

به نام خدا

موضوع پیشنهادي پروژه

ارزيابي کارآيي و بررسي تحليلي سيستم های توزيعی

***Performance Evaluation and Analysis of
Distributed Systems***

احمد خونساري

دانشيار دانشکده فني، دانشگاه تهران

e-mail: ak@ipm.ir

فهرست مطالب

چکیده	3
مقدمه	4
1. ارائه یک مدل مدیریت اعتماد برای شبکه های خودرویی مبتنی بر یادگیری ماشین	5
2. مدیریت شتابدهنده های ناهمگون برای وظایف آموزش و استنتاج یادگیری عمیق	7
3. افزایش امنیت داده ها در شبکه های برق هوشمند با استفاده از بلاکچین مقاوم در برابر کوانتوم ..	10
4- همکاران پروژه	18
5- فهرست منابع و مراجع	18

چکیده

در ادامه ی پژوهش های سالهای قبل در سال جدید، 3پژوهش(1 ارائه یک مدل مدیریت اعتماد برای شبکه های خودرویی مبتنی بر یادگیری ماشین2) مدیریت شتابدهنده های ناهمگون برای وظایف آموزش و استنتاج یادگیری عمیق و 3) افزایش امنیت داده ها در شبکه های برق هوشمند با استفاده از بلاکچین مقاوم در برابر کوانتوم را مورد مطالعه قرار خواهیم داد.

پژوهش‌های که در ادامه ذکر می‌شوند جزو مسائل مهم در علوم شبکه می‌باشند و اخیراً مورد مطالعه پژوهشگران برجسته در سطح دنیا قرار گرفته‌اند. در نهایت الگوریتم‌های مناسب برای حل مسائل مطرح شده ارائه می‌شوند و بسترهای ارزیابی الگوریتم‌های پیشنهادی نیز پیاده‌سازی می‌شوند.

1- ارائه یک مدل مدیریت اعتماد برای شبکه‌های خودرویی مبتنی بر یادگیری ماشین

وسایل نقلیه در پیمایش مسیرهای روزانه خود حجم زیادی از اطلاعات آن مسیر طی شده را تولید می‌کنند که این اطلاعات می‌تواند برای سایر رانندگان، سازمانهای خصوصی و دولتی از قبیل آتش‌نشانی، تاکسیرانی، اتوبوس‌رانی، ترافیک، نهادهای دولتی، ارگان‌های پلیس و سایر سازمان‌ها که قصد پیمایش آن مسیر یا اطلاع از وضعیت ترافیکی را دارند مورد استفاده قرار بگیرند. به عنوان مثال استفاده از این اطلاعات برای مسیریابی رانندگان خودرو آتش‌نشانی در سریع‌ترین زمان ممکن با استفاده از اطلاعات شده توسط خودروهای دیگر است. کاربردی بودن و رشد سریع اطلاعات تولید شده توسط خودروها در شبکه خودرویی فرصت مناسب را برای حضور بازار تجارت اطلاعات ایجاد کرده است. پژوهش‌های مختلفی در این زمینه صورت گرفته است که برخی از آنها ایجاد بازار تجارت اطلاعات برای اطلاعات تولید شده توسط خودروها و نیز تجارت شارژ الکتریکی بین خودروهای الکتریکی است [1].

برخی از این پژوهش‌ها در کار خود موضوع اعتماد را مورد بررسی قرار داده‌اند و اعتماد را در قالب یک زیرساخت تجارت قابل اعتماد بیان کرده‌اند [2] [3]. مدل‌های آماری اعتماد پیشنهاد شده به طور کلی به مدل‌های آماری، مدل‌های برهانی و مدل‌های یادگیری ماشین تقسیم بندی می‌شوند [4]. مدل‌های آماری از محاسبات ساده برای منعکس کردن تأثیرات یا وزن شواهد مختلف اعتماد استفاده می‌کنند. این نوع مدل‌ها بصری هستند و می‌توانند شواهد اعتماد مختلفی را در ارزیابی شامل شوند. با این حال، به ویژه به وزن‌ها حساس است، که ممکن است برای کاربردهای مختلف متفاوت باشد. مدل‌های برهانی ابتدا اعتماد را با توجه به ابعاد چندگانه توصیف می‌کنند (به عنوان مثال، باور، ناباوری و عدم اطمینان) و سپس اعتماد را از طریق قوانین از پیش تعریف‌شده

(مانند منطق موضوعی و بیزوی [5][6]) استنباط می‌کنند. اگرچه آنها به خوبی می‌توانند موقعیت‌های دنیای واقعی را نشان دهند، این مدل‌ها بر دانش قبلی تکیه دارند و از پیکربندی نادرست قوانین ارزیابی رنج می‌برند. قابل ذکر است که مدل‌های آماری و مدل‌های استدلالی به شدت به دانش قبلی در مورد دامنه برنامه و برخی تنظیمات پارامترهای سیستم تکیه می‌کنند که مانع از ارزیابی کلی اعتماد می‌شود.

مدل‌های یادگیری ماشین معمولاً اعتماد را از طریق طبقه‌بندی یادگیری تحت نظارت [7] ارزیابی می‌کنند که اغلب به عنوان پیش‌بینی اعتماد شناخته می‌شود. با تجزیه و تحلیل الگوها و روند در داده‌های مربوط به اعتماد، چنین مدل‌هایی می‌توانند اعتماد را پیش‌بینی کنند. آن‌ها می‌توانند وزن‌ها و قوانین را به‌طور خودکار حتی در زمینه‌های مختلف بیاموزند، و همچنین زمانی که داده‌های کافی در دسترس هستند به دقت بالایی دست یابند [8]. در نتیجه، مدل‌های یادگیری ماشین دارای مزایای فوق‌العاده‌ای برای دستیابی به ارزیابی اعتماد هوشمند و دقیق هستند. شبکه عصبی گراف نوع نسبتاً جدیدی از مدل‌های یادگیری ماشین هستند که نسبت به انواع وظایف تحلیل شبکه، از جمله طبقه‌بندی گره، پیش‌بینی پیوند و طبقه‌بندی گراف برتری خود را نشان داده‌اند [9][10]. قدرت شبکه عصبی گراف در توانایی قوی آنها برای یادگیری بازنمایی‌های معنادار (یعنی جاسازی گره و لبه طریق انتشار و توجه به خود ساختاری گراف است [11]. این امر شبکه عصبی گراف را برای پیش‌بینی روابط اعتماد مناسب می‌کند، زیرا روابط اعتماد بین موجودیت‌ها در شبکه‌های مختلف (به عنوان مثال، شبکه‌های اجتماعی و شبکه خودرویی) می‌تواند به طور طبیعی به عنوان گراف مدل شود، به طوری که گره نشان دهنده موجودیت‌ها و لبه‌های بین گره نشان دهنده روابط اعتماد آنها است [12]. علاوه بر این، برخلاف مدل‌های سنتی یادگیری ماشین که اغلب به استخراج ویژگی نیاز دارند، شبکه عصبی گراف ارزیابی اعتماد سراسری را ارائه می‌کنند، که در آن داده‌های گراف خام می‌توانند مستقیماً به مدل‌های شبکه عصبی گراف برای به دست آوردن نتیجه ارزیابی محاسبه شوند. سادگی و اثربخشی شبکه عصبی گراف محققان را برانگیخته است تا پتانسیل این شبکه‌ها را برای ارزیابی اعتماد کشف کنند.

با وجود مزایای جذاب شبکه عصبی گراف، تحقیقات در مورد ارزیابی اعتماد مبتنی بر شبکه عصبی گراف هنوز در مراحل اولیه است. مدل‌های موجود [11][13][14][15][16] کاستی‌های متعددی رنج می‌برند. برخی از این مشکلات عبارتند از:

اول

مهمترین ماهیت ذاتی اعتماد که پویایی است، در سایر مدل‌ها به طور مناسب در نظر گرفته نشده است [11][13][14]. روابط اعتماد در طول زمان یا با رویدادها تغییر می‌کنند که نشان می‌دهد که روابط اعتماد یک زوج اعتماد دهنده - اعتماد گیرنده در بازه‌های زمانی مختلف متفاوت است. اگر اطلاعات زمانی در مورد اعتماد در نظر گرفته شوند می‌تواند منجر به پیش بینی مناسب و معقول از روابط آینده گراف شوند ولی اگر این اطلاعات مهم نادیده گرفته شوند منجر به نتیجه گیری مشکوک [15][17] شده و اثربخشی ارزیابی اعتماد را کاهش می‌دهد.

دوم

حملات مربوط به اعتماد به طور قابل توجهی فرآیند ارزیابی اعتماد را تضعیف می‌کنند و در نتیجه نتایج ارزیابی بی‌اهمیت می‌شود. به طور خاص، گره‌های مخرب می‌توانند رتبه‌بندی اعتماد را دستکاری کرده و قابلیت اطمینان یک گره با رفتار خوب را از بین ببرند یا قابلیت اعتماد یک گره مخرب را تقویت کنند [18]، که به ترتیب به عنوان حملات بد دهان و خوب دهان شناخته می‌شوند. این نوع حملات در دنیای واقعی رایج هستند [19]. به عنوان مثال، یلپ حدود شانزده درصد از رتبه‌بندی رستوران‌های خود را نادرست معرفی کرده است [20]. چنین رتبه‌بندی‌های غیرصادقانه‌ای می‌توانند مدل ارزیابی را گمراه کنند، اما هیچ یک از مدل‌های موجود غیر از [16] تلاشی برای افزایش استحکام خود نکرده‌اند.

سوم

نتایج ارزیابی اعتماد به دست آمده از مدل‌های شبکه عصبی گراف به دلیل نداشتن یک زیرساخت آشنا به زیان انسان درک راحتی ندارند. به عنوان مثال مشخص نیست که آیا نتایج توسط کاربر قابل قبول است یا خیر. عدم وجود توضیحات، قابل اعتماد بودن مدل ارزیابی را از نظر شهود انسانی کاهش می‌دهد و مانع پذیرش آن می‌شود [4][21].

چهارم

روش های موجود پویا بودن گراف را یاد در نظر نمیگیرن یا بسته با ادبیات و روش حل مسئله خود تنها بخشی از پویایی گراف ها را در نظر می گیرند. به عنوان مثال در روش [16] پویا بودن به حذف و اضافه شدن گره خلاصه می شود و اضافه و حذف گره را مطرح نشده است. روش پیشنهادی ما با الهام از [22] یک روش مدیریت کاملاً پویا به طوری که تمام پویایی گراف شامل اضافه و حذف شدن گره و گره را در پوشش می دهد. طبق پژوهش های انجام شده کار ما اولین کار در مدیریت اعتماد در شبکه خودرویی بر اساس شبکه عصبی گراف کاملاً پویا است.

پنجم

در مدل های قبلی همه داده های گراف ورودی به صورت فرض اولیه و مقدار تصادفی است که می تواند اعتماد را تا مرحله محاسبه نهایی تحت تاثیر قرار دهد (مخصوصاً اگر واقعا گره های مخرب زیادی در بخش اول وجود داشته باشند)، ما در این پژوهش از روش تشخیص فعال برای محاسبه واقعی اعتماد اولیه بین گره استفاده می کنیم. این روش محاسبه اعتماد و مقدار تصادفی باعث واقعی بودن نتیجه گیری اعتماد نهایی می شود. برای این منظور اعتماد تمام گره گراف ورودی با مقادیر واقعی اعتماد آنها که با پرس و جو از همسایگانش محاسبه می شود به عنوان مقدار دهی اولیه در گراف درج می شود. این فاز یک نوآوری در محاسبه اعتماد گره است. بنابراین، بررسی یک مدل ارزیابی اعتماد مبتنی بر شبکه عصبی گراف دقیق، قوی که ارزیابی دقیق را حتی در یک محیط دارای گره های مخرب ارائه می دهد و توضیحات قانع کننده ای در مورد نتایج ارزیابی ارائه می کند و به طور کامل ویژگی های اعتماد ذاتی را پوشش می دهند که دارای اهمیت بالایی است.

2- مدیریت شتاب دهنده های ناهمگون برای وظایف آموزش و استنتاج یادگیری عمیق

یادگیری عمیق در زمینه های مختلف پیشرفت فزاینده ای کرده است. توسعه و پردازش یک مدل یادگیری عمیق یک روش زمان بر و نیازمند منابع قدرتمندی است. از این رو، شتاب دهنده های اختصاصی مانند GPU، TPU، FPGA و ASIC ها به طور گسترده ای برای آموزش مدل های یادگیری عمیق به کار گرفته شده اند. این شتاب دهنده ها در خوشه های یادگیری عمیق رفتار

عملکردی ناهمگونی از خود نشان می‌دهند، به این معنی که ویژگی‌های عملکردی آن‌ها در مدل‌های مختلف یادگیری عمیق متفاوت است [۲۳].

الگوریتم‌ها برای خوشه‌های شتاب‌دهنده‌ها نقش مهمی در مدیریت این منابع پردازشی گران قیمت ایفا می‌کند. الگوریتم‌های موجود بر روی بهینه‌سازی اهداف مختلف، از جمله انصاف و زمان، تمرکز کرده‌اند. آن‌ها با به کارگیری استراتژی‌های مختلف مانند اولویت‌بندی کار، متعادل‌سازی حجم کار و سیاست‌های تخصیص منابع به این اهداف دست می‌یابند. درحالی‌که الگوریتم‌های موجود به این اهداف پرداخته‌اند، اغلب ناهمگونی عملکرد شتاب‌دهنده‌های مختلف را در نظر نمی‌گیرند. الگوریتم‌های سنتی که برای داده‌های بزرگ یا بارهای کاری محاسباتی با کارایی بالا طراحی شده‌اند، در حالت کلی برای استفاده کامل از منابع در مورد بارهای کاری یادگیری عمیق که خاصیت کشسانی دارند، مناسب نیستند و از همی قابلیت‌های مختلف شتاب‌دهنده‌ها برای بهینه‌سازی عملکرد و تخصیص منابع استفاده نمی‌کنند. از این رو ارائه یک الگوریتم تخصیص منبع آگاه از ناهمگونی که به‌طور سیستماتیک اهداف سیستم را برآورده کند مسئله مهمی است که باید به آن پرداخته شود [۲۴ و ۲۵].

در این پیشنهاد پژوهشی، روشی برای مدیریت شتاب‌دهنده‌های ناهمگون در خوشه‌های یادگیری عمیق برای وظایف آموزشی و استنباط ارائه شده است. بارهای کاری مختلف باید طوری تخصیص داده شود که اهداف مورد نظر مثل گذردهی و انصاف با محدودیت‌های که دارند را به درستی ارضا کند. این پژوهش بر مدل‌سازی و تخصیص منابع به وظایف یادگیری عمیق به منظور افزایش گذردهی و داشتن انصاف تاکید دارد و با استفاده از چارچوب محاسباتی ریاضیاتی و از منابع ناهمگون در روش پیشنهادی استفاده می‌کند.

با افزایش مدل‌های مختلف یادگیری عمیق و پردازش‌های زیاد این مدل‌ها، در خوشه‌های یادگیری عمیق که متشکل از انواع مختلف شتاب‌دهنده‌ها است نیازمند مدیریتی هستند که بتواند گذردهی مناسبی داشته باشد. همان‌طور که گفته شد بخاطر ناهمگونی منابع در این مراکز پردازش نمی‌توان از تمام ظرفیت منابع استفاده کرد. از این رو برای استفاده کامل و بهره‌وری ظرفیت تمام منابع نیازمند روشی هستند بتواند گذردهی را برای سیستم بالا ببرد.

در این پژوهش یک رویکرد به‌منظور مدیریت شتاب‌دهنده‌های ناهمگون در خوشه‌های یادگیری عمیق برای وظایف آموزش و استنباط ارائه شده است که عملیات تخصیص وظایف، انصاف، زمان‌بندی‌های آگاه از ناهمگونی، تقسیم‌بندی وظایف و موازی‌سازی، اشتراک‌گذاری منابع را به خوبی مدیریت کند. با در نظر گرفتن این جنبه‌ها و اتخاذ تکنیک‌های مناسب، مدیریت شتاب‌دهنده‌های ناهمگون برای آموزش شبکه‌های عصبی عمیق و وظایف استنباط می‌تواند منجر به بهبود گذردهی، استفاده از منابع و افزایش کارایی کلی شود [۲۶ و ۲۷ و ۲۸].

در کل، در نظر گرفتن اشتراک‌گذاری منابع و توزیع پذیری وظایف می‌تواند به بهبود

گذردهی منجر شود اما انجام این کار به علت بزرگ شدن مساله، چالش پیچیده‌ای خواهد بود. اما با استفاده از بهبود گذردهی باعث بهبود اهداف گفته شده می توان شد. هدف دیگر این پژوهش ارایه یک سیستم مدل هست که بتوان در کنار هدف اصلی که بهبود گذردهی است بتواند انصاف و تاخیر اندک که اهمیت بالایی برای وظایف استنباط دارد، ارضا کند. ترکیب یک سیستم مدل که وظایف استنباط و آموزش را به نحوی مدیریت کند که بتواند اهداف و شرایط را در نظر بگیرد چالش این پژوهش است [۲۹ و ۳۰].

برای مدل سازی تاثیر توزیع شدگی بر گذردهی وظایف یادگیری ماشین، ابتدا باید ویژگی های مختلف وظایف را در نظر گرفت. با تحلیل توزیع شدگی این ویژگی ها بر روی وظایف، اثرات آن بر کارایی و نیازمندی های منابع محاسباتی مدل می شود [۳۱ و ۳۲]. بر اساس مدل پیشنهادی، طراحی سیستم به گونه ای است که پاسخگوی وظایف استنباط و آموزش به صورت همزمان باشد و هدف آن بهبود گذردهی سیستم خواهد بود. مدل سازی بر پایه ی مدل بهینه سازی با در نظر گرفتن محدودیت ها و نیازمندی های منابع تلاش می کند تا یک تخصیص بهینه و عادلانه از منابع را ارائه دهد. برای حل مسئله بهینه سازی پیشنهادی، از الگوریتم های بهینه سازی متنوعی مانند الگوریتم های تکاملی، یا الگوریتم های بهینه سازی مبتنی بر مسائل بهینه سازی محدب می توان استفاده کرد [۳۳ و ۳۴ و ۳۵].

پژوهش حاضر سعی دارد تا با استفاده از روش برنامه ریزی خطی¹ (LP) مدیریت شتاب دهنده های ناهمگون را با در نظر گرفتن معیارهای واقعی مدل کند تا به اهداف مطلوب برسد [۳۶ و ۳۷ و ۳۸]. ماهیت این روش نشان می دهد که استفاده از آن برای زمان بندی منابع مربوط به شتاب دهنده های سخت افزاری نیز می تواند مفید باشد.

پژوهش پیشنهادی متشکل است:

- در نظر گرفتن ناهمگونی در وظایف یادگیری عمیق
- تخمین پارامترهای وظایف برای وظایف جدید یادگیری عمیق
- مدل سازی تاثیر اشتراک پذیری وظایف یادگیری عمیق
- مدل سازی توزیع شدگی بر وظایف یادگیری عمیق
- ارائه یک روش کارآمد برای حل مسئله بهینه سازی مخصوصا برای مقیاس های بزرگ
- در نظر گرفتن انصاف

- در نظر گرفتن کلاستر های مختلف برای مدیریت تاخیر وظایف استنباط

3 - افزایش امنیت داده‌ها در شبکه‌های برق هوشمند با استفاده از بلاکچین مقاوم در برابر کوانتوم

یکپارچه‌سازی فزاینده‌ی سیستم‌های غیرمتمرکز در زیرساخت‌های حیاتی مانند شبکه‌های هوشمند، فرصت‌ها و چالش‌های جدیدی را به همراه داشته است. فناوری بلاکچین، به‌ویژه شبکه بیت‌کوین، بستری امن و غیرمتمرکز برای معاملات انرژی فراهم می‌کند. با این حال، محدودیت‌های ذاتی مقیاس‌پذیری و تهدیدهای امنیتی در حال تحول، مانند محاسبات کوانتومی، نیازمند انطباق‌های نوآورانه برای به‌کارگیری مؤثر در محیط‌های شبکه هوشمند است.

این پژوهش یک شبکه بیت‌کوین [39] مقاوم در برابر کوانتوم، مجهز به پشتیبانی از شبکه لایتنینگ [40] را پیشنهاد می‌کند تا چالش‌های مقیاس‌پذیری و امنیت در معاملات انرژی در شبکه‌های هوشمند غیرمتمرکز را برطرف نماید [41]. تمرکز اصلی این تحقیق بر توسعه‌ی الگوریتمی خواهد بود که اجرای مؤثر شبکه لایتنینگ را در سناریوی شبکه هوشمند، جایی که گره‌ها به‌طور کامل به یکدیگر متصل نیستند، امکان‌پذیر کند.

چرا بیت‌کوین؟

۱. **غیرمتمرکز بودن:** شبکه بیت‌کوین، به عنوان پلتفرم بلاکچین بنیادی، نسبت به سایر گزینه‌ها غیرمتمرکزتر بوده و برای سیستم‌های شبکه هوشمند غیرمتمرکز ایده‌آل است. [42]
۲. **امنیت:** مکانیزم‌های امنیتی قوی بیت‌کوین، آن را برای مدیریت داده‌های حساس معاملات انرژی مناسب می‌سازد.
۳. **چالش‌های مقیاس‌پذیری:** نرخ پردازش تراکنش‌های بیت‌کوین تنها ۷ تراکنش در ثانیه است، در حالی که شبکه‌های هوشمند ممکن است به بیش از ۱۰۰۰ تراکنش در ثانیه نیاز داشته باشند.

برای غلبه بر محدودیت‌های مقیاس‌پذیری بیت‌کوین، شبکه لایتنینگ معرفی شده است. این شبکه امکان پردازش تراکنش‌ها به‌صورت خارج از زنجیره (Off-Chain) [43] را فراهم کرده و به‌طور قابل‌توجهی توان عملیاتی را افزایش می‌دهد. با این حال، پیاده‌سازی آن در محیط شبکه هوشمند با چالش‌هایی همراه است:

- **اتصال گره‌ها:** گره‌ها در شبکه‌های هوشمند (مانند خانه‌ها و پست‌های توزیع) کاملاً به هم متصل نیستند. [44]
- **مسیریابی:** یافتن مسیرهای بهینه‌ی پرداخت از طریق گره‌های واسطه (شامل اتصالات الکتریکی و مبتنی بر تبادل) چالش مهمی محسوب می‌شود.

محاسبات کوانتومی تهدیدی جدی برای مکانیزم‌های رمزنگاری سنتی محسوب می‌شود. ترکیب رمزنگاری مقاوم در برابر کوانتوم با شبکه بیت‌کوین [45]، امنیت بلندمدت معاملات انرژی در شبکه‌های هوشمند را تضمین می‌کند.

اهداف تحقیق

۱. **توسعه‌ی یک شبکه بیت‌کوین مقاوم در برابر کوانتوم:** انطباق شبکه بیت‌کوین [46] با الگوریتم‌های رمزنگاری مقاوم در برابر کوانتوم برای ذخیره‌سازی و انجام تراکنش‌های امن.
۲. **ادغام شبکه لایت‌نینگ:** طراحی و پیاده‌سازی معماری شبکه لایت‌نینگ متناسب با محیط‌های شبکه هوشمند برای دستیابی به مقیاس‌پذیری.
۳. **توسعه‌ی الگوریتم مسیریابی:** پیشنهاد و ارزیابی یک الگوریتم برای مسیریابی معاملات انرژی از طریق گره‌های واسطه در یک شبکه هوشمند نیمه‌متصل.
۴. **شبیه‌سازی شبکه هوشمند:** شبیه‌سازی شبکه پیشنهادی در یک سناریوی شبکه هوشمند به‌منظور اعتبارسنجی مقیاس‌پذیری، امنیت و کارایی آن.

روش تحقیق

مرحله ۱: ادغام رمزنگاری مقاوم در برابر کوانتوم (انجام شده)

- بررسی الگوریتم‌های رمزنگاری مقاوم در برابر کوانتوم برای کاربردهای بلاکچین [47]
- جایگزینی الگوریتم‌های رمزنگاری سنتی بیت‌کوین با جایگزین‌های مقاوم در برابر کوانتوم [48]

- ارزیابی عملکرد و امنیت شبکه‌ی اصلاح‌شده تحت حملات شبیه‌سازی‌شده کوانتومی

مرحله ۲: تطبیق شبکه لایت‌نینگ (در حال انجام)

- توسعه‌ی مدل شبکه هوشمند شامل گره‌ها (خانه‌ها، پست‌های توزیع) و نحوه‌ی اتصال آن‌ها
- طراحی یک الگوریتم مسیریابی برای برقراری کانال‌های ارتباطی در شبکه لایت‌نینگ با استفاده از گره‌های واسطه
- پیاده‌سازی شبکه لایت‌نینگ اصلاح‌شده در یک محیط شبیه‌سازی‌شده

مرحله ۳: شبیه‌سازی و ارزیابی (در انتظار اجرا)

- استفاده از ابزارهایی مانند MiniNet ، Omnet++ و Hyperledger Fabric برای شبیه‌سازی سیستم پیشنهادی
- ارزیابی عملکرد سیستم از نظر توان عملیاتی، تأخیر، امنیت و بهره‌وری انرژی
- مقایسه‌ی سیستم پیشنهادی با راهکارهای موجود مبتنی بر بلاکچین برای معاملات انرژی

مشارکت‌های مورد انتظار

۱. ارائه‌ی یک شبکه بیت‌کوین مقاوم در برابر کوانتوم برای معاملات انرژی امن و غیرمتمرکز
۲. طراحی معماری شبکه لایتنینگ متناسب با نیازهای مقیاس‌پذیری شبکه‌های هوشمند
۳. ارائه‌ی یک الگوریتم جدید برای مسیریابی تراکنش‌های مبتنی بر گره‌های واسطه در شبکه‌های نیمه‌متصل
۴. توسعه‌ی یک چارچوب ارزیابی جامع برای تحلیل معاملات انرژی مبتنی بر بلاکچین در شبکه‌های هوشمند

چالش‌های احتمالی

۱. پیچیدگی رمزنگاری مقاوم در برابر کوانتوم: سربار محاسباتی بالای این الگوریتم‌ها ممکن است بر عملکرد شبکه تأثیر بگذارد.
۲. کارایی الگوریتم مسیریابی: تضمین مسیریابی کارآمد در یک محیط شبکه هوشمند پویا و نیمه‌متصل یک چالش محسوب می‌شود.
۳. دقت شبیه‌سازی: مدل‌سازی دقیق پیچیدگی‌های شبکه‌های هوشمند واقعی در محیط شبیه‌سازی این تحقیق با هدف ارتقای فناوری بلاکچین از طریق ایجاد یک شبکه بیت‌کوین مقاوم در برابر کوانتوم و ادغام آن با شبکه لایتنینگ برای معاملات انرژی در شبکه‌های هوشمند انجام می‌شود. راهکار پیشنهادی چالش‌های مقیاس‌پذیری و امنیت را برطرف کرده و چارچوبی مقاوم برای سیستم‌های شبکه هوشمند آینده ارائه می‌دهد.

4- همکاران پروژه

- 1- احمد خونساري (دانشیار دانشکده فنی، دانشگاه تهران)
- 2- حسن خالقی راد (دانشجوی دکتری، دانشگاه تهران)
- 3- نگار رضایی (دانشجوی دکتری، دانشگاه تهران)
- 4- احمد رئیسی (دانشجوی دکتری، دانشگاه تهران)

5- فهرست منابع و مراجع

- [1] C. Chen, J. Wu, H. Lin, W. Chen, and Z. Zheng, "A secure and efficient blockchain-based data trading approach for internet of vehicles," IEEE Transactions on Vehicular Technology, vol.68, no.9, pp.9110–9121, 2019.
- [2] W. Xiong and L. Xiong, "Data trading certification based on consortium blockchain and smart contracts," IEEE Access, vol.9, pp.3482–3496, 2021.
- [3] A. Sadiq, M. U. Javed, R. Khalid, A. Almogren, M. Shafiq, and N. Javaid, "Blockchain based data and energy trading in internet of electric vehicles," IEEE Access, vol.9, pp.7000–7020, 2021.
- [4] J. Wang, Z. Yan, H. Wang, T. Li, and W. Pedrycz, "A survey on trust models in heterogeneous networks," IEEE Communications Surveys and Tutorials, vol.24, no.4, pp.2127–2162, 2022.
- [5] A. Jøsang. Subjective Logic. Springer, 2016.
- [6] R. Ismail and A. Jøsang, "The beta reputation system," in Bled eConference, 2002.
- [7] J. Wang, X. Jing, Z. Yan, Y. Fu, W. Pedrycz, and L. T. Yang, "A survey on trust evaluation based on machine learning," ACM Comput. Surv., vol.53, sep 2020.
- [8] G. Liu, C. Li, and Q. Yang, "Neuralwalk: Trust assessment in online social networks with neural networks," in IEEE INFOCOM 2019- IEEE Conference on Computer Communications, pp.1999–2007, 2019.
- [9] Z. Yang, W. Pei, M. Chen, and C. Yue, "Wtagraph: Web tracking and advertising detection using graph neural networks," in 2022 IEEE Symposium on Security and Privacy (SP), pp.1540–1557, 2022.
- [10] Y. Cao, H. Jiang, Y. Deng, J. Wu, P. Zhou, and W. Luo, "Detecting and mitigating ddos attacks in sdn using spatial-temporal graph convolutional network," IEEE Transactions on Dependable and Secure Computing, vol.19, no.6, pp.3855–3872, 2022. ۵۲

- [11] C. Huo, D. He, C. Liang, D. Jin, T. Qiu, and L. Wu, “Trustgnn: Graph neural network-based trust evaluation via learnable propagative and composable nature,” *IEEE Transactions on Neural Networks and Learning Systems*, pp.1–13, 2023.
- [12] Z. Yu, D. Jin, C. Huo, Z. Wang, X. Liu, H. Qi, J. Wu, and L. Wu, “Kgtrust: Evaluating trustworthiness of snot via knowledge enhanced graph neural networks,” in *Proceedings of the ACM Web Conference 2023, WWW ’23*, (New York, NY, USA), p.727–736, Association for Computing Machinery, 2023.
- [13] W. Lin, Z. Gao, and B. Li, “Guardian: Evaluating trust in online social networks with graph convolutional networks,” in *IEEE INFOCOM 2020- IEEE Conference on Computer Communications*, pp.914–923, 2020.
- [14] N. Jiang, J. Wen, J. Li, X. Liu, and D. Jin, “Gatrust: A multi-aspect graph attention network model for trust assessment in osns,” *IEEE Transactions on Knowledge and Data Engineering*, vol.35, no.6, pp.5865–5878, 2023.
- [15] W.LinandB.Li, “Medley: Predicting social trust in time-varying online social networks,” in *IEEE INFOCOM2021- IEEE Conference on Computer Communications*, pp.1–10, 2021.
- [16] J.Wang,Z.Yan,J.Lan,E.Bertino, andW.Pedrycz, “Trustguard: Gnn-basedrobustandexplainable trust evaluation with dynamicity support,” *IEEE Transactions on Dependable and Secure Computing*, pp.1–18, 2024.
- [17] da Xu, chuanwei ruan, evren korpeoglu, sushant kumar, and kannan achan, “Inductive representation learning on temporal graphs,” in *International Conference on Learning Representations*, 2020.
- [18] B. Wang, J. Jia, and N. Z. Gong, “Graph-based security and privacy analytics via collective classification with joint weight learning and propagation,” in *ISOC Network and Distributed System Security Symposium (NDSS)*, 2019.
- [19] Y. Liu, W. Zhou, and H. Chen, “Efficiently promoting product online outcome: An iterative rating attack utilizing product and market property,” *IEEE Transactions on Information Forensics and Security*, vol.12, no.6, pp.1444–1457, 2017.
- [20] A. F. i. Author’s Last name, “Fake it till you make it: Reputation, competition, and yelp review fraud,” *Journal Name*, vol.Volume Number, no.Issue Number, p.Page Range, 2023. [
- [21] W. C. K. W. R. Y. S. W. H. Z. Z. W. M. J. J. Y. X. S. D. Han, Z. Wang and X. Yin, “Anomaly detection in the open world: Normality shift detection, explanation, and adaptation,” 2023.

- [22] A. Sankar, Y. Wu, L. Gou, W. Zhang, and H. Yang, "Dysat: Deep neural representation learning on dynamic graphs via self-attention networks," in *Proceedings of the 13th international conference on web search and data mining*, pp.519–527, 2020.
- [23] A. Nandakumar, S. Shao, and B. Nikolic, "Accelerating Deep Learning on Heterogenous Architectures," *Electrical Engineering and Computer Sciences, University of California, Berkeley*, Technical Report No. UCB/EECS-2022-100, May 13, 2022.
- [24] D. Narayanan, K. Santhanam, F. Kazhamiaka, A. Phanishayee, and M. Zaharia, "{Heterogeneity-Aware} cluster scheduling policies for deep learning workloads," in *14th USENIX Symposium on Operating Systems Design and Implementation (OSDI 20)*, 2020, pp. 481-498 .
- [25] A. Shawahna, S. M. Sait, and A. El-Maleh, "FPGA-based accelerators of deep learning networks for learning and classification: A review," *ieee Access*, vol. 7, pp. 7823-7859, 2018.
- [26] K. Mahajan *et al.*, "Themis: Fair and efficient {GPU} cluster scheduling," in *17th USENIX Symposium on Networked Systems Design and Implementation (NSDI 20)*, 2020, pp. 289-304 .
- [27] J. Gu *et al.*, "Tiresias :A {GPU} cluster manager for distributed deep learning," in *16th USENIX Symposium on Networked Systems Design and Implementation (NSDI 19)*, 2019, pp. 485-500 .
- [28] T. N. Le, X. Sun, M. Chowdhury, and Z. Liu, "Allox: compute allocation in hybrid clusters ", in *Proceedings of the fifteenth european conference on computer Systems*, 2020, pp. 1-16 .
- [29] A. Verma, L. Pedrosa, M. Korupolu, D. Oppenheimer, E. Tune, and J. Wilkes, "Large-scale cluster management at Google with Borg," in *Proceedings of the tenth european conference on computer systems*, 2015, pp. 1-17 .
- [30] M. Tushev, G. Williams, and A. Mahmoud, "Using GitHub in large software engineering classes. An exploratory case study," *Computer Science Education*, vol. 30, no. 2, pp. 155-186, 2020.
- [31] W. Xiao *et al.*, "Gandiva: Introspective cluster scheduling for deep learning," in *13th USENIX Symposium on Operating Systems Design and Implementation (OSDI 18)*, 2018, pp. 595-610 .
- [32] M. Jeon, S. Venkataraman, A. Phanishayee, J. Qian, W. Xiao, and F. Yang, "Analysis of {Large-Scale}{Multi-Tenant}{GPU} clusters for {DNN} training workloads," in *2019 USENIX Annual Technical Conference (USENIX ATC 19)*, 2019, pp. 947-960 .
- [33] Y. Peng, Y. Bao, Y. Chen, C. Wu, and C. Guo, "Optimus: an efficient dynamic resource scheduler for deep learning clusters," in *Proceedings of the Thirteenth EuroSys Conference*, 2018, pp. 1-14 .

- [34] W. Gao, Z. Ye, P. Sun, Y. Wen, and T. Zhang, "Chronus: A novel deadline-aware scheduler for deep learning training jobs," in *Proceedings of the ACM Symposium on Cloud Computing*, 2021, pp. 609-623 .
- [35] P. Zhou, X. He, S. Luo, H. Yu, and G. Sun, "JPAS: Job-progress-aware flow scheduling for deep learning clusters," *Journal of Network and Computer Applications*, vol. 158, p. 102590, 2020.
- [36] Q. Hu, P. Sun, S. Yan, Y. Wen, and T. Zhang, "Characterization and prediction of deep learning workloads in large-scale gpu datacenters," in *Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis*, 2021, pp. 1-15 .
- [37] Q. Weng *et al.*, "{MLaaS} in the wild: Workload analysis and scheduling in {Large-Scale} heterogeneous {GPU} clusters," in *19th USENIX Symposium on Networked Systems Design and Implementation (NSDI 22)*, 2022, pp. 945-960 .
- [38] J. Cao, R. Sen, M. Interlandi, J. Arulraj, and H. Kim, "GPU Database Systems Characterization and Optimization," *Proceedings of the VLDB Endowment*, vol. 17, no. 3, pp. 441-454, 2023.
- [39] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2008.
- [40] L. e. a. Chen, "Report on Post-Quantum Cryptography.," *NIST*, 2016.
- [41] J. & S. I. Alwen, "On the Security and Scalability of Bitcoin's Lightning Network," 2021.
- [42] N. Z. & S. D. Aitzhan, "Security and Privacy in Decentralized Energy Trading through Multi-Signatures, Blockchain, and Anonymous Messaging Streams," 2018.
- [43] F. e. a. Armknecht, "The Soundness of Provably Secure Blockchains: An Analysis of Lightweight Bitcoin Clients," 2015.
- [44] X. e. a. Gao, "GridMonitoring: Secured Sovereign Blockchain Based Monitoring on Smart Grid.," 2018.
- [45] X. e. a. Liang, " Integrating Blockchain for Data Sharing and Collaboration in Mobile Healthcare Applications.," 2017.
- [46] M. e. a. Andrychowicz, "Secure Multiparty Computations on Bitcoin," 2014.
- [47] M. e. a. Conti, " A Survey on Security and Privacy Issues of Bitcoin," 2018.
- [48] D. e. a. Yaga, " Blockchain Technology Overview.," *NIST*, 2019.