

ارائه یک مدل دومرحله‌ای جهت تشخیص تقلب در شبکه توزیع به وسیله یادگیری عمیق

مهدی عمادالاسلامی^۱ حسن مجیدی^۲ محمودرضا حقی‌فام^۳

۱- دانشجوی دکتری- دانشکده مهندسی برق و کامپیوتر- دانشگاه تربیت مدرس- تهران- ایران

mahdi.emadaleslami@modares.ac.ir

۲- دانش آموخته کارشناسی ارشد- دانشکده مهندسی برق و کامپیوتر- دانشگاه تربیت مدرس- تهران- ایران

hassan.majidi20@modares.ac.ir

۳- استاد- دانشکده مهندسی برق و کامپیوتر- دانشگاه تربیت مدرس- تهران- ایران

haghifam@modares.ac.ir

چکیده: شرکت‌های برق از دیرباز به دنبال شناسایی و کاهش موارد برق‌دزدی به‌عنوان اصلی‌ترین بخش تلفات غیر فنی بوده‌اند. از طرفی شناسایی این موارد لزوماً از طریق بازرسی مشترکین ممکن است که شرکت‌های برق به دلایلی نظیر هزینه بالا، تعداد مشترکین و ... به دنبال کاهش محدوده بازرسی به موارد با احتمال برق‌دزدی بیشتر هستند. یکی از راهکارهای کاهش محدوده بازرسی، استفاده از روش‌های هوش مصنوعی است، اما چالش مهمی که در این حوزه وجود دارد عدم تعادل در نسبت مشترکین مشکوک به مشترکین عادی است که منجر به عملکرد ضعیف الگوریتم‌ها می‌شود. در این مقاله باهدف غلبه بر این چالش با فرض اینکه بتوان رفتار مشترک مشکوک را به‌صورت تابع ریاضی از رفتار مشترک عادی بیان کرد، در مرحله اول الگوی مصرف مشترکین عادی و مشکوک دسته‌بندی شده است؛ سپس یک شبکه عمیق اولیه جهت مدل‌سازی رفتار مشترکین مشکوک آموزش داده شده است. در ادامه به کمک شبکه آموزش داده شده اولیه، سناریوهای محتمل برق‌دزدی به ازای مشترکین عادی پیش‌بینی شده است. در نهایت یک شبکه عمیق ثانویه جهت تفکیک مشترکین عادی و مشکوک آموزش داده شده است. بررسی مدل پیشنهادی به ازای سناریوهای مختلف و مقایسه با تحقیقات پیشین بر روی مجموعه داده واقعی با بیش از ۶۰۰۰ مشترک عملکرد بالای آن را نشان می‌دهد.

واژه‌های کلیدی: برق‌دزدی، تشخیص تقلب، دسته‌بندی مشترکین مشکوک، پیش‌بینی الگو مصرف، یادگیری عمیق

نوع مقاله: پژوهشی

DOI: 10.52547/jiaeee.19.1.13

تاریخ ارسال مقاله: ۱۴۰۰/۰۲/۲۳

تاریخ پذیرش مشروط مقاله: ۱۴۰۰/۰۵/۲۵

تاریخ پذیرش مقاله: ۱۴۰۰/۰۶/۱۶

نام نویسنده‌ی مسئول: دکتر محمودرضا حقی‌فام

نشانی نویسنده‌ی مسئول: تهران - خیابان جلال آل احمد - دانشگاه تربیت مدرس - دانشکده‌ی برق و کامپیوتر

۱- مقدمه

تلفات شبکه توزیع به صورت تفاوت بین انرژی الکتریکی ورودی به شبکه توزیع از منابع داخلی، شبکه بالادست یا پایین دست و انرژی الکتریکی خروجی از آن به صورت درصدی برای بازه زمانی مشخص تعریف می‌شود. این تلفات به طور معمول به دو گروه تلفات فنی و غیرفنی تقسیم می‌شوند [۲۱،۱]. امروزه تلفات غیر فنی یکی از معضلات اصلی صنعت برق به شمار می‌رود به طوری که مشترکین متخلف سعی می‌کنند در عین مصرف زیاد انرژی، اطلاعات ثبت شده توسط کنتورها را به کمک روش‌های متعددی دستکاری شده کنند و سعی دارند با انتقال موارد پرمصرف و غیرمجاز به زمان‌هایی با تعرفه پایین تر، مصرفی کمتر از مصرف واقعی را گزارش کنند. از طرفی شناسایی این موارد لزوماً از طریق بازرسی مشترکین ممکن است اما به دلایل متعددی نظیر هزینه بالا، زیاد بودن تعداد مشترکین، پیچیدگی شبکه و ... امکان بازرسی و صحت‌سنجی اطلاعات مصرف تمامی مشترکین و مشخص کردن مصرف آن‌ها وجود ندارد و شرکت‌های برق عموماً اطلاعات محدودی از مشترکین برق دزد دارند و هموار به دنبال محدود کردن محدوده بازرسی به موارد با احتمال برق دزدی بیشتر هستند. از جمله راهکارهای کاهش محدوده بازرسی، استفاده از روش‌های مبتنی بر تخمین حالت، نظریه بازی^۱ و هوش مصنوعی به منظور استخراج الگوریتمی جهت شناسایی موارد برق دزدی و عادی است [۱]. روش‌های مبتنی بر تخمین حالت توانایی شناسایی موارد برق دزدی را ندارد و در بهترین حالت منطقه برق دزدی را با احتمال بالا تشخیص می‌دهند علاوه بر این، هزینه تجهیزات و بسترهای مخابراتی آن‌ها زیاد است [۲، ۳]. روش‌های مبتنی بر نظریه بازی به دلایلی نظیر پیچیدگی مدل‌سازی رفتار مشترکین، تحلیل و بررسی اطلاعات مصرف و الگوهای بار مشترکین عملکرد خوبی از خود نشان نمی‌دهند. موارد مذکور به عنوان چالش‌های اصلی در تشخیص برق دزدی، سبب روی آوری به علمی مانند داده کاوی و هوش مصنوعی شده است و اهمیت این موضوع در گذر زمان و با پیشرفت تجهیزات سخت‌افزاری نه تنها کم‌رنگ تر نشده بلکه امروزه بیشتر مطالعات صورت گرفته در مسائل تحلیل بار، شناسایی برق دزدی و دیگر مسائل حوزه برق با تمرکز بر روش‌های داده کاوی و هوش مصنوعی است. اما چالش مهمی که در حوزه هوش مصنوعی وجود دارد، مسئله عدم تعادل در نسبت داده‌های صحیح و غلط است به طوری که اگر این نسبت در نمونه‌های جمع‌آوری شده رعایت نشود، عملکرد الگوریتم‌های آموزش داده شده بر اساس نمونه‌های جمع‌آوری شده قابل اتکا نیست و سبب کشیدگی الگوریتم به سمت داده‌های صحیح می‌شود. همین امر تشخیص برق دزدی را که به صورت طبیعی یک مسئله نامتعادل از جهت نسبت مشترکین سارق به مشترکین عادی است را دشوار می‌کند و منجر به عملکرد ضعیف الگوریتم‌های آموزش داده شده در این حوزه می‌شود.

یکی از روش‌های غلبه بر مسئله عدم تعادل داده‌ها، پیش‌بینی و تخمین رفتار مشترکین مشکوک با فرض اینکه بتوان رفتار یک مشترک مشکوک را به صورت توابع ریاضی از رفتار مشترکین عادی بیان کرد، است. در آن صورت می‌توان این انتظار را داشت که با تکیه بر این توابع ریاضی، تعداد نمونه‌های مورد نیاز جهت آموزش الگوریتم را افزایش داد و بر مسئله عدم تعادل چیره شد. در این تحقیق با تکیه بر این فرض که رابطه بین مصرف واقعی و مصرف ثبت شده به صورت ریاضی قابل بیان است، در ابتدا سعی شده الگوی مصرف مشترکین عادی و مشکوک به کمک الگوریتم خوشه‌بندی K-means دسته‌بندی شده است. سپس این رابطه به صورت ریاضی مدل شده و یک شبکه عصبی عمیق DNN جهت مدل‌سازی رفتار مشترکین مشکوک آموزش داده شده است.

به طور خلاصه نوآوری‌های این مقاله به شرح زیر است:

- استفاده از اطلاعات مصرف، آماری و معیشتی مشترکین در تحلیل رفتار مشترکین
- استخراج الگوهای مختلف مصرف مشترکین مشکوک و عادی با در نظر گرفتن تعداد صحیح دسته‌ها
- ارائه یک شبکه عمیق جهت مدل‌سازی و تخمین الگوی رفتاری مشترکین مشکوک
- ارائه یک شبکه عمیق ثانویه جهت دسته‌بندی مشترکین
- بررسی سناریوهای مختلف تشخیص برق دزدی

۱-۱- پیشینه تحقیق

به طور خلاصه روش‌های تشخیص برق دزدی را براساس تحقیقات اخیر می‌توان به دو دسته سخت‌افزاری و نرم‌افزاری تقسیم کرد. روش نرم‌افزاری عموماً براساس تخمین حالت، تئوری بازی یا الگوریتم‌های دسته‌بندی انجام می‌شود [۴]. با توجه به اینکه روش پیشنهادی در این تحقیق یک روش نرم‌افزاری مبتنی بر دسته‌بندی است. بنابراین، در ادامه پژوهش‌هایی که به وسیله بهره‌گیری از داده‌های کنتور هوشمند سعی در تشخیص مشترکین متقلب را دارند مورد بررسی قرار می‌گیرند. نویسندگان در [۴] ابتدا مجموعه انرژی مصرفی کنتورهای مشترکین هر منطقه و میزان تلفات خط را محاسبه کرده‌اند و با مقایسه انرژی مصرف شده کل و میزان انرژی گزارش شده توسط کنتور ترانس توزیع هر منطقه، مناطقی که دارای اختلاف زیادی هستند را به عنوان مناطق مستعد برق دزدی انتخاب کرده‌اند. سپس با فرض این نکته که الگوی رفتار مشترکین مشکوک را می‌توان به صورت تابعی از رفتار مشترکین عادی هر منطقه دانست، به کمک تعریف تابع‌های متعددی از الگو مشترکین عادی یک مجموعه داده ساختی ایجاد کرد. در نهایت به کمک دیتاست ساختگی^۲ و اطلاعات مصرف مشترکین عادی، یک الگوریتم دسته‌بندی مبتنی بر ماشین بردار پشتیبان^۳ (SVM) را آموزش می‌دهد و به کمک آن اگر مشترکی برای تعداد بار مشخصی به عنوان دزد توسط سیستم شناسایی شود، سیستم آن را به عنوان یک

لجستیک^{۱۱} آموزش داده‌شده‌اند و بهترین آن‌ها بر اساس دقت بالا در پیش‌بینی داده‌های آزمون و زمان کمتر در مرحله آموزش انتخاب شده و بر اساس این الگوریتم به تشخیص برق‌دزدی در مشترکین جدید پرداخته شده است. در نهایت یک لیست رده‌بندی شده از احتمال وجود برق‌دزدی ارائه شده است. نویسندگان در مرجع [۱۱] با بیان اینکه مصرف نادرست عموماً به سه روش دستکاری شده، تخریب و هک کنتور باهدف ارسال مصرف کمتر از مقدار واقعی و یا عدم ارسال اطلاعات مصرف انجام می‌شود. به منظور شبیه‌سازی الگوهای مخرب در شبکه به ایجاد یک مجموعه داده از نمونه‌های مخرب بر اساس الگوی مصرف مشترکین عادی پرداخته‌اند و به ازای هر مشترک عادی، ۳ نمونه الگو مخرب ایجاد کرده‌اند. در نهایت یک سیستم SVM براساس این اطلاعات جهت دسته‌بندی و شناسایی برق‌دزدی آموزش داده شده است. معیارهای دقت^{۱۲}، نرخ شناسایی غلط داده صحیح^{۱۳} جهت سنجش الگوریتم استفاده شده است. در [۱۲] نویسندگان به کمک توابع ریاضی مرجع [۴] و انتخاب الگوی مصرف تعدادی از مشترکین به ایجاد یک مجموعه داده مصنوعی پرداخته‌اند و با تکیه بر این نکته که رفتار مصرفی یک مشترک دارای سیکل هفتگی است و صرفاً تفاوت‌های روزانه دارد، به آموزش یک شبکه عمیق به ازای هر روز جهت استخراج ویژگی‌های توصیف‌کننده رفتار مصرفی مشترکین پرداخته‌اند. سپس با تکیه بر ویژگی‌های استخراج شده به آموزش یک شبکه عمیق جهت شناسایی مشترکین متخلف پرداخته‌اند و به وسیله معیارهای DR، FPR، و DR الگوریتم را مورد سنجش قرار داده‌اند. نوآوری معرفی شده در این مقاله استفاده از دو شبکه عمیق به منظور استخراج ویژگی‌ها و پیش‌بینی نتایج و همچنین استفاده از آموزش نیمه نظارت یافته است که امکان استفاده از مجموعه داده‌های بدون برچسب در فرایند آموزش شبکه را فراهم می‌کند. مرجع [۱۳] ابتدا الگوریتم CNN را با توجه به توانایی‌اش در تحلیل تصاویر جهت شناسایی تفاوت‌ها در ساعات مختلف و روزهای مختلف مورد استفاده قرار داده است. سپس الگوریتم جنگل‌های تصادفی^{۱۴} به کمک ویژگی‌های استخراج شده جهت تشخیص مشترکین متخلف استفاده شده است. پارامترهای الگوریتم جنگل‌های تصادفی توسط الگوریتم جست‌وجو شبکه^{۱۵} تنظیم شده‌اند. معیارهای ماتریس اغتشاش^{۱۶} و ROC^{۱۷} جهت ارزیابی استفاده شده است. مرجع [۱۸] به ارائه یک روش مبتنی بر XG Boost پرداخته است؛ به این منظور به ازای هر مشترک ۶ سناریوی برق‌دزدی ایجاد کرده است و به وسیله سناریوهای ایجاد شده و الگوهای مصرف عادی مشترکین یک مدل آموزش داده است. براساس نتایج روش پیشنهادی در این مقاله نسبت به الگوریتم درخت تصمیم و SVM عملکرد بهتری دارد و در مقابل عدم تعادل داده‌ها مقاوم است. مرجع [۲۰] با ارائه الگوریتمی دومرحله‌ای ابتدا مصرف برق مشترکین را در هر دوره مصرف به مفهومی تحت عنوان رأی تبدیل کرده است. در مرحله اول، الگوی مصرف مشترکین را با توجه به پیشینه و کمینه مصرف برق در هر دوره به سه دسته کلی الگوی

کاندید برق‌دزدی جهت بازدید حضوری معرفی می‌کند. مرجع [۵] از یک روش بالا به پایین مبتنی بر درخت تصمیم^{۱۸} و SVM جهت شناسایی برق‌دزدی استفاده کرده است. درخت تصمیم در ابتدا میزان مصرف مورد انتظار یک مشترک را بر اساس اطلاعاتی نظیر تعداد تجهیزات خانه، افراد خانه، دمای بیرون و ... تخمین می‌زند و سپس این مقدار به همراه دیگر ویژگی‌های ورودی درخت تصمیم جهت آموزش SVM استفاده می‌شوند. در نهایت SVM تشخیص می‌دهد الگوی مصرف یک مشترک عادی است یا غیرعادی. مرجع [۶] از الگوریتم خوشه‌بندی مسیر بهینه جنگل^{۱۹} جهت دسته‌بندی الگو مصرف مشترکین استفاده کرده است. پس از دسته‌بندی مشترکین به گروه‌های مختلف اگر فاصله هر پروفیل بار از مرکز خوشه از آستانه‌ای مشخص بیشتر باشد، مشترک مورد نظر به عنوان یک ناهنجاری شناسایی می‌شود. مرجع [۷] به جای دسته‌بندی تمامی پروفیل‌های بار مشترکین به دسته‌بندی پروفیل بار، هر مشترک پرداخت است، روش پیشنهادی این مقاله به این صورت است که برای هر مشترک پروفیل مصرف عادی و غیرعادی را به دست می‌آورد و سپس یک سیستم دسته‌بندی را بر اساس مجموعه‌ای از منحنی بار عادی و غیرعادی مشترکین آموزش می‌دهد. مطالعه موردی صورت‌گرفته در مقاله نشان می‌دهد روش ارائه شده دقت بیشتری نسبت به SVM دارد. مرجع [۸] براساس تبدیل فوریه^{۲۰} اطلاعات مصرف مشترکین در یک بازه یک‌ساله را به حوزه فرکانس می‌برد و با الگوبرداری از ویژگی‌های یک بازه زمانی مرجع (به عنوان مثال ماه اول سال) که در ابتدا فرایند تحلیل توسط کاربر تعیین شده است، به بررسی بازه زمانی مورد آزمایش (به عنوان مثال ماه ششم سال) پرداخته است و تشخیص می‌دهد که الگو مصرف عادی یا غیرعادی است. روش پیشنهادی در این مقاله توانایی اجرا به صورت موازی برای چندین هزار مشترک را دارد. نویسندگان در مرجع [۹] با بیان اینکه مسئله برق‌دزدی یک مسئله غیرمتعادل از جهت تعداد مشترکین است، دو روش جهت غلبه بر مشکل غیر متعادل بودن نسبت داده‌ها بیان کرده و معایب هریک را بررسی کرده است. سپس اطلاعات مشترکین غیرعادی را به کمک الگوریتم نزدیک‌ترین همسایه^{۲۱} (KNN) دسته‌بندی می‌کند و از طریق هر دو مشترک که کمترین فاصله را نسبت به یکدیگر دارند، یک مشترک ساختگی بر اساس اختلاف فاصله آن‌ها ضربدر یک عدد تصادفی بین صفر و یک تولید می‌کند. بعد از تولید مجموعه داده ساختگی با توجه به ماهیت داده‌های انرژی که سری زمانی هستند، از ترکیب الگوریتم CNN^{۲۲}، LSTM^{۲۳} جهت ایجاد یک سیستم تشخیص برق‌دزدی استفاده می‌کند. مرجع [۱۰] به منظور شناسایی برق‌دزدی در سطح مشترکین صنعتی و تجاری اطلاعات مصرف مشترکین در یک بازه ۱۰ ساله به همراه اطلاعات جانبی که توصیف‌کننده ویژگی‌های جغرافیایی و فنی هر مشترک هستند را جمع‌آوری کرده است. سپس به کمک اطلاعات مشترکینی که حداقل یک‌بار بازرسی حضوری شده‌اند الگوریتم‌های متعددی از جمله XG Boost، KNN و رگرسیون

پیش‌بینی رفتارهای برق‌دزدی بر اساس مطالعه رفتارهای اجتماعی مشترکین و تحلیل منحنی مصرف آن‌ها داشته است. به‌طوری‌که در گذشته عموماً متخصصین با توجه به شناخت کلی از رفتارهای اجتماعی مشترکین مجموعه‌ای از معیارهای ساده جهت تفکیک مشترکین برق دزد و عادی را مطرح می‌کردند. اما امروزه با تغییر رفتار مصرفی مشترکین و تنوع زیاد در نوع و زمان مصرف امکان استفاده از معیارهای ساده در تفکیک مشترکین برق دزد و عادی وجود ندارد و لازم است که معیارهای پیچیده‌تری جهت تفکیک مورد استفاده قرار گیرد. یکی از روش‌های شناسایی این معیارها (با فرض اینکه بتوان رفتار یک مشترک برق دزد را به صورت تابع ریاضی از رفتار مشترکین عادی بیان کرد)، تخمین و استخراج این توابع ریاضی است که در آن صورت می‌توان انتظار داشت که با تکیه بر این توابع ریاضی، تعداد نمونه‌های مورد نیاز جهت آموزش الگوریتم افزایش یابد و بر مسئله عدم تعادل چیره شد. امروزه عمده مقالات مطرح شده در سطح جهانی تمرکز خود را بر پیش‌بینی توابع ریاضی جهت توصیف رفتار مشترکین برق دزد قرار داده‌اند، اما توابع ارائه شده توسط مقالات بعضاً بسیار ساده و صرفاً با تکیه بر تجربه بوده است و همین امر سبب می‌شود که توانایی پیش‌بینی تعداد محدودی از موارد برق‌دزدی را داشته باشند. مدل ارائه شده در این تحقیق باهدف پیش‌بینی و تخمین رفتار مشترکین مشکوک که به‌وسیله روش‌های سایبری و مبتنی بر داده مقدار مصرف خود را دستکاری شده کرده‌اند، طراحی شده است.

۳- مدل سازی مسئله

به‌طور کلی اگر اطلاعات مصرف واقعی یک مشترک و اطلاعات ارسال شده توسط کنتور به شرکت برق در یک بازه زمانی مشخص را در نظر بگیریم. میزان مصرفی واقعی با اختلاف ناچیزی که عموماً این اختلاف ناشی از خطای اندازه‌گیری کنتور است برابر با مقدار ارسال شده است اگر و فقط اگر مشترک در مصرف خود صالح و کنتور دستکاری شده نشده باشد و برعکس اگر مقدار ارسالی توسط یک مشترک برابر با مقدار مصرف واقعی‌اش نباشد، آنگاه این مشترک می‌تواند کاندید استفاده غیرمجاز باشد و در لیست بازرسی شرکت برق قرار بگیرد.

مسئله حائز اهمیت این است که عموماً اطلاعات مصرف واقعی مشترکین مشکوک که استفاده غیرمجاز آن‌ها توسط شرکت برق تأیید شده است وجود ندارد و تنها اطلاعات دستکاری شده آن‌ها موجود است. در نتیجه امکان سنجش و مقایسه این اطلاعات با مقادیر ارسالی وجود ندارد. اما با تکیه به آخرین بازرسی مشترکین مشکوک که در آن بازه اطلاعات ارسالی به صورت صحیح بوده است، می‌توان با بهره‌گیری از یک ماژول پیش‌بینی بار تحت عنوان $STLF$ میزان مصرف واقعی مشترک را در بازه مورد مطالعه بازسازی کرد و تخمین زد. این عمل در واقع این اصل را بیان می‌کند که اگر رفتار مشترک همانند گذشته بود، الگوی مصرف به چه صورت می‌شد. با توجه به اینکه مبحث

نرمال، غیر نرمال و الگوی پرمصرف تقسیم شده و مشترکین غیرعادی را بر اساس میزان رأی آن‌ها جهت بازرسی اولویت‌بندی می‌کند. در مرحله دوم مصرف برق هر مشترک با مشابه آن در سال قبل مقایسه می‌شود و بر اساس درصد کاهش، آن را به چهار دسته تقسیم می‌کند. روش ارائه شده به‌وسیله داده‌های مصرف ۳۰۰ مشترک در سه ناحیه مختلف از نظر سطح اقتصادی و معیشتی مورد بررسی و آزمایش قرار گرفته است.

۲- بیان مسئله

به‌طور کلی سارقان انرژی سعی می‌کنند در عین مصرف زیاد انرژی، اطلاعات ثبت شده توسط کنتورهای هوشمند را به کمک روش‌های سایبری، فیزیکی و داده‌ای که در جدول ۱ ذکر شده‌اند دستکاری شده کنند [۱۴].

از طرفی شناسایی این موارد لزوماً از طریق بازرسی مشترکین ممکن است و شرکت‌های برق همواره به دنبال محدود کردن محدوده بازرسی خود به مواردی با احتمال برق‌دزدی بیشتر هستند. یکی از راهکارهای کاهش محدوده بازرسی، استفاده از روش‌های مبتنی بر هوش مصنوعی است ولی چالش مهمی که در حوزه هوش مصنوعی وجود دارد، مسئله عدم تعادل در نسبت داده‌های مشترکین عادی و مشکوک است که منجر به عملکرد ضعیف الگوریتم‌های آموزش داده شده می‌شود.

جدول (۱): روش‌های مختلف برق‌دزدی

روش‌ها	نوع
<ul style="list-style-type: none"> دستکاری شده سیستم عامل/حافظه کنتور تغییر/مداخله در ارتباطات کنتور اشغال کردن ram/cpu سرقت اطلاعات ورود به کنتور از بین بردن یا مختل کردن شبکه ارتباطی کنتورها و مرکز داده 	سایبری
<ul style="list-style-type: none"> تخریب کنتور معکوس کردن اتصالات کنتور قطع کردن کنتور دور زدن کنتور به‌وسیله سیم 	فیزیکی
<ul style="list-style-type: none"> عدم ارسال اطلاعات مصرف یا ارسال مصرف صفر تغییر مقادیر انرژی اندازه‌گیری شده به صورت نسبی از کل انرژی مصرفی گزارش مصرف منفی (عمل کردن به صورت تولیدکننده) حذف انرژی مصرفی تجهیزات پرمصرف از اندازه‌گیری استفاده غیرمجاز از تعرفه 	داده

پیش‌بینی و تخمین رفتار مشترکین برق دزد به‌عنوان یکی از روش‌های قدیمی و قابل اتکا در بحث تشخیص برق‌دزدی، همواره سعی در

xmn : میزان مصرف واقعی مشترک m در ساعت n
 θnn : ضریب تأثیر ساعت n در مصرف ثبت شده m
 ymn : میزان مصرف ثبت شده مشترک m در زمان n

در این رابطه ضرایب θ مجهول و مقادیر x, y معلوم هستند. تعیین مجهولات در این رابطه با بزرگ‌تر شدن n پیچیده می‌شود و با توجه به غیرخطی بودن، حل آن بسیار سخت و بعضاً ناممکن است. یکی از راه‌های تخمین ماتریس ضرایب که بیان‌کننده رابطه بین x, y است، مدل‌سازی رابطه فوق به صورت یک مسئله رگرسیون چند متغیره و استفاده از یک شبکه عصبی عمیق جهت تخمین این ضرایب است؛ به طوری که در این شبکه عصبی مقادیر مصرف واقعی به عنوان ورودی و مقادیر ارسال شده توسط کنتور به عنوان خروجی در نظر گرفته می‌شوند و شبکه عصبی آموزش داده شده بر اساس نمونه‌های موجود بیانگر ضرایب مجهول θ است. مرحله مهمی که پیش از آموزش شبکه عصبی لازم است به آن پرداخته شود، تفکیک و بررسی الگوهای رفتاری متفاوت مشترکین عادی است. الگوی رفتاری یک مشترک در یک بازه زمانی لزوماً ثابت نیست و همواره دچار تغییر می‌شود؛ این تغییرات لزوماً بیانگر رفتار غیرعادی و نابهنجار نیستند بلکه ممکن است در اثر تغییر در نحو استفاده از تجهیزات، تغییر در میزان زمان حضور در منزل، تغییر عادات مصرفی و ... ایجاد شده باشند. عدم توجه به این تغییرات و تأثیر آن‌ها به طور یقین سبب خطای بسیار زیادی در تشخیص برق دزدی می‌شود و ممکن است حتی به اشتباه موارد صحیح و عادی به عنوان برق دزد شناسایی شوند. لذا لازم است در ابتدا الگوهای رفتاری متفاوت این مشترکین شناسایی و دسته‌بندی شوند.

یکی از روش‌های استخراج الگوهای مختلف مصرف با تکیه بر ویژگی‌های مختلف، استفاده از الگوریتم‌های خوشه‌بندی نظیر-K means است [۱۵]. مسئله مهمی که در استفاده از این الگوریتم وجود دارد، تعیین تعداد درست خوشه‌ها است. اگر تعداد آن‌ها به اندازه کافی بزرگ نباشد یا بیش از حد بزرگ باشد، امکان توصیف کامل و جامع رفتارهای مختلف جامعه مطالعاتی وجود ندارد و همواره لازم است که تعداد صحیح خوشه‌ها جهت توصیف مشترکین تعیین شود. یکی از معیارهای تعیین تعداد صحیح خوشه‌ها معیار Silhouette است. معیار Silhouette یکی از روش‌های ارزیابی خوشه‌بندی است که بر اساس تحلیل میزان پیوستگی و تفکیک‌پذیری خوشه‌ها میزان تعلق هر نمونه به خوشه‌ای که در آن قرار دارد را در مقایسه با خوشه‌های مجاور اندازه می‌گیرد. معیار Silhouette به کمک رابطه (۷) محاسبه می‌شود:

$$s(i) = \frac{b(i) - a(i)}{\max(b(i), a(i))} \quad (4)$$

در این رابطه $a(i)$ بیانگر میانگین فاصله یک نقطه از خوشه با نقاط دیگر آن خوشه است. $b(i)$ بیانگر حداقل میانگین فاصله یک نقطه با خوشه‌های دیگر است. با توجه به رابطه بالا مقدار این شاخص بین

پیش‌بینی بار یک فضای مطالعاتی متفاوت است، در این تحقیق از پرداختن به آن اجتناب شده و با فرض اینکه یک ماژول STLF با دقت قابل قبول در دسترس خواهد بود مقادیر مصرف مشترکین مشکوک در بازه زمانی مورد مطالعه تخمین زده شده‌اند. از اینجا به بعد منظور از مقدار واقعی مصرف، مقدار تخمین زده شده توسط ماژول STLF است. در صورتی که رابطه مقدار مصرف واقعی و ارسال شده را به صورت زیر در نظر بگیریم:

$$\vec{Y}_i = h(\vec{X}_i + \varepsilon) \quad (1)$$

در این فرمول بردار مصرف واقعی مشترک \vec{Y}_i بردار مصرف ارسالی مشترک \vec{X}_i و ε خطای ناشی از اندازه‌گیری کنتور یا ارسال اطلاعات است که بر اساس کلاس دقت اندازه‌گیری کنتور تعیین می‌شود و عموماً کمتر از ۲٪ خواهد بود. در نتیجه تابع $h(\vec{X}_i + \varepsilon)$ بیانگر رفتار مشترک است. به طوری که اگر مشترک در مصرف خود صالح و کنتور دستکاری شده نشده باشد، بیانگر یک رابطه یک‌به‌یک است و مقدار ارسالی برابر مقدار واقعی مصرف بعلاوه مقدار خطای کنتور در نظر گرفته می‌شود و برعکس اگر مقدار ارسالی توسط یک مشترک دستکاری شده باشد، یک رابطه غیرخطی است و بیانگر رفتار ریاضی مشترک مشکوک است. بر اساس مطالعه سناریوهای متعدد برق دزدی و با تکیه بر علم و تجربه مهندسی می‌توان انتظار داشت که حالت‌های ساده آن پیش‌بینی و تخمین زده شود. به عنوان مثال ساده‌ترین حالت این تابع با صرف نظر کردن از خطای کنتور و با توجه به اینکه هدف مشترکین برق دزد گزارش مقدار مصرف کمتر از مقدار واقعی است، به صورت رابطه ۲ قابل بیان است:

$$h(x) = \alpha x, 0 < \alpha < 1 \quad (2)$$

که در این رابطه ضریب α معادل میزان حریم بودن یک مشترک در گزارش مقدار مصرف است به طوری که اگر α برابر یک باشد یعنی مشترک صالح و اگر برابر صفر باشد به معنای عدم ارسال مقادیر مصرف است. به عنوان مثال α برابر ۰/۸ به این معناست که شرکت برق فقط ۸۰٪ مصرف واقعی را دریافت می‌کند و ۲۰٪ مصرف توسط مشترک به روش‌های مختلف ارسال نمی‌شود. دیگر حالت‌های ساده $h(x)$ در [۴] قابل مشاهده است.

نکته حائز اهمیت این است که تمامی حالات ممکن تابع $h(x)$ به خصوص حالت‌های پیچیده و غیرخطی آن قابل پیش‌بینی و تخمین با تکیه بر تجربه نیست؛ اما با فرض اینکه اطلاعات تعدادی از مشترکین مشکوک در دسترس است آنگاه رابطه $y=h(x)$ را می‌توان با کنار هم قرار دادن بردارهای \vec{X}_i و \vec{Y}_i مشترکین به صورت رابطه ماتریسی ۳ بیان کرد:

$$\begin{bmatrix} x_{1n} & \dots & x_{mn} \\ \dots & \dots & \dots \\ x_{1m} & \dots & x_{nm} \end{bmatrix} \begin{bmatrix} \theta_{11} & \dots & \theta_{1n} \\ \dots & \dots & \dots \\ \theta_{n1} & \dots & \theta_{nm} \end{bmatrix} = \begin{bmatrix} y_{1n} & \dots & y_{mn} \\ \dots & \dots & \dots \\ y_{1m} & \dots & y_{nm} \end{bmatrix} \quad (3)$$

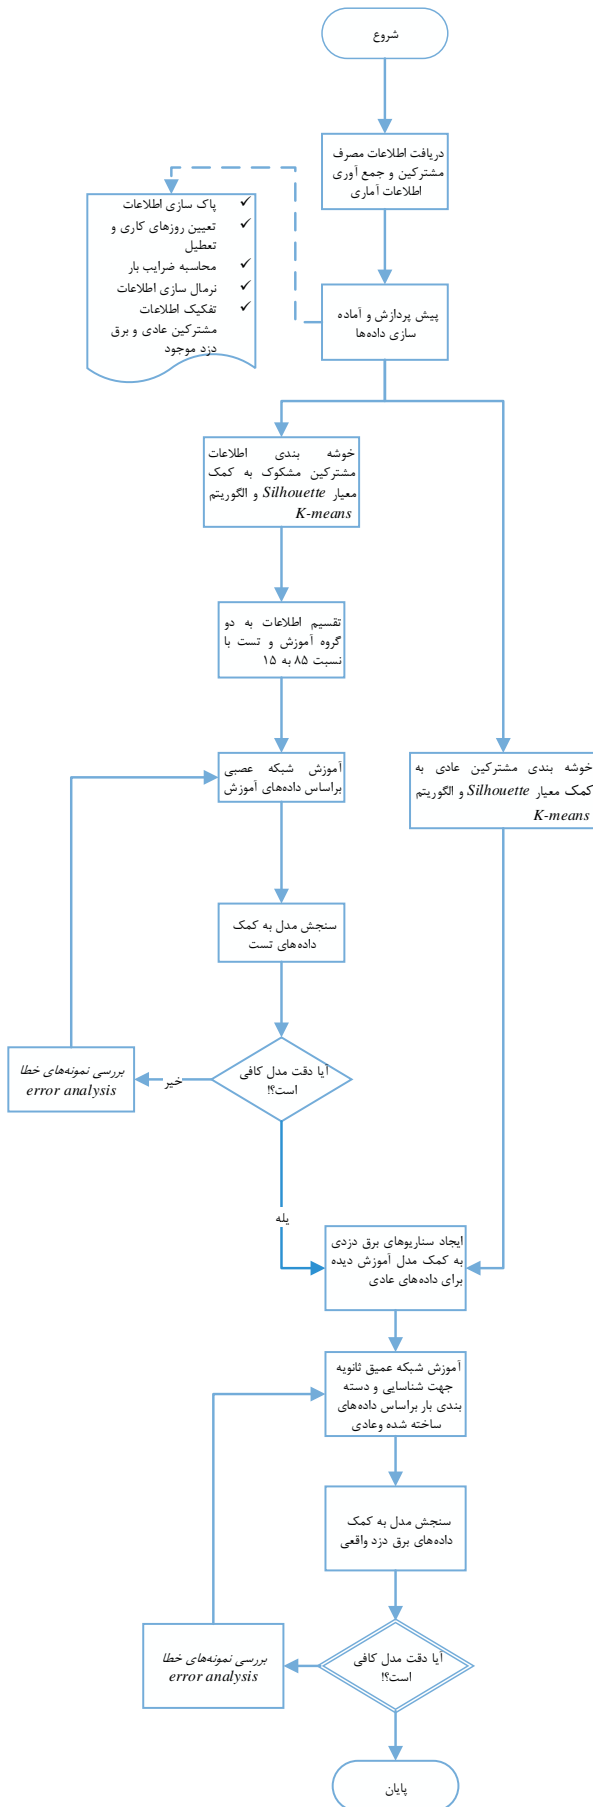
m : تعداد مشترکین مشکوک

n : بازه زمانی ثبت اطلاعات بر حسب ساعت

[۱۰،۱-] تغییر می‌کند و مقدار نزدیک به یک بیانگر انطباق خوب بین نقطه و خوشه است.

بر اساس توضیحات ارائه شده در قدم اول مرحله اول به آماده‌سازی اطلاعات مشترکین جهت خوشه‌بندی مشترکین پرداخته می‌شود که پس از آماده‌سازی در مجموع ۷۰ ویژگی شامل اطلاعات مصرف ۲۴ ساعته مشترک و اطلاعات آماری و معیشتی نظیر تعداد افراد ساکن در منزل، درآمد خانواده، سیستم گرمایشی و سرمایش، تعداد اتاق و سن افراد می‌شوند. در قدم دوم به وسیله معیار Silhouette تعداد مناسب خوشه‌های توصیف‌کننده مشترکین عادی تعیین می‌شوند و الگوریتم K-means جهت تعیین خوشه‌ها استفاده می‌شود. در قدم سوم و نهایه مرحله اول اطلاعات مشترکین مشکوک را به دودسته آموزش و آزمون با نسبت ۸۵ به ۱۵ درصد تقسیم می‌کنیم و به وسیله داده‌های آموزشی چند شبکه DNN را با پارامترهای متفاوت از جمله تعداد لایه‌ها، تعداد نورون‌ها و توابع فعال‌ساز مختلف با تابع هزینه میانگین مربعات خطا^{۱۸}، اندازه دسته^{۱۹} برابر ۸ و بهینه‌ساز^{۲۰} آدام جهت پیش‌بینی مصرف مشترکین مشکوک برای ۲۴ ساعت آینده آموزش داده می‌شوند. سپس به کمک شبکه عمیق آموزش‌دیده در مرحله قبل تعداد نمونه مشکوک بر اساس اطلاعات مشترکین عادی ایجاد می‌کنیم. این نمونه‌ها در واقع شبیه‌سازی سناریوهای محتمل برق‌دزدی و دستکاری شده کنتور به ازای مشترکین عادی است و این واقعیت را بیان می‌کند که اگر روزی یک مشترک عادی با تغییر رفتار مصرفی خود به سمت استفاده غیرمجاز یا دستکاری شده کنتور برود تأثیر این رفتار در الگوی مصرف به چه صورت است. در نهایت در مرحله دوم بر اساس اطلاعات مشترکین عادی و مشکوک به آموزش یک شبکه عمیق DNN که در لایه ورودی از ۷۰ نورون، در لایه‌های میانی از ترکیب ۱۰۰ و ۵۰ نورون و در لایه پایانی از L نورون تشکیل شده است جهت تفکیک مشترکین پرداخته می‌شود. L برابر تعداد خوشه‌های استخراج شده در مرحله خوشه‌بندی مشترکین عادی به علاوه برچسب مشترکین مشکوک است. تابع فعال‌ساز نورون‌های میانی Relu و تابع فعال‌ساز نورون‌های لایه آخر با توجه به این که وظیفه لایه آخر تفکیک موارد عادی و مشکوک است از نوع SoftMax است و به تبع آن تابع هزینه categorical_crossentropy جهت آموزش مدل استفاده شده است.

پس از آموزش مدل و اطمینان از صحت عملکرد مدل، اطلاعات مصرف روزانه مشترکین را دسته‌بندی می‌کنیم و مشترکین که تعداد دفعات تشخیص آن‌ها توسط مدل به عنوان موارد مشکوک بیشتر از یک حد مشخصی باشد به لیست موارد مشکوک شرکت برق جهت بازرسی اضافه می‌شوند. حد مشخص تکرار بر اساس نظر متخصصین شرکت‌های برق برای هریک از مناطق مورد مطالعه می‌تواند متفاوت تعیین گردد و این اصل را بیان می‌کند که مناطق مختلف رفتاری مشابه ندارند. در نهایت بر اساس توضیحات داده شده روند نمای کلی کار به صورت شکل ۱ است.



شکل (۱): روند نمای کلی روش پیشنهادی

در نهایت با توجه به توضیحات ارائه شده، ۵۰۰۰ نمونه برق دزدی مطابق شکل ۵ جهت آموزش شبکه عصبی اولیه تولید شده است. نتایج مربوط به پیاده‌سازی مدل‌های استفاده‌شده در روش پیشنهادی با پارامترهای مختلف برحسب معیار MSE در جدول ۲ ارائه شده است. همچنین نمودارهای مربوط به خروجی بعضی از مدل‌ها در شکل ۶ به نمایش گذاشته شده است. مطابق شکل ۶ منحنی‌های آبی رنگ الگوهای مصرف دستکاری شده توسط مشترکین برق دزد را نشان می‌دهند، که در شکل ۵ به صورت نقطه‌چین نمایش داده شده بود؛ منحنی‌های نارنجی رنگ الگوهای مصرفی پیش‌بینی شده توسط مدل‌های آموزش داده شده است. به‌طور خلاصه این مدل‌ها در ورودی منحنی مصرف عادی را دریافت می‌کنند و در خروجی الگوی مصرف دستکاری شده احتمالی را پیش‌بینی می‌کنند.

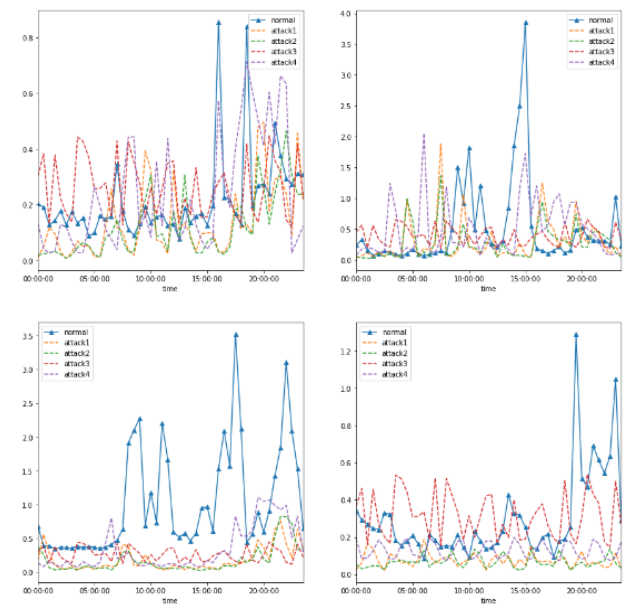
جدول (۲): نتایج مربوط به پیاده‌سازی شبکه DNN

تعداد لایه‌ها	تعداد نورون‌ها	تابع فعال‌ساز	تعداد تکرار	اندازه دسته‌ها	Train-MSE	Test-MSE
۳	(۷۰،۶۰،۴۸)	Relu	۳۰۰	۸	۴/۵۵	۵/۴۳
۴	(۷۰،۶۴،۵۰،۴۸)	Relu	۳۰۰	۱۶	۴/۲۴	۵/۳۱
۳	(۷۰،۶۰،۴۸)	Tanh	۳۰۰	۸	۵/۹۲	۶/۰۱

بر اساس نتایج جدول ۲ محدود خطا مدل DNN در حدود ۴-۶ واحد است. بر اساس شکل ۶ اگرچه میزان خطای شبکه DNN پایین است اما مقایسه نتایج پیش‌بینی الگوی مصرف نشان می‌دهد که مدل توانایی تخمین نقاط اوج را به‌درستی ندارد که می‌توان این ضعف را به دو صورت توجیه کرد؛ اولاً با توجه به اینکه در داده‌های ورودی هیچ‌گونه توجهی به سیر زمانی داده‌ها نشده است در نتیجه مدل توانایی یادگرفتن روند را ندارد؛ دوماً با توجه به تعداد کم داده‌ها به ازای هر یک از گروه‌ها نمی‌توان انتظار عملکرد بسیار دقیق از مدل داشت. پس از اطمینان از دقت مدل‌های آموزش داده شده؛ به کمک این مدل‌ها تعدادی سناریوهای برق دزدی برای مشترکین عادی پیش‌بینی می‌شود. منظور از پیش‌بینی سناریوهای برق دزدی این است که از میان اطلاعات مشترکین عادی به صورت تصادفی تعدادی از منحنی مصرف آن‌ها را به مدل می‌هیم تا مدل متناسب با رابطه‌ای که از رفتار مشترکین برق دزد کشف کرده است الگوی مصرف دستکاری شده احتمالی آن مشترکین را پیش‌بینی کند. در نهایت به کمک این نمونه‌های پیش‌بینی شده و اطلاعات مشترکین عادی، که در مرحله اول تفکیک و خوشه بندی شده بودند، یک شبکه عصبی ثانویه جهت دسته‌بندی مشترکین عادی و مشکوک از یکدیگر ارائه می‌شود.

یکی از فرضیات روش پیشنهادی وجود تعداد حداقلی اطلاعات مشترکین مشکوک است. اما با توجه به اینکه در این مجموعه داده هیچ‌گونه اطلاعات در مورد مشترکین مشکوک یا برق دزد وجود ندارد لازم است که یک مجموعه داده به‌عنوان مرجع اطلاعات مشکوک ایجاد شود. در این راستا با استناد به مرجع [۴] تعدادی نمونه برق دزدی ایجاد شده است. شکل ۵ نمونه الگوی مصرف واقعی و دستکاری شده چند مشترک برق دزد را نشان می‌دهد. در این شکل منحنی‌های ممتد (آبی پررنگ) الگوی مصرف واقعی چند هستند که به‌وسیله مازول (STLF) در بخش قبل توضیح داده شده است، پیش‌بینی شده است. در حالی که هر یک منحنی‌های نقطه‌چین یک نمونه الگوی مصرف دستکاری و ارسال شده این مشترکین است. بر اساس شکل کاملاً مشهود است که اولاً الگوهای ایجاد شده کاملاً تصادفی و متنوع هستند و ثانیاً سطح زیر الگوی مصرف ارسال شده، که بیانگر انرژی مصرفی است، عموماً بسیار کمتر از سطح زیر الگوی مصرف واقعی هستند. این اختلاف انرژی مصرفی بیانگر نوعی استفاده غیرمجاز است که با توجه به معادلات ماتریسی ذکر شده در بخش قبل اگر اطلاعات تعداد کافی از مشترکین برق دزد را در اختیار باشیم، می‌توان به کمک یک شبکه عصبی عمیق رفتار این مشترکین مشکوک را مدل‌سازی کنیم. در نتیجه به کمک مدل ساخته‌شده می‌توان رفتار مشترکین مشکوک را بسط داد و سناریوهای محتمل برق دزدی به ازای مشترکین عادی پیش‌بینی کرد.

به‌طور خلاصه هدف از مدل‌سازی رفتار مشترکین برق دزد شناسایی و کشف رابطه ریاضی است که سبب تبدیل شدن الگوی مصرف واقعی به هر یک از الگوهای مصرف دستکاری شده می‌شود.



شکل (۵): نمونه الگو مصرف واقعی و دستکاری شده چند مشترک برق دزدی

گرفته شده است که در نتیجه آن مدل نمونه‌های بیشتری جهت یادگیری در اختیار داشته و به تبع آن بهترین نتیجه ممکن حاصل شده است. همچنین قابل مشاهده است که با افزایش تعداد گروه‌ها توانایی مدل در تشخیص کاهش می‌یابد که با توجه به کاهش تعداد نمونه‌ها به ازای هر یک از گروه‌ها جهت آموزش مدل کاملاً امری طبیعی است. همچنین قابل مشاهده است که عمده تحقیقات گذشته بر اساس شبکه‌های یادگیری عمیق انجام شده است و ثانیاً در عمده تحقیقات از پرداختن به تأثیر عوامل آماری و اجتماعی اجتناب شده است.

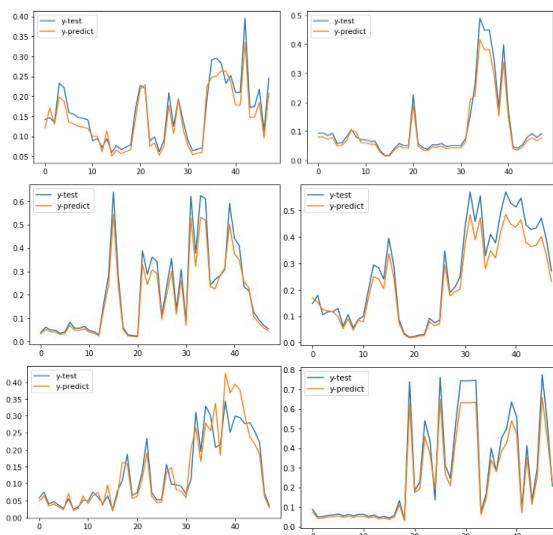
جدول (۳): مقایسه روش پیشنهادی و روش‌های موجود

اطلاعات استفاده شده	Accuracy (%)	FPR (%)	DR (%)	مرجع
پروفیل بار مشترکین	-	۵/۱۴	۹۵/۰۴	[۱۲]
	-	۵/۵۶	۹۷/۲۷	
پروفیل بار مشترکین و ترانس	-	۱۱	۹۴	[۴]
پروفیل بار مشترکین، تعداد اعضا خانه، تعداد لوازم خانگی	۹۲/۵۰	۵/۱۲	-	[۵]
پروفیل بار مشترکین	۹۳/۳۶	۵/۸۴	۹۲/۵۶	[۱۸]
پروفیل بار مشترکین	-	۳/۱۷	۹۷/۵۳	[۱۹]
پروفیل بار مشترکین، تعداد اعضا خانه، نوع سیستم گرمایش و سرمایش، میزان درآمد، سن افراد	۹۵/۱	۵/۱۵	۹۸	سناریو ۱
	۹۰/۶	۱۴/۴	۹۲/۳	سناریو ۲

۵- نتیجه‌گیری

در این پژوهش، یک مدل دو مرحله‌ای مبتنی بر شبکه‌های عمیق جهت تشخیص برق دزدی در بستر کنتورهای هوشمند ارائه شده است. در مرحله اول، الگوهای مصرف مشترکین به کمک الگوریتم خوشه‌بندی استخراج شده؛ سپس با تکیه بر این فرض که رابطه بین مصرف واقعی و مصرف ثبت شده به صورت ریاضی قابل بیان است، یک شبکه عمیق اولیه جهت پیش‌بینی الگوهای برق دزدی بر اساس الگوهای مشترکین متقلب توسعه داده شده است. به کمک این شبکه سناریوهای محتمل برق دزدی به ازای مشترکین عادی جهت غلبه بر مسئله عدم تعادل در نسبت مشترکین مشکوک تولید می‌شود.

در نهایت با تکیه بر سناریوهای تولید شده و اطلاعات مشترکین عادی چندین شبکه عمیق ثانویه جهت دسته‌بندی مشترکین ارائه شده است. بررسی مدل پیشنهادی بر روی مجموعه داده واقعی با بیش از ۶۰۰۰ مشترک و مقایسه آن با دیگر روش‌های موجود عملکرد بالایی آن را از دیدگاه نرخ شناسایی و دقت نشان می‌دهد. در پژوهش‌های آتی سعی می‌شود از ترکیب شبکه‌های LSTM, CNN که عملکرد بهتری در حوزه رگرسیون دارند و همچنین داده‌های مربوط به داخل کشور استفاده شود.




شکل (۶): مقایسه نمونه الگوهای خروجی مدل DNN و الگوهای واقعی

به منظور سنجش عملکرد روش پیشنهادی می‌توان سناریوهای متفاوتی برای مدل ثانویه مطابق شکل ۷ مطرح کرد:

- سناریوی اول: در این حالت مسئله تشخیص برق دزدی به صورت یک مسئله دسته‌بندی ۲ تایی مطرح می‌شود. به طوری که در این حالت هدف صرفاً تشخیص برق دزد یا نبودن یک مشترک بدون توجه به الگوهای مختلف برق دزدی و عادی که در مراحل خوشه‌بندی استخراج شده‌اند است. در این سناریو در صورتی که مدل تشخیص دهد نمونه ورودی مشکوک است خروجی یک می‌شود و در غیر این صورت صفر است.

- سناریوی دوم: در این حالت مسئله تشخیص برق دزدی به صورت یک مسئله دسته‌بندی چندتایی ۲۲ از دیدگاه تفکیک مشترکین برق دزد و عادی مطرح می‌شود. در این حالت هدف تشخیص برق دزد یا نبودن یک مشترک در کنار توجه به الگوهای مختلف مشترکین مشکوک و عادی است. به طوری که علاوه بر تشخیص نوع فعالیت مشترکین شماره گروهی که به آن تعلق دارند نیز تعیین می‌شود. در صورتی که مدل تشخیص دهد نمونه ورودی مشکوک است در خروجی شماره گروه مشترک را نمایش می‌دهد و در غیر این صورت شماره گروه مشترک را نمایش می‌دهد.



شکل (۷): سناریوهای مختلف تشخیص برق دزدی

نتایج حاصل از مقایسه سناریوی اول، دوم و تحقیقات پیشین در جدول ۳ مورد بررسی قرار گرفته است. بر اساس نتایج در سناریوی اول مسئله تشخیص برق دزدی به صورت دسته‌بندی دوتایی در نظر

- IEEE Journal on Selected Areas in Communications, vol. 31, no. 7, pp. 1319-1330, 2013.
- [15] J. A. Hartigan, and M. A. Wong, "AK-Means Clustering Algorithm," *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, vol. 28, no. 1, pp. 100-108, 1979.
- [16] "Irish Social Science Data Archive. [Online]. Available: <http://www.ucd.ie/issda/data/commissionforenergy>
- [17] S. Salinas, M. Li, and P. Li, "Privacy-Preserving Energy Theft Detection in Smart Grids: A P2P computing approach," *IEEE Journal on Selected Areas in Communications*, vol. 31, no. 9, pp. 257-267, 2013.
- [18] Ibrahim MI, Nabil M, Fouda MM, Mahmoud MM, Alasmay W, Alsolami F. "Efficient privacy-preserving electricity theft detection with dynamic billing and load monitoring for AMI networks," *IEEE Internet of Things Journal*, vol.8, no.2, pp.1243-58, 2020.
- [19] Yan, Z. and Wen, H, "Electricity theft detection base on extreme gradient boosting in AMI," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp.1-9, 2021.
- [۲۰] وحید یوسفی، مصطفی محمودی و شهریار شیخ اویسی، طراحی یک قالب برای تشخیص تقلب در شبکه توزیع برق، سومین کنفرانس بین‌المللی مهندسی برق، مهندسی مکانیک، کامپیوتر و علوم مهندسی، صوفیه - بلغارستان، ۱۳۹۸.
- [۲۱] موبدی راد حجت، فلقی حمید، فرشاد محسن. یک الگوریتم ابتکاری برای تجدید آرایش شبکه‌های توزیع به منظور کاهش تلفات اهمی مبتنی بر نظریه‌ی گراف. نشریه مهندسی برق و الکترونیک ایران. ۱۳۹۳؛ ۱۱ (۱): ۵۹-۷۲
- [1] P. Glauner, J. A. Meira, P. Valtchev, R. State, and F. Bettinger, "The Challenge of Non-Technical Loss Detection Using Artificial Intelligence: A Survey," arXiv preprint: 1606.00626, 2016.
- [2] J. B. Leite, and J. R. S. Mantovani, "Detecting and locating Non-Technical Losses in Modern Distribution Networks," *IEEE Transactions on Smart Grid*, vol. 9, no. 2, pp. 1023-1032, 2016.
- [3] S.-C. Huang, Y.-L. Lo, and C.-N. Lu, "Non-technical loss Detection Using State Estimation and Analysis of Variance," *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 2959-2966, 2013.
- [4] P. Jokar, N. Arianpoo, and V. C. Leung, "Electricity theft Detection in AMI Using Customers' Consumption Patterns," *IEEE Transactions on Smart Grid*, vol. 7, no. 1, pp. 216-226, 2015.
- [5] A. Jindal, A. Dua, K. Kaur, M. Singh, N. Kumar, and S. Mishra, "Decision Tree and SVM-Based Data Analytics for Theft Detection in Smart Grid," *IEEE Transactions on Industrial Informatics*, vol. 12, no. 3, pp. 1005-1016, 2016.
- [6] L. A. P. Júnior, C. C. O. Ramos, D. Rodrigues, D. R. Pereira, A. N. de Souza, K. A. P. da Costa, and J. P. Papa, "Unsupervised Non-Technical Losses Identification Through Optimum-Path Forest," *Electric Power Systems Research*, vol. 140, pp. 413-423, 2016.
- [7] A. Nizar, Z. Dong, and Y. Wang, "Power Utility Nontechnical Loss Analysis with extreme Learning Machine Method," *IEEE Transactions on Power Systems*, vol. 23, no. 3, pp. 946-955, 2008.
- [8] V. Botev, M. Almgren, V. Gulisano, O. Landsiedel, M. Papatriantafidou, and J. van Rooij, "Detecting non-Technical Energy Losses Through Structural Periodic Patterns in AMI Data." pp. 3121-3130, 2016.
- [9] M. Hasan, R. N. Toma, A.-A. Nahid, M. Islam, and J.-M. Kim, "Electricity Theft Detection in Smart Grid Systems: a CNN-LSTM Based Approach ", *Energies*, vol. 12, no. 17, pp. 3310, 2019.
- [10] M. M. Buzau, J. Tejedor-Aguilera, P. Cruz-Romero, and A. Gómez-Expósito, "Detection of Non-Technical Losses Using Smart Meter Data and Supervised Learning," *IEEE Transactions on Smart Grid*, vol. 10, no. 3 ,pp. 2661-2670, 2018.
- [11] N. E. I. k. Abdelaziz Amara Korba, "Smart Grid Energy Fraud Detection Using SVM," *International Conference on Networking and Advanced Systems (ICNAS)*, 2019.
- [12] T. Hu, Q. Guo, X. Shen, H. Sun, R. Wu, and H. Xi, "Utilizing Unlabeled data to Detect Electricity Fraud in AMI: A Semisupervised Deep Learning Approach," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 30, no. 11, pp. 3287-3299, 2019.
- [13] S. Li, Y. Han, X. Yao, S. Yingchen, J. Wang, and Q. Zhao, "Electricity Theft Detection in Power Grids with Deep Learning and Random Forests," *Journal of Electrical and Computer Engineering*, vol, 2019.
- [14] S. McLaughlin, B. Holbert, A. Fawaz, R. Berthier, and S. Zonouz, "A Multi-Sensor Energy Theft Detection Framework for Advanced Metering Infrastructures,"

زیر نویس‌ها

- ¹ Game theory
- ² Syntactic Dataset
- ³ Support Vector Machine
- ⁴ Decision Tree
- ⁵ Optimum-Path Forest
- ⁶ Fourier Transform
- ⁷ K-Nearest Neighbor
- ⁸ Convolutional Neural Network
- ⁹ Long-Short Term Memory
- ¹⁰ Logistic Regression
- ¹¹ Precision
- ¹² False Positive Rate
- ¹³ Random Forest
- ¹⁴ Grid Search Algorithm
- ¹⁵ Confusion Matrix
- ¹⁶ Receiver Operating Characteristic
- ¹⁷ Short Term Load Forecasting
- ¹⁸ Mean Score Error
- ¹⁹ Batch Size
- ²⁰ Adam Optimizer
- ²¹ Binary-Class Classification
- ²² Multi-Class Classification