneous frequency," *Energy Systems*, vol. 11, no. 2, pp. 491-514, 2020, doi: 10.1007/s12667-018-00320-0.
- [27] B. Taheri, S. A. Hosseini, M. Sedighizadeh, and M. Khatibi, "A moving window numerical distance protection based on flat-top signal windowing," *Arabian Journal for Science and Engineering*, vol. 47, no. 11, pp. 14249-14266, 2022, doi: 10.1007/s13369-022-06709-5.
- [28] G. Guo, H. Wang, D. Bell, Y. Bi, and K. Greer, "KNN model-based approach in classification," in *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE: OTM Confederated International Conferences, CoopIS, DOA, and ODBASE 2003, Catania, Sicily, Italy, November 3-7, 2003. Proceedings*, 2003: Springer, pp. 986-996, doi: 10.1007/978-3-540-39964-3_62.
- [29] L. Huang, T. Song, and T. Jiang, "Linear regression combined KNN algorithm to identify latent defects for imbalance data of ICs," *Microelectronics Journal*, vol. 131, p. 105641, 2023, doi: 10.1016/j.mejo.2022.105641.
- [30] F. Jazizadeh, M. Afzalan, B. Becerik-Gerber, and L. Soibelman, "EMBED: A dataset for energy monitoring through building electricity disaggregation," in *Proceedings of the Ninth International Conference on Future Energy Systems*, 2018, pp. 230-235, doi: 10.1145/3208903.3208939.
- [31] M. Zeifman and K. Roth, "Nonintrusive appliance load monitoring: Review and outlook," *IEEE transactions on Consumer Electronics*, vol. 57, no. 1, pp. 76-84, 2011, doi: 10.1109/icce.2011.5722560.
- [32] S. Drenker and A. Kader, "Nonintrusive monitoring of electric loads," *IEEE Computer Applications in Power*, vol. 12, no. 4, pp. 47-51, 1999, doi: 10.1109/67.795138.
- [33] A. I. Cole and A. Albicki, "Data extraction for effective non-intrusive identification of residential power loads," in *IMTC/98 Conference Proceedings. IEEE Instrumentation and Measurement Technology Conference. Where Instrumentation is Going (Cat. No. 98CH36222)*, 1998, vol. 2: IEEE, pp. 812-815, doi: 10.1109/imtc.1998.676838.
- [34] F. Sultanem, "Using appliance signatures for monitoring residential loads at meter panel level," *IEEE Transactions on Power Delivery*, vol. 6, no. 4, pp. 1380-1385, 1991, doi: 10.1109/61.97667.
- [35] L. K. Norford and S. B. Leeb, "Non-intrusive electrical load monitoring in commercial buildings based on steady-state and transient load-detection algorithms," *Energy and Buildings*, vol. 24, no. 1, pp. 51-64, 1996, doi: 10.1016/0378-7788(95)00958-2.
- [36] D. Srinivasan, W. Ng, and A. Liew, "Neural-network-based signature recognition for harmonic source identification," *IEEE transactions on power delivery*, vol. 21, no. 1, pp. 398-405, 2005, doi: 10.1109/tpwr.2005.852370.



- [37] M. E. Berges, E. Goldman, H. S. Matthews, and L. Soibelman, "Enhancing electricity audits in residential buildings with nonintrusive load monitoring," *Journal of industrial ecology*, vol. 14 ,no. 5, pp. 844-858, 2010, doi: 10.1111/j.1530-9290.2010.00280.x.
- [38] M. Dong, P. C. Meira, W. Xu, and C. Chung, "Non-intrusive signature extraction for major residential loads," *IEEE Transactions on Smart Grid*, vol. 4, no. 3, pp. 1421-1430, 2013, doi: 10.1109/tsg.2013.2245926.
- [39] A. G. Ruzzelli, C. Nicolas, A. Schoofs ,and G. M. O'Hare, "Real-time recognition and profiling of appliances through a single electricity sensor," in *2010 7th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks (SECON)*, 2010: IEEE, pp. 1-9, doi: 10.1109/secon.2010.5508244.
- [40] M. B. Figueiredo, A. De Almeida, and B. Ribeiro, "An experimental study on electrical signature identification of non-intrusive load monitoring (nilm) systems," in *Adaptive and Natural Computing Algorithms: 10th International Conference, ICANNGA 2011, Ljubljana, Slovenia, April 14-16, 2011, Proceedings, Part II 10*, 2011: Springer, pp. 31-40, doi: 10.1007/978-3-642-20267-4_4.
- [41] J. M. Gillis, S. M. Alshareef, and W. G. Morsi, "Nonintrusive load monitoring using wavelet design and machine learning," *IEEE Transactions on Smart Grid*, vol ,^v.no. 1, pp. 320-328, 2015, doi: 10.1109/tsg.2015.2428706.
- [42] J. M. Gillis and W. G. Morsi, "Non-intrusive load monitoring using semi-supervised machine learning and wavelet design," *IEEE Transactions on Smart Grid*, vol. 8, no. 6, pp. 2648-2655, 2016, doi: 10.1109/tsg.2016.2532885.
- [43] S. M. Tabatabaei, S. Dick, and W. Xu, "Toward non-intrusive load monitoring via multi-label classification," *IEEE Transactions on Smart Grid*, vol. 8, no. 1, pp. 26-40, 2016, doi: 10.1109/tsg.2016.2584581.
- [44] H.-H. Chang, "Non-intrusive demand monitoring and load identification for energy management systems based on transient feature analyses," *Energies*, vol. 5, no. 11, pp. 4569-4589, 2012, doi: 10.3390/en5114569.

زیرنویس‌ها

1. Non-intrusive load monitoring (NILM)
2. k-nearest neighbors (KNN)
3. Smart meter
4. A dataset for energy monitoring through building electricity disaggregation (EMBED)
5. Classification trees (CT)
6. Long short-term memory (LSTM)
7. Confusion Matrix (CM)

