روشی جدید در پایش و شناسایی خطا در سیستم کنترل و اتوماسیون مبتنی بر یادگیری تقویتی و شبکه عصبی

سعید خادمی[۱]، یاسر صداقت[۲]

[۱] شرکت برق منطقه ای خراسان، معاونت برنامه ریزی و تحقیقات،، مشهد
s.khademi@krec.ir

[۲] دانشگاه فردوسی ، دانشکده مهندسی، گروه کامپیوتر ، مشهد
y_sedaghat@um.ac.ir

چکیده

در این مقاله روشی هوشمند برای شناسایی، جداسازی و مکان‌یابی خطاهای رخ داده در سیستم اتوماسیون و کنترل ایستگاه‌های قدرت معرفی می‌شود. از یک سیستم یادگیری ماشینی، و یک شبکه عصبی چند لایه بازگشتی به عنوان آنالیزکننده الگوهای سیگنال-های آلارم و رخدادهای یک ایستگاه قدرت استفاده و کارایی زمانی و دقت تشخیص خطا در آنها مقایسه می‌شود. ورودی‌های این دو سیستم هوشمند، آلارم‌های ناشی از عملکرد رله‌های حفاظتی و کلیدهای سیستم قدرت می‌باشند و خروجی‌های آنها، اجزای خطادار سیستم را مشخص می‌کنند. این شبکه ها، با کمک مجموعه داده های تاریخچه ای مرکز دیسپاچینگ و در تعامل با مهندسان سیستم، آموزش می بیند.

تشخیص خطا، حتی در وضعیت نقص سیستم حفاظتی، غلط بودن اطلاعات آلارم‌ها و رخدادها، یا نویزی بودن مسیر مخابراتی، به-درستی انجام می‌شود و نتایج قابل قبولی در مقایسه با شبکه عصبی پرسپترون معمولی ارائه می‌دهد. کارایی و دقت روش پیشنهادی بر روی قسمتی از یک سیستم قدرت واقعی در شبکه فوق توزیع، به تایید رسیده است. نتایج نشان می دهد دقت شناسایی خطا و سرعت عملکرد سیستم مبتنی بر یادگیری ماشینی بیشتر است.

کلمات کلیدی

تشخیص هوشمند خطا؛ یادگیری ماشینی؛ شناسایی و آنالیز الگو؛ حفاظت و پایش سیستم قدرت؛

۱- مقدمه

در سیستم‌های قدرت، حجم زیادی از آلارم‌ها، رویدادها و پیامها در هنگام اختلال یا حادثه در سیستم اتوماسیون پست تولید می شود که بخشی از آنها نیز در مرکز کنترل شبکه قابل دستیابی هستند. این اختلالات، مربوط به خطاهای احتمالی در تجهیزات مختلف هستند که ممکن است در هر کجای سیستم اتفاق بیفتد. آشکارسازی خطا و جداسازی بخش خطادار از بقیه اجزاء سیستم، وظیفه اصلی تجهیزات حفاظتی و مهندسان مرکز کنترل می‌باشد. بنابراین تشخیص خطا در کمترین زمان و در نتیجه بازیابی سریع سیستم به شرایط طبیعی و نرمال، بسیار حیاتی است. از طرف دیگر، مرکز کنترل شبکه باید از میان حجم وسیع اطلاعات دریافتی، نتیجه‌گیری و تصمیم‌گیری نماید، که این امر، به‌خصوص در زمان حادثه زمان بر خواهد بود و ممکن است بازیابی شبکه را طولانی نماید. بعلاوه، اشکال در عملکرد تجهیزات حفاظتی و اتوماسیون پست، اختلال در مسیرهای مخابراتی یا تجهیزات مخابراتی پست، دریافت اطلاعات نادرست،

و حتی دستکاری عمدی اطلاعات سیستم اتوماسیون پست توسط یک نفوذگر و مهاجم فعال یا یک بدافزار، از مهمترین مسائلی هستند که تشخیص درست محل خطا را با مشکل مواجه می سازد.

کاربرد سیستم های خُبره در تشخیص خطا و هوشمندسازی سیستم های قدرت بسیار رایج است [۱]. تشخیص الگوهای آلارم آشفته یا جدید، در این متدها به سختی انجام می پذیرد که این مورد از نقاط ضعف سیستم-های خبره بشمار می‌رود. در سالهای اخیر، شیوه‌های یادگیری ماشینی[۱] در بسیاری از زمینه‌های کاربردی شبکه قدرت، مزایای زیادی را بدنبال داشته است[۱۶,۱۲]. شبکه‌های عصبی نیز در حل مسائل سیستم‌های قدرت، و از جمله تشخیص خطا، با موفقیت بکار رفته‌اند [۲]. علاوه بر تمام ویژگی‌های شبکه‌های عصبی، این شبکه‌ها نسبت به خطا کاملاً مقاوم هستند و می توانند استنتاج‌های سریع و بلادرنگی را پس از آموزش برون خطی[۲] و سرپرستی شده[۳]، بر اساس مجموعه ای از داده‌های تاریخچه‌ای[۴] یا شبیه سازی شده، انجام دهند. پس از یادگیری، شبکه‌های عصبی توانایی تعمیم دهی الگوها و اجرای برنامه در زمان بسیار کوتاه را خواهند داشت. با بکارگیری تنها یک شبکه عصبی برای تمام شبکه قدرت، و بالا بردن ابعاد بردار ورودی شبکه، حل مسئله را با مشکل مواجه می‌سازد [۳]. همچنین در این متدها، به دلیل در نظرگرفتن توپولوژی ثابت برای شبکه، برای توپولوژی‌های جدید، لازم است فاز یادگیری مجدد اجرا شود.

مقاله های متعددی در کاربرد چندین شبکه عصبی و یادگیری ماشینی، برای تعیین محل خطا در شبکه قدرت [۶, ۱۶ , ۵ ,۴] و برای توپولوژی-های متغیر شبکه [۷] ارائه گردیده است. فرضیه اصلی این متدها، عملکرد بدون عیب‌بودن سیستمهای اتوماسیون پست، و موجود بودن کلیه پیام‌ها و آلارمها در مرکز کنترل می‌باشد که چنین وضعیتی، یعنی رویت پذیر بودن تمامی شبکه، به دلایل مختلف در سیستم‌های واقعی کمتر اتفاق می‌افتد. در شبکه‌های عصبی این گونه، پس از بروز خطا، تعدادی از شبکه‌ها تشخیص خطا را انجام داده، و خروجی هر شبکه به عنوان ورودی شبکه‌های دیگر بکار می‌رود. پس از به پایداری رسیدن تشخیص هر شبکه، تشخیص نهایی به دنبال اجرای فرآیندهای تکراری و سلسله مراتبی بدست خواهد آمد. در هنگام بروز اشکال در سیستم حفاظتی و عملکرد نادرست آن، اطلاعات موجود برای تشخیص درست کافی نیست و در نتیجه، به دلیل سلسله مراتبی بودن سیستم تشخیص، از دقت تشخیص نهایی نیز مرتباً کاسته خواهد شد [۹].

در این مقاله، به منظور شناسایی آلارم‌ها، مکانیابی و تشخیص هوشمند خطاهای سیستم قدرت، روشی را مبتنی بر شبکه‌های عصبی چند لایه‌ی بازگشتی[۵] (RNN) و یادگیری تقویتی معرفی خواهد شد [۱۱, ۱۸]. آشکارسازی خطا در اجزای سیستم، در نواحی کوچک انجام می‌شود و هر شبکه عصبی مسئول رسیدگی به خطاهای ناحیه خود می‌باشد. در مقایسه با یک شبکه عصبی پرسپترون چند لایه معمولی با یادگیری کلاسیک نظارت شده، شبکه بازگشتی و آموزش تقویتی استفاده شده در این تحقیق (به عنوان نمونه ای از سیستم های یادگیری ماشینی) ، حتی در شرایط بحرانی، مانند نویزی شدن داده ها یا اختلال در سیستم حفاظتی و اتوماسیون، تشخیص‌های درستی انجام می‌دهد. آزمایش‌های انجام شده، مزیت و مفید بودن استراتژی شبکه‌های عصبی بازگشتی و یادگیری تقویتی را تایید می کند.

۲- مبانی تحقیق

یکی از مهمترین اهداف طراحی سیستم‌های حفاظت و اتوماسیون محلی و از راه‌دور، جداسازی و تفکیک اجزای اشکال‌دار سیستم قدرت، در هنگام بروز اختلال در شبکه می باشد. سرعت، هماهنگی، و انتخاب پذیری[۶] از مهمترین ویژگیهای مورد انتظار یک سیستم حفاظتی است. سرعت در جداسازی اجزاء خطادار شبکه، کاهش خطر آسیب رسیدن به سایر تجهیزات سالم را به دنبال دارد. تجهیزات حفاظتی و اتوماسیون، و همچنین مرکز کنترل شبکه بر اساس اطلاعاتی که از این سیستم‌ها از راه‌دور دریافت می‌کند؛ بایستی با هماهنگی، تنها اجزای آسیب دیده یا خطادار را انتخاب و از شبکه جدا نمایند. در صورت عملکرد نادرست سیستم حفاظتی اصلی، پیش بینی حفاظت‌های پشتیبان کمک می‌کند تا خطا از سیستم حذف شود و از گسترش ناحیه خطادار و سخت شدن تشخیص آن جلوگیری به عمل آید [۱۱].

تعدادی از آلارم‌های ناشی از عملکرد سیستم اتوماسیون محلی پست و همچنین اطلاعات اسکادای تجهیزات، توسط پایانه‌های راه‌دور جمع‌آوری و برای پایش و راهبری شبکه، به مرکز دیسپاچینگ ارسال می‌شود. اپراتورهای سیستم، پس از تحلیل این آلارم‌ها و پیام‌های دریافت شده در مرکز کنترل، درباره بازیابی، بهره برداری و نگهداری شبکه استنتاج و تصمیم‌گیری می‌نمایند. حجم زیاد آلارم‌های دریافتی در مرکز کنترل، در کنار سایر مسائل، مانند کامل نبودن اطلاعات و نقص سیستم حفاظتی، عکس العمل‌ها و تصمیم‌گیری‌های سریع را بسیار مشکل خواهد ساخت [۸].

شبکه‌های عصبی و یادگیری ماشینی قادرند پردازش حجم زیاد اطلاعات گفته شده را در زمان کم، اجرا نمایند که این قابلیت، بهره‌برداری آنها را برای هوشمند ساختن سیستم‌های بلادرنگ قدرت مناسب ساخته است. علاوه بر مقاوم بودن این شبکه‌ها نسبت به خطا، تعمیم پذیری از دیگر مزایای آنها به شمار می رود که این مزیت، امکان رسیدگی به به الگوهای خطای آموزش داده نشده در سیستم را فراهم می‌کند [۱۳, ۱۴].

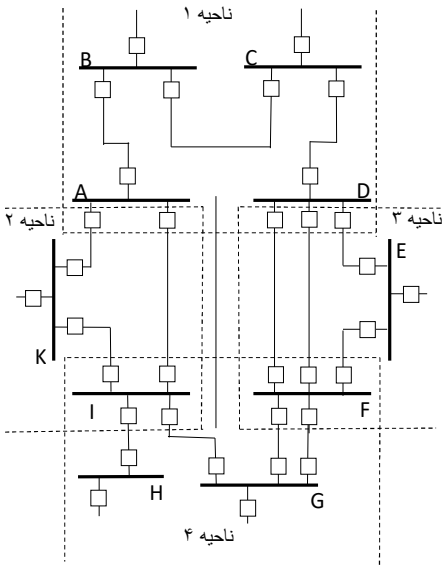

شکل ۱: شبکه قدرت مورد مطالعه

۳- روش مبتنی بر شبکه عصبی چندلایه بازگشتی

در این بخش از پژوهش، عملکرد مدل شبکه عصبی پرسپترون چند لایه با یک لایه مخفی (MLP) [۷]، با شبکه عصبی بازگشتی یعنی RNN، در حل مسئله گروه‌بندی آلارم و تشخیص خطا در سیستم کنترل قدرت مورد مطالعه در شکل ۱ با هم مقایسه خواهد شد [۱۲]. سیستم قدرت مورد مطالعه شامل ۱۰ ایستگاه، قسمتی از شبکه قدرت فوق توزیع خراسان است وآلارم‌ها و پیام‌های مرتبط با این سیستم، از اطلاعات تاریخچه‌ای مرکز دیسپاچینگ منطقه‌ای شمال شرق کشور استخراج گردیده است که برای آموزش شبکه‌های عصبی پیشنهادی بکار خواهد رفت. سیستم به طور فرضی، به چهار ناحیه تقسیم شده، که هر ناحیه تعداد محدودی ایستگاه و تجهیزات را در بر می‌گیرد. در این حالت چهار شبکه RNN - متناظر با هر ناحیه - به منظور مانیتورینگ اجزای سیستم در هر ناحیه خاص، تعریف می‌شود [۱۰].

پرسپترون با یک لایه مخفی و RNN در شکل ۲ ملاحظه می‌شوند. هر دو مدل، یک لایه مخفی داشته و از نوع تغذیه روبه جلو[۸] هستند و پس از یادگیری سرپرستی شده[۹]، قادر به تصمیم‌گیری در هر ناحیه خواهند بود. بلوک‌های بازگشتی یا فیدبک در RNN ، شامل تاخیر زمانی نیز می‌شوند.

همانطور که در نتایج شبیه‌سازی ملاحظه خواهد شد بلوک‌های بازگشتی، سبب افزایش قدرت یادگیری شبکه و در نتیجه کاهش خطای تشخیص آن خواهند شد. مدل استفاده شده برای نِرونها، برای پرسپترون تابع تحریک سیگموئید و برای RNN تابع گوسی می باشد [۹].

متغیرهای ورودی هر دو شبکه، اطلاعات بریکرها و رله‌ها است که جهت شناسایی اجزای خطادار در ناحیه مونیتور شده، ضروری می باشد. هر نِرون خروجی، رخ دادن خطا در یک جزء خاص را شناسایی یا رد می‌کند. چهار شبکه عصبی پرسپترون MLP و RNN ، بترتیب مربوط به ناحیه های ۱ تا ۴، به نحوی آموزش داده می‌شوند تا ارتباط بین الگوهای آلارم ورودی و خطاهای مشاهده شده در سیستم قدرت شکل ۱ را یاد بگیرند.
فاز آموزش یا یادگیری شبکه‌ها، فقط یک بار و در حالت سرپرستی شده (برون خطی) انجام می‌شود. داده‌های لازم برای یادگیری، از میان نمونه-های مختلفی از الگوهای آلارم بدست می آیند. در این میان، حتی الگوهای آلارمی که در آن سیستم حفاظتی عملکرد درستی نداشته است، نیز در نظر گرفته می‌شوند. علاوه بر نمونه‌های بدست آمده از اطلاعات تاریخچه‌ای ثبت شده در مرکز دیسپاچینگ، برخی اطلاعات نیز با بهره-

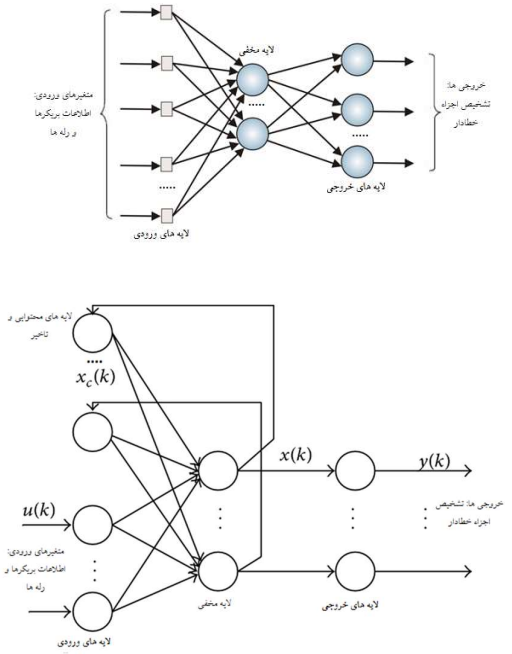

شکل ۲: شبکه عصبی پرسپترون (MLP) با یک لایه مخفی (تصویر بالا)؛ شبکه عصبی بازگشتی پیشنهادی (RNN) (تصویر پایین)

گیری از تجارب مهندسان مرکز کنترل، درباره عملکرد شبکه تحت پوشش استخراج و به عنوان الگوهای یادگیری به شبکه عصبی معرفی می‌شوند.
پس از تکمیل شدن پروسه یادگیری، هر شبکه پرسپترون و هر RNN متناظر با ناحیه مشخص شده، می‌توانند در تشخیص بلادرنگ بکار روند. در هنگام بروز خطا در سیستم قدرت مورد مطالعه، و دریافت آلارم‌ها در مرکز کنترل، مراحل اصلی تشخیص، به شرح زیر خواهد بود:

الف) انتخاب ناحیه‌هایی که حداقل یک آلارم ورودی، به عنوان متغیر ورودی دارند.

ب) آزمودن شبکه‌های انتخاب شده با الگوهای آلارم ورودی

پ) انجام تشخیص نهایی بر اساس تحلیل خروجی‌های شبکه‌ها

در هنگام بروز خطاهای فراگیر در سیستم‌های حفاظتی، بخش‌های بزرگتری از شبکه قدرت قطع خواهند شد و انتظار می‌رود نواحی بیشتری نیاز به تست داشته باشند. از مهمترین مزایای روش ارائه شده در این مقاله، می‌توان به این نکته اشاره نمود که شبکه‌های آموزش داده شده، برای تست الگوهای آلارم مرتبط با نمونه های پیش‌بینی نشده نیز، کارایی قابل قبولی دارند. این نمونه ها، در هنگام نویزی شدن اطلاعات یا در وضعیت عملکرد نادرست سیستم حفاظتی، پیش می‌آیند.

۴- روش پیشنهادی مبتنی یادگیری تقویتی

الگوریتم‌های یادگیری ماشین به دسته‌های نظارت شده، نظارت نشده و تقویتی قرار دارند. یادگیری تقویتی[۱۰] گونه‌ای از روش‌های یادگیری ماشین، بی نیاز به مدل، است که یک عامل[۱۱] را قادر به یادگیری در محیطی تعاملی، بدون نیاز به راهنما یا ناظر، با استفاده از آزمون و خطاها و استفاده از بازخوردهای اعمال و تجربیات خود می‌سازد. در یادگیری تقویتی، وقتی عامل در یک حالت خاص عملی را انجام می دهد، در مقابل پاداش دریافت می نماید. در این نوع یادگیری ماشین، تمامی تلاش و هدف عامل این خواهد بود که تا پاداش دریافتی را در دراز مدت به حداکثر برساند. اگرچه هم یادگیری نظارت شده و هم یادگیری تقویتی از نگاشت بین ورودی و خروجی استفاده می‌کنند، اما در یادگیری تقویتی بر خلاف یادگیری نظارت شده، از پاداش‌ها و تنبیه‌ها به عنوان سیگنال‌هایی برای بهبود عملکرد نهایی سیستم استفاده می شود.
تفاوت اصلی میان یادگیری تقویتی با روش های دیگر یادگیری ماشینی، در این است که در یادگیری تقویتی، هیچ گاه به عامل گفته نمی‌شود که کار درست در هر وضعیت کدام است و فقط به وسیله‌ی معیاری، به عامل فهمانده می شود که یک عمل[۱۲] به چه میزان خوب و یا به چه میزان بد می باشد. این وظیفه عامل یادگیرنده[۱۳] می باشد که با در دست داشتن این اطلاعات، یاد بگیرد که بهترین عمل در هر وضعیت کدام است. این موضوع، بخشی از نقاط قوت خاص یادگیری تقویتی است.
در میان روش‌های مدل‌سازی مبتنی بر عامل، یادگیری تقویتی به‌دلیل ذات عامل محور بودن خود، برای مدل‌سازی مبتنی بر عامل سیستم‌های پیچیده بسیار توانمند می‌باشد؛ و در بین الگوریتم‌های یادگیری تقویتی، الگوریتم یادگیری Q از آن‌جا که برای تصمیم‌گیری به مدل سیستم نیاز ندارد، برای تصمیم گیری در خصوص رفتار پیچیده سیستم کنترل و حفاظت قدرت بسیار مناسب است.
در الگوریتم کنترلی و برخط یادگیری Q بر اساس مدل فرآیند تصادفی مارکوف [۱۷] ، به هر زوج حالت/کنش یک مقدار $Q(s,a)$ نسبت داده میشود. این مقدار عبارت است از مجموع پاداشهای دریافتی، وقتی عامل از حالت s شروع و کنش a را انجام داده و در ادامه سیاست موجود را پیروی کرده باشد و تا زمانی که به مقدار بهینه همگرا شود، با استفاده از رابطه به روز رسانی می شود .لازم به ذکر است که این الگوریتم نیازی به داشتن مدلی از محیط ندارد .همچنین در هر اپیزود، زمانیکه s_{t+1}، یک حالت نهایی باشد، مقدار تابع Q برای آن هیچگاه به روز نمیشود و مقدار اولیه خود را حفظ می‌کند [۱۸] .

$$Q(s_t,a_t) \leftarrow Q(s_t,a_t) + \alpha[r_{t+1} + \gamma \max_a Q(s_{t+1},a_{t+1}) - Q(s_t,a_t)]$$

روال زیر الگوریتم یادگیری Q را تشریح می کند:

- به ازای هر کنش a ، Q را مقداردهی اولیه کن(معمولا صفر)
- در هر اپیزود تکرار کن
  - حالت فعلی s را مشاهده کن
  - تا مشاهده حالت پایانی تکرار کن
    - کنش a را از حالت فعلی s انتخاب کن(با سیاست جاری)
    - کنش a را اجرا کن، پاداش r و حالت جدید s' را مشاهده کن
    - مقدار Q را برای s و a به روز کن
    - حالت جدید s' را حالت فعلی s درنظر بگیر

پارامترهای الگوریتم، شامل α نرخ یادگیری برابر ۰٫۱، γ نرخ تنزیل برابر ۰٫۹، تعداد اپیزودها برابر ۲۰۰۰، و تعداد تکرار برابر ۵۰۰ تنظیم می شوند.

۵- شبیه‌سازی و ارزیابی عملکرد

بر اساس طبقه‌بندی‌های بدست آمده از خروجی شبکه‌های عصبی MLP و RNN و الگوریتم یادگیری ماشینی Q در هر ناحیه، عملکرد روش های پیشنهادی، بر اساس شاخص‌های زیر اندازه‌گیری می‌شود: ۱) درصد تشخیص های درست، ۲) درصد تشخیص های نادرست، ۳) درصد تشخیص های مبهم.

دو شبکه عصبی پرسپترون معمولی (MLP) و شبکه عصبی پیشنهادی بازگشتی (RNN) برای شبکه های عصبی، و الگوریتم یادگیری Q به عنوان سیستم یادگیری ماشینی، برای تشخیص خطاهای سیستم قدرت شکل یک (شامل ۱۰ ایستگاه) پیاده سازی شده است. در فاز یادگیری، توپولوژی‌های مختلف مورد بررسی قرار گرفتند. هم شبکه پرسپترون و هم RNN ، یک لایه مخفی با ۱۶ نِرون دارند که تعداد لایه‌های مخفی و تعداد نِرون‌های آن بصورت تجربی و برای بهترین عملکرد بدست آمده‌اند. جداول ۱ و ۲ و ۳، دقت تشخیص خطای بدست آمده برای ۲۰۰ الگوی آلارم و خطای تست شده، به ترتیب روی شبکه عصبی پرسپترون و RNN، وسیستم یادگیری تقویتی Q را نشان می‌دهد. این نتایج، مبین عملکرد بسیار خوب متدهای پیشنهادی، شبکه RNN در مقایسه با پرسپترون و یادگیری تقویتی Q در مقایسه با شبکه های عصبی می‌باشد.

جدول ۱: درصد تشخیص خطا در شبکه پرسپترون چند لایه

مجموع الگوهای آلارم تست شده	۲۰۰
درصد تشخیص‌های درست	۸۸٪
درصد تشخیص‌های نادرست	۳٪
درصد تشخیص‌های مبهم	۹٪

جدول ۲: درصد تشخیص خطا در شبکه RNN پیشنهادی

مجموع الگوهای آلارم تست شده	۲۰۰
درصد تشخیص‌های درست	۹۵٪
درصد تشخیص‌های نادرست	۲٪
درصد تشخیص‌های مبهم	۳٪

جدول ۳: درصد تشخیص خطا در الگوریتم یادگیری Q پیشنهادی

مجموع الگوهای آلارم تست شده	۲۰۰
درصد تشخیص‌های درست	۹۸٪
درصد تشخیص‌های نادرست	۱٪
درصد تشخیص‌های مبهم	۱٪

می‌توان ملاحظه کرد بلوک بازگشتی در RNN و روش خاص یادگیری Q مبتنی بر بازخورد، باعث کاهش قابل توجه حالت‌های مبهم و نادرست شبکه عصبی (عدم تشخیص یا تشخیص‌های نادرست خطا در سیستم قدرت) شده است. خطاهای طبقه‌بندی و طبقه‌بندی‌های نامشخص، غالباً به خاطر الگوهای آلارم غیر قابل پیش‌بینی و نامنظم اتفاق می‌افتند. با گنجاندن این نمونه های نادر در الگوهای آموزشی شبکه، می‌توان کارایی کلی سیستم تشخیص خطا را ارتقاء داد. باید توجه داشت بار محاسباتی اضافه شده برای طبقه‌بندی الگوهای جدید در حین روند یادگیری شبکه RNN، نسبت به پرسپترون اندکی بیشتر است و این مسئله، با توجه به پیچیدگی توپولوژی RNN قابل توجیه است.

همچنین درصد دقت سه شبکه MLP و RNN و یادگیری تقویتی Q، در تشخیص صرفاً درست خطا، بر حسب تعداد الگوهای آلارم استفاده شده در فاز یادگیری، در نمودار شکل ۳ ملاحظه می‌شود. با افزایش تعداد الگوهای یادگیری، دقت شبکه RNN پیشنهادی بطور قابل توجهی ارتقاء می‌یابد. وجود بلوک بازگشتی (فیدبک) در شبکه RNN این پدیده را توجیه می‌کند. در واقع نقطه قوت RNN در طبقه‌بندی درست الگوهای خطا، نسبت به MLP ، همین بلوک بازگشتی است که میزان تاثیرگذاری آن با افزایش تعداد الگوهای یادگیری، بیشتر خواهد شد. باید توجه داشت یادگیری مبتنی بر عامل های بازخوردی یادگیری Q، دقت آن را نسبت به شبکه های عصبی افزایش داده است.

مقایسه کارایی زمانی یادگیری تقویتی Q، با یادگیری نظارت شده در شبکه RNN، بر اساس تعداد رخدادها و آلارم های تست شده (تعداد تصمیم گیری) برای این دو شبکه، در شکل ۴ آورده شده است. واحد محور زمان در این نمودار میلی ثانیه و مقیاس آن لگاریتمی است. کارایی زمانی بهتر یادگیری تقویتی Q نسبت به شبکه عصبی، مشهود است که به تنهایی، مزیت بسیار خوبی در تشخیص خطا در سیستم‌های قدرت محسوب می‌شود.

۶- نتیجه‌گیری

در این مقاله، در این مقاله، دقت و کارایی زمانی دو سیستم هوشمند، ۱) مبتنی بر شبکه عصبی و ۲) مبتنی بر یادگیری تقویتی، برای پردازش آلارم ها و شناسایی خطا در یک شبکه قدرت واقعی و با استفاده از اطلاعات تاریخچه ای موجود در مرکز دیسپاچینگ، مقایسه شدند. شبکه عصبی RNN، با استفاده از الگوهای آلارم واقعی و متنوع، بصورت برون خطی و سرپرستی شده آموزش داده می‌شود. سیستم یادگیری تقویتی نیز بر اساس الگوریتم یادگیری Q به صورت تعاملی آموزش می بیند. پس از فاز یادگیری، هر دو شبکه هوشمند (عصبی و یادگیری تقویتی) قابلیت پردازش آلارم‌ها را بصورت بلادرنگ دارا می باشند. نتایج شبیه سازی، قابلیت تعمیم دهی و آشکارساز خطای بسیار خوبی را برای این دو نوع شبکه، در مقایسه با شبکه عصبی پرسپترون معمولی، نشان می‌دهد. با توجه به اهمیت زمان صرف شده برای تصمیم گیری و شناسایی خطا، سیستم یادگیری تقویتی مبتنی بر الگوریتم یادگیری تعاملی Q پیشنهاد شد که ارزیابی انجام شده، مزیت و برتری آن را در مقایسه با شبکه عصبی بازگشتی RNN ، اثبات نمود.

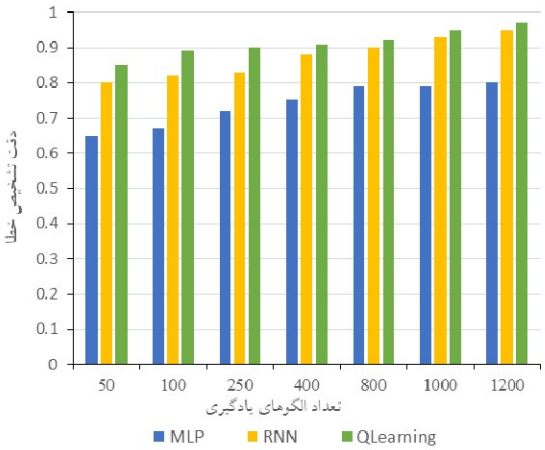

شکل ۳: دقت تشخیص درست خطا بر حسب تعداد الگوها در فاز یادگیری

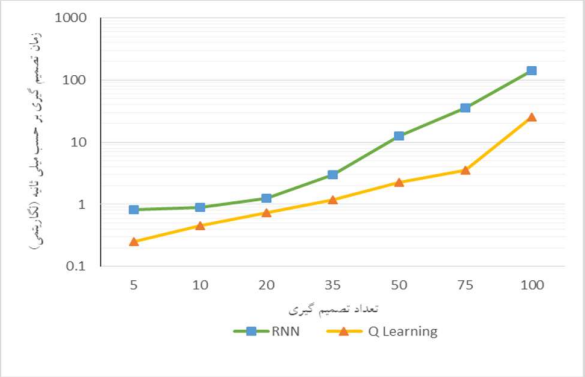

شکل ۴: مقایسه کارایی زمانی شبکه عصبی با یادگیری تقویتی Q

به دلیل ناحیه‌بندی سیستم قدرت و کوچک کردن سایز زیر شبکه ها، روش پیشنهادی این مقاله را براحتی می توان برای شبکه‌های قدرت بزرگتر و پیچیده‌تر پیاده‌سازی کرد. هر زیر شبکه هوشمند در هر ناحیه، مستقل عمل می‌کند که می‌توان به منظور کسب نتایج بهتر در حالت بلادرنگ، محاسبات نواحی را در محیط‌های موازی یا توزیع شده اجرا کرد. شبکه های عصبی و یادگیری تقویتی Q پیشنهاد شده در این تحقیق، حتی در شرایط و وضعیت‌های مشکل و پیش‌بینی نشده (مانند خطای تجهیز حفاظتی، از دست دادن اطلاعات، اطلاعات نویزی و الگوهای آلارم در نظر گرفته نشده در فاز آموزش) تشخیص درست انجام می دهند. به منظور مدل‌سازی واقعی‌تر الگوهای آلارم و خطا، ارتقاء هوشمندی شبکه و وضعیت‌های نامشخص سیستم، بکارگیری شبکه های خود سازمان ده و تطبیقی فازی در مطالعات بعدی پیشنهاد می‌شود.

مراجع

[1] Ferreira, V. H., et al. "A survey on intelligent system application to fault diagnosis in electric power system transmission lines." *Electric Power Systems Research* 136 (2016): 135-153.

[2] Baranovic, Neven, et al. "Experiences from Intelligent Alarm Processing and Decision Support Tools in Smart Grid Transmission Control Centers." *Proceedings of the CIGRÉ Session* 46 (2016).

[3] Expósito, Antonio Gómez, et al., eds. *Electric energy systems: analysis and operation*. CRC Press, 2016.

[4] Patton, Ron J., Paul M. Frank, and Robert N. Clark, eds. *Issues of fault diagnosis for dynamic systems*. Springer Science & Business Media, 2013.

[5] Sowa, John F., ed. Principles of semantic networks: Explorations in the representation of knowledge. Morgan Kaufmann, 2014.

[6] J.C.S. Souza, A.M. Leite da Silva, A.P. Alves da Silva, "Data debugging for real-time power system monitoring based on pattern analysis", *IEEE Trans. on Power Systems,* Vol.11, No.3, pp.1592- 1599, Aug. 1996.

[7] Sobajic, Dejan J. Neural network computing for the electric power industry: proceedings of the 1992 INNS summer workshop. Psychology Press, 2013.

[8] A.P. Alves da Silva, A.H.F. Insfran, P.M. da Silveira, G. Lambert- Torres, "Neural networks for fault location on substations", *1995 IEEE PES Summer Meeting*, July 23-27, 1995, Portland, OR.

[9] Chanca, Alfonso Q. Pérez, and Manfred F. Bedriñana. "Efficient processing of alarms avalanche using artificial neural networks and classification techniques." *Transmission & Distribution Conference and Exposition-Latin America (PES T&D-LA), 2014 IEEE PES*. IEEE, 2014.

[10] Maren, Alianna J., Craig T. Harston, and Robert M. Pap. *Handbook of neural computing applications*. Academic Press, 2014.

[11] T. S. Dillon, D. Niebur, *"Neural Network Applications in Power Systems"* , CRL Pub. Ltd, London, UK, 1996.

[12] S.Haykin, *Neural Networks: A Comprehensive Foundation*, Macmillan College Publishing Company, 1994.

[13] Samarasinghe, Sandhya. Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition. CRC Press, 2016.

[14] Gertler, Janos. *Fault Detection and Diagnosis*. Springer London, 2015

[15] Sutton, Richard S., and Andrew G. Barto. *Reinforcement learning: An introduction*. MIT press, 2018.

[16] Glavic, M., Fonteneau, R., & Ernst, D. (2017). Reinforcement learning for electric power system decision and control: Past considerations and perspectives. *IFAC-PapersOnLine*, *50*(1), 6918-6927.

[17] Puterman, M. L. (2014). Markov Decision Processes.: Discrete Stochastic Dynamic Programming. John Wiley & Sons.

[18] Gu, S., Lillicrap, T., Sutskever, I., & Levine, S. (2016, June). Continuous deep q-learning with model-based acceleration. In *International Conference on Machine Learning* (pp. 2829-2838).

زیرنویس‌ها

[1] - Machine learning
[2] – Off-line learning
[3] - Supervised learning
[4] – Historical data
[5] - Recurrent Neural Network (RNN)
[6] – Selectivity
[7] - Multi Layer Perceptron (MLP)
[8] – Feed forward
[9] – Supervised learning
[10] - Reinforcement Learning
[11] - Agent
[12] - Action
[13] - Learner