

دریافت مقاله: ۱۴۰۳/۰۴/۰۵

پذیرش مقاله: ۱۴۰۳/۰۴/۳۰

نوع مقاله: پژوهشی

بهبود یادگیری ائتلافی در خودروهای خودران با استفاده از الگوریتم تاریخچه خطا و وزن‌دهی نمایی: یک رویکرد منصفانه

امیر ملانژاد

گروه کامپیوتر، واحد قم، دانشگاه آزاد اسلامی، قم، ایران
پست الکترونیکی: amir.mollanejad@gmail.com

احمد حبیبی زاد نوین*

استادیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، واحد تبریز، تبریز، ایران
پست الکترونیکی: a.habibizad@srbiau.ac.ir

شمس اله قنبری

استادیار دانشکده مهندسی، دانشگاه آزاد اسلامی واحد آشتیان، آشتیان، ایران
پست الکترونیکی: myrshg@gmail.com

چکیده

داده‌های نامتوازن نیز عملکرد بهتری داشته باشند. برای ارزیابی عملکرد الگوریتم، آزمایش‌های گسترده‌ای بر روی مجموعه داده شبیه‌سازی شده KITTI انجام دادیم. نتایج نشان می‌دهد که الگوریتم پیشنهادی در مقایسه با الگوریتم‌های استاندارد مانند FedAvg، به ۳ درصد دقت بالاتر دست می‌یابد. همچنین، استفاده از وزن‌دهی نمایی به بهبود انصاف در فرآیند یادگیری کمک می‌کند، به گونه‌ای که اختلاف واریانس دقت الگوریتم پیشنهادی با بقیه الگوریتم‌ها در بهترین حالت ۴۰۰ می‌باشد. **واژه‌های کلیدی:** یادگیری ائتلافی، انصاف، سابقه خطا، وزن‌دهی نمایی، خودروهای خودران

۱. مقدمه

پیشرفت‌های اخیر در یادگیری ماشینی و هوش مصنوعی، استفاده از فناوری در رانندگی را بسیار مهم

در یادگیری ائتلافی خودروهای خودران، چالش اصلی عدم توازن و انصاف در دسترسی به داده‌های مختلف از سوی مشترکین است که می‌تواند منجر به کاهش دقت مدل و افزایش نوسانات در فرآیند یادگیری شود. این مسئله به ویژه زمانی که داده‌ها به صورت نابرابر بین مشترکین توزیع شده‌اند، نمایان‌تر می‌شود. برای رفع این چالش، یک الگوریتم جدید مبتنی بر تاریخچه خطا و وزن‌دهی نمایی پیشنهاد می‌دهیم. الگوریتم پیشنهادی از تاریخچه خطای n دور اخیر استفاده می‌کند و نرمال شده خطای هر مشترک را در گرادیان ارسالی ضرب می‌کند. این رویکرد باعث می‌شود تا از نوسانات شدید در به‌روزرسانی وزن‌ها جلوگیری شود و بهبود دقت و همگرایی سریع‌تر حاصل گردد. علاوه بر این، وزن‌دهی نمایی کمک می‌کند تا انصاف در فرآیند یادگیری حفظ شود، به گونه‌ای که مشترکین با

* نویسنده مسئول

[۸]. بررسی فناوری‌های یادگیری عمیق مورد استفاده در رانندگی خودمختار نشان‌دهنده پیشرفت‌های سریع در این زمینه است و به درک بهتر نقاط قوت و محدودیت‌های رویکردهای یادگیری عمیق و هوش مصنوعی کمک می‌کند [۹]. با توجه به مطالب فوق، یادگیری ماشین نقش مهمی در خودروهای خودران دارد اما با چالش‌هایی مواجه است. این چالش‌ها شامل استفاده کارآمد از منابع با حفظ امنیت قوی با سطحی از حریم خصوصی، میزان بالای انتقال داده، استفاده از پهنای باند و تأخیر کم است.

یکی از راه‌حل‌های مقابله با چالش‌های یادگیری ماشین، استفاده از یادگیری ائتلافی در خودروهای خودران است. استفاده از یادگیری ائتلافی برای شناسایی اشیاء می‌تواند به حل مشکلات تقارن عددی و تعمیم کمک کند و روش انتقال می‌تواند عملکرد را تحت تغییرات ظاهری بهبود بخشد [۱۰]. همچنین می‌تواند یادگیری قدرتمندی را برای ماشین‌های خودران ارائه دهد که از نظر ابزارهای ارتباطی کارآمد است و حفاظت از حریم خصوصی یادگیری مشارکتی می‌تواند به کاهش هزینه‌های ارتباطی و حفظ حریم خصوصی و افزایش سرعت آموزش کمک کند. یادگیری ائتلافی در یک ماشین خودران خوب به نظر می‌رسد. زیرا، به کاهش خطاهای آموزشی کمک می‌کند و دقت را در عین حفظ حریم خصوصی افزایش می‌دهد. این روش می‌تواند به حل مشکلات مربوط به یکپارچگی داده‌ها و ارتباطات کلی کمک کند و در عین حال فرآیند یادگیری را بهبود بخشد و ارتباطات را کاهش دهد [۱۱-۱۵]. علاوه بر این، یادگیری ائتلافی می‌تواند به انتقال اطلاعات بین ابزارهای مختلف در محیط، بهبود ایمنی و کاهش تصادفات کمک کند [۱۰، ۱۶-۲۱]. کارهای متعددی در حوزه خودروهای خوران از یادگیری ائتلافی استفاده کرده است [۱۱-۱۵]. یکی از چالش‌هایی که در یادگیری ائتلافی مطرح است انصاف در آموزش می‌باشد. این چالش به این دلیل مهم است که در یادگیری ائتلافی مشترکین توزیع شده و زیاد می‌باشند. انصاف آموزشی در یادگیری

کرده است. یکی از بزرگترین چالش‌ها در رانندگی خودران، توسعه یک مدل ماشین واقعی است که می‌تواند عملکرد یک ماشین مسابقه را تقلید کند. این مدل‌ها اغلب غیر خطی، پیچیده و دشوار هستند. برای حل این مشکل، از یک مدل نامگذاری ساده که با استفاده از معیارها و ابزارهای یادگیری ماشین توسعه یافته است، استفاده می‌شود. این روش منجر به توسعه مدل مبتنی بر آموزش و داده‌های بر خط شد که از رگرسیون گاوسی برای تخمین مدل باقیمانده و پیش بینی رفتار رانندگی استفاده می‌کند [۱]. شبکه‌های وسایل نقلیه نوظهور با استفاده از یادگیری ماشین، به حل مسائل چالش‌برانگیز سنتی کمک کرده و مسیر را برای رانندگی خودمختار در عصر سیستم‌های مخابراتی نسل پنجم (5G) هموار می‌سازند [۲]. یادگیری ماشین در وسایل نقلیه خودران نه تنها می‌تواند به کاهش ترافیک و بهبود کارایی سوخت کمک کند، بلکه دسترسی افراد با توانایی محدود به حمل‌ونقل را نیز بهبود می‌بخشد. همچنین این فناوری منجر به راه‌حل‌های حمل‌ونقل پایدارتر می‌شود [۳]. یادگیری ماشین فعال نیز می‌تواند برای تولید داده‌های آزمایشی مصنوعی با کیفیت بالا که می‌تواند تکنیک‌های موجود مانند آزمایش‌های سخت‌افزاری و آزمایش‌های جاده‌ای را تکمیل و بهبود بخشد، استفاده شود [۴]. استفاده از «خودمختاری مینیاتوری» برای آزمایش روش‌های یادگیری ماشین در مقیاس کوچک می‌تواند برای ارزیابی ایمنی و کارآمد بودن راه‌حل‌های پیشنهادی مفید باشد [۵]. یادگیری ماشین به عنوان یک شاخه از هوش مصنوعی، در زمینه‌های مختلفی از جمله رانندگی خودمختار به کار گرفته شده است و نشان‌دهنده حال و آینده نگرش به جهان است [۶]. یک سیستم رانندگی خودمختار مبتنی بر انسان نیز می‌تواند با استفاده از الگوریتم‌های یادگیری ماشین دو مرحله‌ای توسعه یابد که در آن ویژگی‌های رانندگی و انسانی ترکیب می‌شوند [۷]. محیط‌های یادگیری ماشین برای ارزیابی نرم‌افزار رانندگی خودمختار می‌توانند به توسعه و آزمایش ایمن وسایل نقلیه خودران کمک کنند

یافته بر اساس تاریخچه خطا ارائه می‌دهیم که می‌تواند به طور قابل توجهی بهبود انصاف در یادگیری مدل‌های خودروهای خودران را افزایش دهد. دستاوردهای اصلی این پژوهش به شرح زیر است:

- الگوریتم یادگیری ائتلافی مبتنی بر تاریخچه خطا: ما یک رویکرد جدید برای به‌روزرسانی مدل‌های یادگیری ائتلافی پیشنهاد داده‌ایم که از تاریخچه خطاهای هر مشترک استفاده می‌کند. این روش با وزن‌دهی نمایی به خطاهای گذشته، اجازه می‌دهد تا اطلاعات بیشتری از مشترکین با عملکرد پایین‌تر جمع‌آوری شود و باعث افزایش انصاف در یادگیری مدل شود.
- کاهش بار محاسباتی مشترکین: با انتقال بخش عمده‌ای از محاسبات به کارساز، بار محاسباتی مشترکین کاهش یافته و به این ترتیب، استفاده از دستگاه‌های با توان محاسباتی پایین‌تر نیز امکان‌پذیر می‌شود.
- مقایسه با الگوریتم‌های موجود: عملکرد الگوریتم پیشنهادی در مقایسه با الگوریتم‌های معروفی مانند Fe-dAvg و AFL، بر روی مجموعه داده‌های KITTI نشان داده شد. نتایج تجربی نشان‌دهنده بهبود قابل توجه در دقت آزمون و کاهش فاصله تا بهینه تجربی بوده است.
- تضمین انصاف: الگوریتم پیشنهادی با تأکید بر بهبود عملکرد مشترکین با دقت پایین‌تر، به طور قابل توجهی واریانس نتایج را کاهش داده و توزیع یکنواخت‌تری از دقت بین مشترکین ایجاد کرده است.
- این دستاوردها نشان می‌دهند که الگوریتم پیشنهادی می‌تواند به عنوان یک رویکرد مؤثر برای بهبود انصاف و کارایی مدل‌های یادگیری ائتلافی در کاربردهای حیاتی مانند خودروهای خودران مورد استفاده قرار گیرد.
- در بخش ۲، کارهای گذشته در مورد انصاف یادگیری ائتلافی در خودروهای خودران پرداخته می‌شود. جزئیات الگوریتم پیشنهادی، به‌ویژه با تمرکز بر موضوع انصاف در بخش ۳ توضیح داده شده‌اند. در بخش ۴، به ادبیات موضوع در زمینه تحقیق پرداخته

ائتلافی به دلیل ماهیت ناهمگن داده‌های توزیع شده بسیار مهم است و اطمینان از انصاف بین عوامل محلی را چالش برانگیز می‌سازد. هدف جلوگیری از سناریوهایی است که در آن عوامل با داده‌های با کیفیت بالا به طور ناعادلانه تحت تأثیر کسانی با داده‌های با کیفیت پایین قرار می‌گیرند، و اطمینان حاصل شود که همه شرکت‌کنندگان بدون فدا کردن عملکرد به طور معنادار مشارکت می‌کنند و دقت عمل بالایی دارند [۲۲].

همان‌طور که اشاره شد چالش انصاف جزو چالش‌های مهم یادگیری ائتلافی می‌باشد. برای ارائه راه‌حل به چالش مذکور روش‌های مختلفی پیشنهاد شده‌است. یکی از کارهای انجام شده در این حوزه مقاله [۱۵] می‌باشد. این مقاله یک الگوریتم یادگیری ائتلافی منصفانه و کارآمد را برای رانندگی خودکار معرفی می‌کند و به چالش‌های مربوط به توزیع نامتعادل داده‌ها و شرایط مختلف کانال پرداخته می‌شود. این روش با استفاده از رویکرد شخصی برای دوره‌های آموزشی محلی، کاهش زمان آموزش محلی، افزایش سرعت همگرایی و دستیابی به انصاف در هزینه انرژی در بین وسایل نقلیه متصل و خودران (CAV)، انصاف را تضمین می‌کند. CAVها حجم داده و فاصله خود را به کارساز بارگذاری می‌کنند، که سپس تعداد دوره‌های آموزش محلی برای هر CAV را بر اساس عبارات خاص محاسبه می‌کند و از سازگاری در هزینه‌های کلی زمان و انرژی اطمینان می‌دهد. این روش به طور خاص بر حفظ انصاف و کارایی آموزش، رفع اختلافات در هزینه آموزش محلی و مدت بارگذاری مدل بین CAVهای مختلف تمرکز دارد و در نهایت کارایی و انصاف فرآیند FL برای سناریوهای رانندگی خودکار را افزایش می‌دهد. در حالی که این مقاله بر انصاف در هزینه انرژی و کاهش تعداد دورها تأکید دارد، اما به طور صریح به ارزیابی دقیق یا تجزیه و تحلیل انصاف واریانس در الگوریتم FL اشاره نمی‌کند.

در این مقاله، ما یک الگوریتم یادگیری ائتلافی بهبود

می‌شود. در بخش ۵ یک ارزیابی تجربی کامل از روش پیشنهادی بر روی مجموعه داده‌ها ارائه می‌شود. در نهایت، در بخش ۶ نتیجه گیری انجام می‌شود.

۲. کارهای گذشته

در این بخش، به بررسی پیشینه یادگیری ائتلافی برای راندگی خودمختار می‌پردازیم. یادگیری ائتلافی به عنوان رویکردی نوین در حوزه یادگیری ماشینی مطرح شده است که امکان آموزش مدل‌های یادگیری عمیق را بدون نیاز به مرکزیت داده‌ها و با حفظ حریم خصوصی کاربران فراهم می‌کند.

در روش ارائه شده در مقاله [۱۷]، تقسیم بندی معنایی برای راندگی خودکار، اختصاص پیکسل به دسته‌ها بسیار مهم است، اما نگرانی‌های حریم خصوصی از استفاده از داده‌های حساس ناشی می‌شود. یادگیری ائتلافی با یادگیری یک مدل جهانی در عین حفظ حریم خصوصی در دستگاه‌های از راه دور، این موضوع را حل می‌کند. FedDrive یک معیار برای FL در تقسیم بندی معنایی با در نظر گرفتن ناهمگونی آماری و چالش‌های تعمیم دامنه معرفی می‌کند. الگوریتم‌های پیشرفته FL، با تکنیک‌های انتقال سبک، تعمیم را افزایش می‌دهند و بر اهمیت پردازش آمار نرمال سازی تأکید می‌کنند، مورد ارزیابی قرار می‌گیرند. این مطالعه عملکرد بهبود یافته در مدیریت تغییرات ظاهری را نشان می‌دهد. عدم بحث در مورد هزینه‌های محاسباتی و ارتباطات مرتبط با یادگیری ائتلافی، که می‌تواند در پیاده‌سازی‌های دنیای واقعی قابل توجه باشد. این مقاله به آسیب‌پذیری‌های امنیتی بالقوه سیستم‌های یادگیری ائتلافی پرداخته نمی‌شود، که می‌توانند توسط عوامل مخرب برای به خطر انداختن حریم خصوصی مورد سوء استفاده قرار گیرند. اکتشاف محدود از مقیاس‌پذیری معیار پیشنهادی FedDrive به مجموعه داده‌های بزرگتر یا وظایف تقسیم‌بندی پیچیده‌تر، که می‌تواند بر کاربرد عملی

آن در سناریوهای مختلف راندگی خودکار تأثیر بگذارد. چارچوب FedSUP [۲۳] به عنوان یک چارچوب مشترک-edge-cloud برای تشخیص حریم خصوصی و خستگی کارآمد در سناریوهای اینترنت وسایل نقلیه (IoV) پیشنهاد شده است. از یادگیری ائتلافی برای بهینه سازی مدل‌ها به صورت پویا و در عین حفظ حریم خصوصی داده‌های لبه استفاده می‌کند. علاوه بر این، یک راهبرد تقریب شبکه عصبی هم‌آمیختگی بیزی (BCNN) بر روی مشترکین و یک الگوریتم تجمیع وزن دار عدم قطعیت بر روی ابر، کارایی آموزش مدل را افزایش داده و از روش‌های اصلی در آزمایش‌های بهتر عمل می‌کند. پیاده‌سازی FedsUP ممکن است به دلیل نیاز به همکاری بین مشترک، لبه، و کارساز ابری پیچیده باشد که به طور بالقوه نیاز به تخصص تخصصی برای استقرار دارد. منابع محاسباتی قابل توجهی ممکن است برای پشتیبانی از راهبرد تقریب BCNN و الگوریتم تجمع مورد نیاز باشد، که محدودیت‌هایی را در محیط‌های محدود منابع ایجاد می‌کند. راه‌اندازی چارچوب در ابتدا ممکن است شامل سر بار اضافی در پیکربندی سازوکارهای ارتباطی و حریم خصوصی باشد و به طور بالقوه زمان استقرار را افزایش دهد. ممکن است چالش‌هایی در دستیابی به دقت و کارایی مطلوب در سناریوهای مختلف راندگی وجود داشته باشد. علی‌رغم تلاش برای کاهش سر بار ارتباطی، مشکلات تأخیر ممکن است بر تشخیص خستگی در زمان واقعی تأثیر بگذارد.

مقاله [۲۴] بر تشخیص فعالیت راننده (DAR) با استفاده از یادگیری ائتلافی در دستگاه‌های لبه تمرکز دارد. DAR به دلیل تمایز خوب بین اقدامات راننده چالش برانگیز است. FL آموزش مدل مشارکتی را در عین حفظ حریم خصوصی داده‌ها و کاهش نیازهای ارتباطی امکان‌پذیر می‌کند. مدل پیشنهادی DAR مبتنی بر FL بر روی دو مجموعه داده مقایسه شده است که عملکرد رقابتی را در تنظیمات متمرکز و غیرمتمرکز نشان می‌دهد. کارایی مدل به دلیل

به شدت به دقت و بازنمایی مجموعه داده‌های دنیای واقعی که برای شبیه‌سازی استفاده می‌شود بستگی دارد. همچنین مقیاس‌پذیری رویکرد به مجموعه داده‌های بزرگتر یا سناریوهای پیچیده‌تر در مقاله به طور گسترده مورد بحث قرار نمی‌گیرد.

مقاله [۲۰] روشی جدید به نام BDFL (روش یادگیری ائتلافی غیرمتمرکز مقاوم به نقص بیزانس)^۲ را معرفی می‌کند که برای وسایل نقلیه خودران برای رفع نگرانی‌های حریم خصوصی در داده‌های آموزشی طراحی شده است. BDFL از رویکرد یادگیری ائتلافی هم‌تا به هم‌تا با تحمل مقاوم به نقص بیزانس استفاده می‌کند و امنیت را افزایش می‌دهد. طرح اشتراک‌گذاری مخفی قابل تأیید عمومی^۳ (PVSS) برای محافظت از مدل‌ها استفاده می‌شود و امکان تأیید سهام رمزگذاری شده را فراهم می‌کند. ارزیابی بر روی مجموعه داده MNIST امکان‌سنجی FL غیرمتمرکز در AV‌ها را نشان می‌دهد، در حالی که BDFL از سایر روش‌های FL مبتنی بر BFT بهتر عمل می‌کند. نتایج تجربی بر روی مجموعه داده KITTی اثر بخشی BDFL در بهبود تشخیص چند شیء در سناریوهای AV را نشان می‌دهد. پیاده‌سازی تحمل خطای بیزانسی و FL غیرمتمرکز ممکن است پیچیدگی اضافی و سربار محاسباتی را ایجاد کند. استفاده از طرح‌های رمزنگاری پیشرفته مانند PVSS می‌تواند به منابع محاسباتی قابل توجهی نیاز داشته باشد و بر عملکرد زمان واقعی در محیط‌های AV محدود منابع تأثیر بگذارد.

مقاله [۲۶] یک چارچوب یادگیری ائتلافی و سایبرتوین با کمک حافظه پنهان (FLCC) را برای ارائه خدمات شخصی در 6G-V2X پیشنهاد می‌کند. یک مدل یادگیری ائتلافی دو لایه برای اینترنت وسایل نقلیه (IoV) و ارتباطات V2X در 6G معرفی شده است که دقت و کارایی یادگیری را افزایش می‌دهد. چارچوب FLOR برای تخلیه محاسبات و مدیریت منابع در 6G-V2X با استفاده از حساب شبکه تصادفی و ائتلافی Q-Learning برای تخصیص بهینه منابع ارائه شده

محدود بودن منابع محاسباتی در دستگاه‌های لبه خودرو برجسته شده است که به طور بالقوه بر پیچیدگی و عملکرد مدل تأثیر می‌گذارد. آموزش مدل‌های قدرتمند DAR نیاز به منابع داده متنوع دارد که ممکن است با رویکرد FL پیشنهادی به طور کامل مورد توجه قرار نگیرند و بر تعمیم و استحکام مدل تأثیر می‌گذارد.

مقاله [۲۵] بر افزایش ایمنی وسایل نقلیه خودران (AV) در شرایط نامساعد آب و هوایی، به ویژه در بارش برف سنگین، با استفاده از آموزش ائتلافی YOLO CNN متمرکز است. تشخیص جسم برای AV‌ها بسیار مهم است، اما تکنیک‌های موجود در آب و هوای نامطلوب مشکل دارند. این مطالعه سیستمی را با ترکیب YOLO CNN و Federated Learning برای بهبود دقت تشخیص در زمان واقعی در آب و هوای نامطلوب ارائه می‌دهد که بر روی مجموعه داده CADC معتبر است. نتایج نشان‌دهنده عملکرد برتر در مقایسه با مدل‌های سنتی مانند مدل غیرمتمرکز Gossip و مدل متمرکز است. راه‌حل‌های سنتی مانند مدل غیرمتمرکز Gossip و مدل متمرکز، در سناریوهای نامطلوب آب و هوایی عملکرد خوبی ندارند. نیاز به بهبود دقت تشخیص در زمان واقعی در شرایط نامساعد آب و هوایی با روش‌های فعلی به اندازه کافی برطرف نمی‌شود.

مقاله [۱۶] بر ذخیره سازی فعال محتوا در اتومبیل‌های خودران برای افزایش کیفیت تجربه (QoE) و کاهش هزینه‌های بازایی محتوا تمرکز دارد. سازوکار پیش‌بینی محبوبیت محتوا را با استفاده از توجه به خود و پیش‌بینی مبتنی بر LSTM در یک محیط ائتلافی سلسله مراتبی معرفی می‌کند. این مطالعه از یادگیری ائتلافی برای رفع نگرانی‌های حریم خصوصی هنگام به اشتراک گذاشتن محتوای محبوب در بین اتومبیل‌های خودران استفاده می‌کند. الگوریتم میانگین ائتلافی سلسله مراتبی (FedAvg) برای توسعه مدل‌های پیش‌بینی محبوبیت محتوای منطقه‌ای و جهانی در واحدهای کنار جاده (RSU) و ایستگاه‌های پایه ماکرو (MBS) استفاده می‌شود. اثر بخشی راهبرد ذخیره‌سازی

2-Byzantine-Fault-Tolerant

3-Publicly Verifiable Secret Sharing

است. یک چارچوب یادگیری ائتلافی پراکنده (DFL) برای اتومبیل‌های رانندگی خودران در 6G پیشنهاد شده است که چالش‌هایی مانند استحکام، امنیت و نشت حریم خصوصی را برطرف می‌کند. چالش‌های پیاده‌سازی مانند از دست دادن دقت مدل یادگیری ائتلافی به دلیل خطاهای بسته و تأخیر انتقال نیاز به رفع دارد.

مقاله [۲۷] یک رویکرد یادگیری تقویتی انتقال ائتلافی^۹ را برای رانندگی خودکار معرفی می‌کند. روش‌های سنتی یادگیری تقویتی شامل پیش‌آموزش با همتایان، انتقال به روبات‌های واقعی و بهینه‌سازی است. اینها وقت‌گیر هستند و اشتراک اطلاعات را محدود می‌کنند. روش پیشنهادی توانایی استخراج اطلاعات بیدرنگ از شرکت‌کننده در محیط‌های مختلف را فراهم می‌کند. این سیستم با شبیه‌ساز Microsoft AirSim و شبیه‌ساز ماشین NVIDIA JetsonTX2 برای جلوگیری از برخورد آزمایش شد و عملکرد خوبی در تبادل اطلاعات بین شبیه‌ساز و ماشین RC نشان داد. هماهنگی انتقال دانش بین عوامل متعدد در زمان واقعی می‌تواند پیچیدگی و چالش‌های بالقوه را در همگام‌سازی ایجاد کند.

مقاله [۱۵] یک الگوریتم یادگیری ائتلافی منصفانه و کارآمد برای رانندگی خودکار پیشنهاد می‌کند تا چالش‌های مرتبط با توزیع نامتوازن داده و شرایط متغیر کانال ارتباطی در وسایل نقلیه خودران متصل (CAV) را برطرف سازد [1a]. هدف این الگوریتم دستیابی به انصاف در زمان کل و هزینه انرژی بین CAVها با در نظر گرفتن حجم داده نگهداری شده توسط آنها و شرایط حاکم بر کانال است تا زمان آموزش محلی را کاهش داده و در عین حال اثربخشی آموزش را تضمین کند. این الگوریتم تعداد دوره‌های آموزش محلی شخصی‌سازی شده برای هر CAV را بر اساس شرایط کانال مربوطه آنها بهینه می‌کند، که منجر به بهبود سرعت همگرایی مدل جهانی و کاهش هزینه‌های انرژی می‌شود. این مقاله فرآیند FL را در بستر سیستم‌های اینترنت اشیا خودرو (IoV) و چارچوب

ارتباطی بین CAVها، واحدهای کنار جاده‌ای (RSU) و یک سرور مورد بحث قرار می‌دهد. این مقاله بر اهمیت راهبردهای تنظیم آموزش محلی شخصی‌سازی شده برای دستیابی به انصاف در هزینه‌های انرژی و زمان تأکید می‌کند. الگوریتم پیشنهادی با در نظر گرفتن هر دو جنبه ارتباطی و آموزش محلی، منجر به بهبود انصاف در هزینه انرژی و کارایی کلی زمان در طول فرآیند FL می‌شود. نتایج شبیه‌سازی نشان می‌دهد که الگوریتم پیشنهادی زمان مورد نیاز برای فرآیند FL را به طور قابل توجهی کاهش می‌دهد و در عین حال انصاف در هزینه‌های انرژی بین CAVها را حفظ می‌کند. این الگوریتم از نظر هزینه انرژی، زمان آموزش و همگرایی مدل، از روش‌های موجود پیشی می‌گیرد و کارایی آن را در کاربردهای رانندگی خودکار به نمایش می‌گذارد. الگوریتم FL شخصی‌سازی شده با نیاز به رویکردهای متناسب برای هر CAV، با در نظر گرفتن حجم داده و شرایط کانال آنها، سطحی از پیچیدگی را به همراه دارد. این سطح از شخصی‌سازی ممکن است نیازمند منابع محاسباتی اضافی و تخصص برای اجرا و نگهداری باشد.

در مقاله [۲۸]، روشی برای یادگیری سیاست‌های رانندگی خودمختار با استفاده از یادگیری ائتلافی عمیق (DFL) و شبکه رانندگی خودمختار ائتلافی (FADNet) ارائه شده است که نتایج تجربی بر روی سه مجموعه داده نشان می‌دهد این روش دقت بالاتری نسبت به روش‌های اخیر دارد و همچنین حریم خصوصی را حفظ می‌کند.

مقاله [۱۴] به بررسی استفاده از یادگیری تقویتی و یادگیری برنامه‌ریزی شده برای آموزش سیاست‌های رانندگی خودمختار بدون دانش پیشین در شبیه‌ساز رانندگی CARLA پرداخته است. این تحقیق نخستین کاری است که نتایج سازگاری از سیاست رانندگی خود را در تمام سناریوهای شهری ارائه شده توسط CARLA ارائه می‌دهد [۲].

در مقاله [۳]، مشکلات موجود در نوآوری‌های کنونی

جدول ۱ مروری بر ادبیات کاربرد FL در وسایل نقلیه خودران

مرجع مقاله	FL الگوریتم	الگوریتم یادگیری	مزایا	چالش	کاربرد	مجموعه داده	مدل داده
[۱۷]	FedAvg	BiSeNet V2	حفظ حریم خصوصی، بهبود توانایی تعمیم	همگن سازی آماری	تفکیک معنایی در خودروهای خودران	Cityscapes و IDDA	تصویر چند وجهی
[۲۳]	FedSub	Bayesian CNN	بهبود سازی مدل پویا	سربار راه اندازی اولیه و منابع محاسباتی زیاد	تشخیص خستگی راننده	Blinking Video Database و Eyeblink8	تصویر RGB
[۲۴]	FedGKT	ResNet-56	کاهش هزینه های ارتباطی	تنوع مجموعه داده ها	بهبود سیستم های کمک راننده با درک رفتار راننده	-	تصویر RGB
[۲۵]	FedSGD	YOLO CNN	بهبود نسبت روش های متمرکز	نیاز به بهبود دقت تشخیص در زمان واقعی در شرایط نامساعد آب و هوایی	تشخیص اجسام در شرایط نامساعد آب و هوایی	Canadian Adverse Driving Conditions Dataset	تصویر RGB
[۱۶]	FedAvg سلسله مراتبی	LSTM	بهبود استفاده از فضای حافظه پنهان	وابستگی به داده های دنیای واقعی	ذخیره سازی محتوای فعال در اتومبیل های خودران	real-world movielens 1M (ml-1m)	فیلم movielens
[۲۰]	BFT-based FL	k-nearest neighbors	بهبود عملکرد در تشخیص چند شیء	پیچیدگی اضافی و سربار محاسباتی	تشخیص چند شیء در خودروهای خودران	KITTI و MNIST	تصویر RGB
[۲۶]	FM-DRL	RBF و kNN	بر طرف کردن چالش نشأت حریم خصوصی	از دست دادن دقت مدل به دلیل خطاهای بسته و تأخیر انتقال	تشخیص شیء هوشمند در اتومبیل های خودران با قابلیت 6G	-	تصویر RGB
[۲۷]	Federated Transfer Reinforcement Learning	Deep Deterministic Policy Gradient (DDPG)	امکان انتقال بی درنگ دانش را بین وظایف مختلف RL در شبیه ساز یا محیط های واقعی با روبات ها	پیچیدگی	سیستم های رانندگی خودران	transferring knowledge between simulators and real-life environments	-
[۱۵]	SFRL	CNN	بهبود انصاف در یادگیری		وسایل نقلیه خودران متصل	CAV dataset	تصویر

پیشگیری از تصادف، ردیابی خط و شناسایی علائم جاده ای را توسعه داده است.

مقاله [۵] به چالش های یادگیری تقویتی چند عاملی در زمینه رانندگی خودمختار پرداخته و سه مشارکت اصلی در کار خود ارائه داده است: استفاده از تکرارهای گرایان سیاست بدون فرضیات مارکوفی، تجزیه و تحلیل مسئله به ترکیبی از سیاست برای خواسته ها و برنامه ریزی مسیر با محدودیت های سخت، و معرفی یک ساختار سلسله مراتبی زمانی که به آن «نمودار گزینه» گفته می شود.

مانند پیچیدگی بیش از حد معماری مدل برای دستیابی به نتایج پیشرفته مورد بررسی قرار گرفته و نشان داده شده است که استفاده از مدل های ساده تر می تواند نتایج خوبی به دست آورد و برای رانندگی خودمختار سطح ۱ مناسب است. مقاله [۴]، یک مورد عملی از یادگیری رانندگی خودمختار را با استفاده از یک وسیله نقلیه خودمختار مقیاس ۱۰/۱ ارائه می دهد که با استفاده از حسگرهای فراصوتی و کتابخانه بینایی کامپیوتری منبع باز (OpenCV) برای تشخیص و پردازش ویدئوی زنده جاده ای، سیستم های

مقاله [۱۳] نخستین کاربرد یادگیری تقویتی عمیق در رانندگی خودمختار را نشان می‌دهد که مدل آن قادر است در تعداد کمی از اپیزودهای آموزشی، سیاست پیروی از خط را با استفاده از یک تصویر تک چشمی به عنوان ورودی یاد بگیرد.

همان‌طور که در مرور کارهای گذشته دیدیم اکثر کارها بجز یک مورد چالش انصاف در خودروهای خودران برای یادگیری ائتلافی را در نظر نگرفته‌اند. برای چالش مطرح شده، در این تحقیق یک الگوریتم جدید برای بهبود انصاف و دقت در یادگیری ائتلافی برای خودروهای خودران با استفاده از تاریخچه خطا و وزن‌دهی نمایی معرفی می‌شود.

۳. ادبیات موضوع

خودروهای خودران به‌عنوان یکی از مهم‌ترین پیشرفت‌ها در صنعت حمل‌ونقل مدرن شناخته می‌شوند. این خودروها از فناوری‌های پیشرفته‌ای مانند هوش مصنوعی، یادگیری ماشین و سنسورهای پیچیده برای انجام وظایف رانندگی بدون دخالت انسان بهره می‌برند. یکی از چالش‌های اصلی در توسعه و بهبود عملکرد این خودروها، جمع‌آوری و پردازش حجم عظیمی از داده‌ها برای آموزش مدل‌های یادگیری ماشین است. در این زمینه، الگوریتم یادگیری ائتلافی به‌عنوان یک رویکرد نوین و موثر می‌تواند نقش مهمی ایفا کند.

۳-۱. یادگیری ائتلافی

یادگیری ائتلافی (Federated Learning) یک رویکرد توزیع‌شده برای یادگیری مدل‌های یادگیری ماشین است که در آن داده‌های آموزشی در دستگاه‌های محلی نگهداری می‌شوند و تنها به‌روزرسانی‌های مدل به کارساز مرکزی ارسال می‌گردد. این روش برای اولین بار توسط گوگل معرفی شد و هدف آن بهبود حریم خصوصی و امنیت داده‌هاست (McMahan et al., 2017). در یادگیری

ائتلافی، هر دستگاه مدل محلی خود را آموزش داده و تنها وزن‌های به‌روز شده مدل را به سرور مرکزی ارسال می‌کند. سپس کارساز مرکزی این وزن‌ها را جمع کرده و مدل به‌روزشده را به دستگاه‌های محلی ارسال می‌کند. هدف یادگیری ائتلافی کمینه کردن مقدار تابع $f(w)$ است.

$$\min_w f(w) = \sum_{k=1}^K p_k F_k(w) \quad (1)$$

که K تعداد مشترکین، w مدل جهانی، P_k احتمال گزینش مشترک k با شرط $P_k > 0$ و $\sum_{k=1}^K P_k = 1$ تابع هدف محلی مشترک k که به صورت $F_k(w) = \frac{1}{n_k} \sum_{j=1}^{n_k} l_{jk}(w)$ و n_k تعداد نمونه‌های محلی مشترک k است [۲۹]. مک ماهان و همکاران برای اولین بار از طریق الگوریتم FedAvg تابع هدف (۱) را معرفی کردند. در الگوریتم FedAvg کارساز مجموعه S_k را از k مشترک که $0 < k < K$ در هر دور برای آموزش مدل جهانی انتخاب می‌کند. مدل جهانی از جمع مدل‌های مشترکین انتخاب شده به صورت $W^t = \{w_1^t, w_2^t, \dots, w_k^t\}$ محاسبه می‌شود. الگوریتم FedAvg تعداد دورهای ارتباطی را کاهش داده اما از لحاظ انصاف دارای توزیع غیریکنواختی از دقت بین مشترکین است [مهری و کیو]. در این تحقیق الگوریتم پیشنهادی سعی بر بهینه کردن تعداد دورهای ارتباطی و همچنین توزیع یکنواخت دقت بین مشترکین (انصاف) را دارد.

۳-۲. انصاف

یکی از چالش‌های اصلی در یادگیری ائتلافی، عدم توازن در کیفیت داده‌های موجود در مشترکین مختلف است. این مشکل می‌تواند منجر به ناهماهنگی در دقت مدل‌های آموزش‌دیده شده در خودروهای مختلف شود. برخی از مشترکین ممکن است به دلیل داشتن داده‌های با کیفیت بالاتر، مدل‌های دقیق‌تری داشته باشند، در حالی که مشترکین دیگر با داده‌های کمتر و با کیفیت پایین‌تر،

که لازم است خطاهای گذشته را مدیریت کنیم. با افزایش فاصله زمانی، وزن‌های مربوط به خطاهای گذشته کاهش می‌یابند و این باعث می‌شود که تاثیر خطاهای دورتر از مدل را در میزان عمیقی که می‌خواهید در مدل خود دارید، دقیقاً تاثیر مدیریت کنید. همچنین وزن‌دهی نمایی به خوبی می‌تواند تاثیرات دقیق خطاها را در یادگیری حفظ کند. با استفاده از این روش، خطاهای جدید و مهم‌ترین خطاها به دلیل تاثیرات زود هنگام محاسبه شده و به چالش می‌کشند، تاثیری در عملکرد کلی مدل و محاسبه تخمینات گرادین به میزان مشخص می‌شوند. بر اساس مدل وزن‌دهی نمایی، خطاهایی که ناشی از نوسانات یا وابستگی‌های واضح مشاهده شده است، به صورت محدود می‌شود. این امر باعث می‌شود که مدل به صورت کلی از خطاها یا نوسانات معمولی بدون نیاز به پیکربندی زیاد که در محاسبات بهینه‌سازی و یا دیگر فرآیندهای یادگیری ائتلافی می‌توان به صورت بهینه‌سازی به دست آورد.

الگوریتم پیشنهادی شامل دو بخش اصلی است: مشترکین و کارساز. در این الگوریتم، محاسبات اصلی بر روی کارساز انجام می‌شود و مشترکین فقط داده‌های خطا و گرادین‌ها را به کارساز ارسال می‌کنند. کارساز با استفاده از خطاهای اخیر مشترکین، خطای وزن‌دهی شده را محاسبه کرده و مدل جهانی را به‌روزرسانی می‌کند.

راهکار پیشنهادی ما شامل چندین مرحله کلیدی است که به‌طور همزمان برای استفاده از اطلاعات خطای گذشته مشتریان به منظور بهبود عملکرد مدل یادگیری و افزایش انصاف در فرآیند یادگیری مورد استفاده قرار می‌گیرد. ابتدا، خطاهای گذشته هر مشترک جمع‌آوری می‌شود. این خطاها شامل لیستی از خطاهای مشترک i در n دور اخیر

می‌باشند، مانند: $E_i^{t-n+1}, E_i^{t-n+2} \dots E_i^t = Errors_i$

پارامتر وزن‌دهی نمایی (λ) عددی بین ۰ و ۱ است که تعیین می‌کند چقدر خطاهای اخیر نسبت به خطاهای قدیمی‌تر اهمیت دارند. هرچه λ به ۱ نزدیک‌تر باشد، تاثیر خطاهای اخیر بیشتر خواهد بود. همچنین، تعداد دورهای

مدلهایی با دقت کمتر خواهند داشت. برای سنجش انصاف از تعرف [۳۰] استفاده شده است بدین‌گونه که انصاف را توزیع یکنواخت کارائی فرض می‌کنیم. منظور از کارائی یعنی دقت آزمون بر روی مجموعه داده‌های انتخاب شده می‌باشد. اگر دو مدل آموزش دیده W و $\tilde{W}$ به ترتیب دارای توزیع دقت تستی $A = \{a_1, a_2, \dots, a_k\}$ و $\tilde{A} = \{\tilde{a}_1, \tilde{a}_2, \dots, \tilde{a}_k\}$ باشند آنگاه اگر $VAR(A) > VAR(\tilde{A})$ یعنی مدل $\tilde{W}$ مدل منصفانه‌تری از W می‌باشد.


$$VAR(A) = \frac{\sum_{i=1}^k (a_i - \bar{a})^2}{n} \quad (2)$$

۴. الگوریتم پیشنهادی الگوریتم یادگیری ائتلافی با استفاده از وزن‌دهی نمایی خطاها

در این بخش، یک الگوریتم یادگیری ائتلافی جدید را معرفی می‌شود که بهبودهایی در عملکرد و انصاف مدل به‌روز شده ارائه می‌دهد. این الگوریتم با استفاده از وزن‌دهی نمایی خطاها و محاسبات متمرکز بر روی کارساز، تلاش می‌کند تا نوسانات و عدم انصاف در به‌روزرسانی مدل‌ها را کاهش دهد.

استفاده از وزن‌دهی نمایی در الگوریتم‌های یادگیری ائتلافی دارای دلایل متعددی است که به حل چالش‌های انصاف و بهبود عملکرد مدل‌های یادگیری کمک می‌کند. وزن‌دهی نمایی از این خاصیت برخوردار است که خطاهای گذشته را با توجه به فاصله زمانی که اتفاق افتاده‌اند، وزن‌دهی می‌دهد. این روش به ما این امکان را می‌دهد که خطاهای گذشته را با وزن‌های مختلف مدیریت کرده و به تناسب تاثیر آن‌ها را در محاسبه تخمین گرادین استفاده کنیم. به این ترتیب، خطاهای گذشته که ممکن است نوسانی یا ناهمگن باشند، به‌طور متوازن‌تر در مدل تاثیر می‌گذارند و عملکرد یادگیری را تثبیت می‌کنند.

وزن‌دهی نمایی با استفاده از پارامتر که عموماً مقداری بین ۰ تا ۱ دارد، به ما این امکان را می‌دهد که به اندازه‌ای



شکل ۱: شمای کلی از روش پیشنهادی

نسبت مخرج خطاهای وزندهی شده به مجموع وزن‌ها، خطای وزندهی شده را به دست می‌دهد:

$$E_i^{\bar{t}} = \frac{\text{numerator}_i}{\text{denominator}} \quad (6)$$

کارساز با رابطه زیر نسبت خطا را برای هر مشترک محاسبه می‌کند:

$$r_i^t = \frac{E_i^{\bar{t}}}{E_i^t} \quad (7)$$

سپس، کارساز نسبت خطا را در گرادیان هر مشترک ضرب می‌کند:

$$g_i^t = r_i^t \cdot g_i^t \quad (8)$$

در نهایت، کارساز وزن جهانی را با استفاده از گرادیان‌های اصلاح‌شده وزن جهانی را با رابطه زیر به‌روزرسانی می‌کند:

$$w^{t+1} = w^t - \eta \cdot \sum_{i=1}^k g_i^t \quad (9)$$

این الگوریتم با توجه به خطاهای گذشته و استفاده از پارامتر وزندهی نمایی، می‌تواند عملکرد مدل یادگیری را بهبود بخشد و به کاهش نابرابری در یادگیری کمک کند. با استفاده از این روش، خطاهای اخیر تاثیر بیشتری بر روی

اخیر (n) که برای محاسبه خطای وزندهی شده مورد استفاده قرار می‌گیرند، مشخص می‌شود.

در مرحله بعد، مشترکین خطای مدل را بر روی داده‌های محلی خود محاسبه کرده و همراه با گرادیان محاسبه‌شده به کارساز ارسال می‌کنند. کارساز این خطاها را ذخیره کرده و در صورت نیاز خطاهای قدیمی‌تر را حذف می‌کند. سپس، کارساز خطای وزندهی شده هر مشترک را با استفاده از خطاهای اخیر و پارامتر λ محاسبه می‌کند.

وزن‌های وزندهی نمایی بر اساس پارامتر λ برای هر i از ۱ تا n به صورت زیر محاسبه می‌شوند:

$$w_k = \lambda^{k-1} \quad (3)$$

این وزن‌ها تعیین می‌کنند که خطاهای دورتر نسبت به خطاهای اخیر تاثیر کمتری دارند. مجموع وزن‌های محاسبه شده در مرحله قبل نیز به صورت زیر به دست می‌آید:

$$\sum_{k=1}^n \lambda^{k-1} = \text{denominator} \quad (4)$$

مخرج خطاهای وزندهی شده از مجموع وزن‌های وزندهی شده ضربدر خطاهای مربوطه محاسبه می‌شود:

$$\sum_{k=1}^n \lambda^{k-1} \cdot E_i^{t-k} = \text{numerator}_i \quad (5)$$

شده است. علاوه بر این، از کتابخانه Mathplotlib پایتون برای ترسیم نمودارها و نمودارهای ارزیابی استفاده شد. یک شبکه ائتلافی با یک کارساز و مشترکین C شبیه سازی شده است که در آن C نشان دهنده تعداد کل مشترکین در مجموعه داده است.

روش پیشنهادی با FedAvg و سیستم های یادگیری ائتلافی مانند AFL مقایسه شده است که در آن سنجی انصاف، توزیع دقت یکنواخت آموزش در نظر گرفته شده است. همه این سه الگوریتم با یکدیگر در چهار مجموعه داده مقایسه شده اند.

۵-۲. نتایج شبیه سازی

در بخش نتایج شبیه سازی، از مجموعه داده KITTI برای تشخیص و ردیابی اشیاء استفاده شد. این مجموعه داده شامل کلیه ی ۷۵۰۰ تصویر با ابرنواحی و اطلاعات عمق است که به دو بخش آموزشی و آزمایشی تقسیم شده است. بخش آموزشی شامل ۶۰۰۰ نمونه و بخش آزمایشی شامل ۱۵۰۰ نمونه است. این مجموعه داده مناسب برای ارزیابی و آزمایش الگوریتم های تشخیص و ردیابی اشیاء در محیط های شهری می باشد و به دلیل استاندارد بالا، در پژوهش های بینایی کامپیوتری بسیار مورد استفاده قرار می گیرد. مقدار n برابر ۳ است، میزان یادگیری برای مجموعه داده KITTI برابر با ۰,۰۱ می باشد. همچنین، اندازه دسته ها برای این مجموعه داده ۶۴ است.

برای انتخاب هایپر پارامتر n، چندین آزمایش انجام شده است. مقدار بهینه با تغییر مقادیر n و اجرای آن بر روی مجموعه داده ارائه شده در تحقیق به دست آمده است. ترکیبی از n که توزیع های دقت تست را با واریانس کمتر ایجاد می کند، بهینه است.

۵-۳. نتایج تجربی برای انصاف

بر اساس نتایج به دست آمده، الگوریتم پیشنهادی از نظر انصاف از سایر کارهای مرتبط در مجموعه داده

به روزرسانی مدل دارند و به این ترتیب، مدل می تواند بهتر به تغییرات داده های ورودی واکنش نشان دهد. این امر منجر به بهبود عملکرد کلی و افزایش انصاف در فرآیند یادگیری می شود. در زیر الگوریتم مربوط به الگوریتم پیشنهادی را مشاهده می کنیم.

Algorithm 1: Proposed Algorithm

Server executes:

Input: parameters $i, T, \eta, W^0, p_i, n, C, Model, E, \lambda$

Output: well-trained w

1: initial global model with W^0

2: **for each** round $t = 1, 2, \dots, T$ **do**:

3: $S_t =$ (random set of C clients with probability of p_i)

4: **for each** $k \in S_t$ **in parallel do**:

5: $g_i^t, E_i^t \leftarrow \text{ClientUpdate}(i, w^t)$

6: $w^{t+1} = w^t - \eta \cdot \sum_{i=1}^k g_i^t$

end for

end for

ClientUpdate (i, w^t):

1: **for each** local epoch j from 1 to E **do**:

2: $w_j^t = w_j^t - L g_j^t$

end for

3: $w_k^t = w^t$

4: **return** g_i^t, E_i^t to server

۵. نتایج آزمایش ها


در این مطالعه آزمایشاتی با مجموعه داده KITTI [۳۱] برای بررسی و مشاهده مزایای الگوریتم پیشنهادی انجام شد. مجموعه ای جامع از آزمایش ها برای بررسی روش پیشنهادی انجام شد. سناریوهای دنیای واقعی که در آن مجموعه داده های آموزشی توزیع داده های مشتریان نامتعادل بود (Non-IID) مورد بررسی قرار گرفت. این آزمایش ها نشان می دهد که روش پیشنهادی در شرایط مختلف به طور قابل توجهی موثر است.

۵-۱. تنظیمات پیاده سازی

برای شبیه سازی روش پیشنهادی از زبان برنامه نویسی پایتون و کتابخانه TFF (TensorFlow Federated) استفاده

جدول ۲- مقادیر پارامترها و هایپر پارامترها برای مجموعه داده مورد آزمایش

مجموعه داده	میزان یادگیری	n	اندازه دسته	تعداد مشترک	Epoch	داده‌های آموزشی	داده‌های تستی
KITTI	۰,۰۱	۳	۶۴	۱۰۰	۵۰	۶۰۰۰	۱۵۰۰



شکل ۲: پارامترهای توزیع (دقت/تعداد مشترکین) در مجموعه داده KITTI با مقادیر بهینه n در روش پیشنهادی در مقایسه با روش‌های FedAvg و AFL

جدول ۳: توزیع دقت آزمون و F1-score برای روش‌های پیشنهادی، FedAvg و AFL


Dataset	Approach	Average (%)	Worst 20% (%)	Best 20% (%)	F1 Score	Variance
KITTI	LHFed, n=3, m=5	84±0.3	73±8	92±2	79±1	220±5
	FedAvg	81±0.1	35±1	87±0.3	75±1	620±10
	AFL	75±0.1	39±0.5	84±0.3	70±2	549±2

در مقایسه با AFL (رنگ آبی) تعداد بیشتری از مشترکین را به دقت بالای ۰,۸ رسانده است. این نشان‌دهنده بهبود دقت کلی مشترکین و کاهش تفاوت‌های دقت بین آن‌ها است. همچنین، روش پیشنهادی (رنگ قرمز) تعداد بیشتری از مشترکین را به دقت بالای ۰,۸ رسانده است، در حالی که روش FedAvg (رنگ آبی) نتوانسته به همان اندازه مشترکین را به دقت بالا برساند. این نشان می‌دهد که روش پیشنهادی در ایجاد توزیع منصفانه‌تر و بهبود دقت کلی مشترکین موثرتر است.

همان‌طور که در جدول ۳ مشاهده می‌شود روش پیشنهادی در تمامی معیارها نسبت به روش‌های FedAvg و AFL عملکرد بهتری داشته است. این روش به ویژه در معیارهای دقت متوسط، بدترین ۲۰ درصد و واریانس


KITTI بهتر عمل کرد. همه روش‌ها با بهترین عملکرد خود تنظیم شده‌اند. در آزمایش اول، مشخص شد که روش پیشنهادی راه‌حل‌های منصفانه‌تری برای داده‌های ائتلافی ایجاد می‌کند. همان‌طور که در شکل ۲ دیده می‌شود، در آزمایش مربوط به توزیع دقت نهایی، روش پیشنهادی با توجه به میانگین مقدار ۵ اجرای تصادفی هر مجموعه داده با روش‌های دیگر مقایسه شد. نتایج تجربی نشان می‌دهد که در روش پیشنهادی، با تنظیم مقدار n، بدون کاهش دقت، توزیع مقدار دقت متراکم‌تر شده و همچنین واریانس کاهش می‌یابد.

همان‌طور که در شکل ۲ نشان داده شده است، الگوریتم پیشنهادی توزیع منصفانه‌تری از نظر دقت را به دست آورد. مشاهده می‌شود که روش پیشنهادی (رنگ قرمز)



شکل ۳: مقایسه عملکرد الگوریتم پیشنهادی با FedAvg و AFL

خطا و رسیدن به بهترین عملکرد ممکن است. شکل ۴، Precision را برای سه روش مختلف (FedAvg، AFL و روش پیشنهادی) بر اساس تعداد دورها در مجموعه داده KITTI نشان می‌دهد. محور عمودی میزان دقت (Precision) را نمایش می‌دهد و محور افقی تعداد دورها را نشان می‌دهد. این نتایج نشان می‌دهد که روش پیشنهادی توانسته است با استفاده از الگوریتم جدید، دقت بیشتری را در مدت زمان کوتاه‌تری نسبت به روش‌های موجود به دست آورد. این مسئله نشان‌دهنده برتری الگوریتم پیشنهادی در بهینه‌سازی و بهبود دقت در سیستم‌های فدرال یادگیری است.




شکل ۴: مقایسه Precision را برای سه روش FedAvg، AFL و روش پیشنهادی

عملکرد برجسته‌ای نشان داده است. FedAvg و AFL با این که در معیارهای خاصی عملکرد خوبی داشته‌اند، اما در معیارهای انصاف مانند بدترین ۲۰ درصد و واریانس ضعیف‌تر از روش پیشنهادی عمل کرده‌اند. این نتایج نشان می‌دهند که روش پیشنهادی نه تنها دقت کلی دارد، بلکه با بهبود معیارهای انصاف، توزیع دقت بین مشترکین را نیز بهبود بخشیده است.

۴-۵. معیارهای عملکردی

در شکل ۳، عملکرد الگوریتم پیشنهادی در مقابل دو روش FedAvg و AFL روی مجموعه داده KITTI مقایسه شده است. در شکل سمت چپ، دقت آزمایشی مدل‌ها در برابر تعداد دورهای آموزشی (Rounds) نشان داده شده است. می‌توان مشاهده کرد که الگوریتم پیشنهادی (Proposed) با خط چین آبی رنگ، به سرعت به دقت بالایی می‌رسد و نسبت به دو روش دیگر، بهبود قابل توجهی در دقت دارد. این نشان‌دهنده همگرایی سریع‌تر و عملکرد بهتر الگوریتم پیشنهادی است. در شکل سمت راست، فاصله مدل‌ها تا بهینه تجربی (Empirical Optimal) بر اساس تعداد دورهای آموزشی نشان داده شده است. الگوریتم پیشنهادی (Proposed) به سرعت به بهینه تجربی نزدیک می‌شود و نسبت به FedAvg و AFL عملکرد بهتری دارد. این نشان‌دهنده کارایی بهتر الگوریتم پیشنهادی در کاهش

مدل از همان ابتدا با سرعت بیشتری نسبت به دو مدل دیگر بهبود می‌یابد و نهایتاً به بالاترین مقدار F1-Score در مقایسه با بقیه می‌رسد. این نتایج نشان‌دهنده کارایی بالا و برتری این مدل در ایجاد تعادل مناسب بین Precision و Recall است. این نمودار به وضوح نشان می‌دهد که الگوریتم پیشنهادی (Proposed) توانسته است به طور موثری عملکرد مدل‌های یادگیری فدرال را بهبود بخشد و با ایجاد تعادل مناسب بین Precision و Recall، به بالاترین مقدار F1-Score دست یابد. این نتایج می‌تواند به عنوان یک دستاورد مهم در پژوهش‌های مرتبط با یادگیری فدرال مورد توجه قرار گیرد و انگیزه‌ای برای تحقیقات بیشتر در این زمینه باشد.




شکل ۶: مقایسه F1-Score را برای سه روش FedAvg، AFL و روش پیشنهادی

۵. نتیجه‌گیری

در این مقاله، یک الگوریتم جدید برای بهبود یادگیری ائتلافی در خودروهای خودران با استفاده از تاریخچه خطا و وزن‌دهی نمایی معرفی شد. هدف اصلی این الگوریتم، افزایش دقت و بهبود انصاف در فرآیند یادگیری بود. آزمایش‌های انجام شده بر روی مجموعه داده شبیه‌سازی شده KITTI نشان داد که الگوریتم پیشنهادی در مقایسه با الگوریتم‌های استاندارد مانند FedAvg، عملکرد بهتری دارد.

در شکل ۵، نتایج مربوط به معیار یادآوری (Recall) برای مجموعه داده KITTI بر اساس تعداد دورها نمایش داده شده است. در این نمودار سه الگوریتم مختلف، یعنی FedAvg، AFL و الگوریتم پیشنهادی (Proposed)، مقایسه شده‌اند. محور افقی نشان‌دهنده تعداد دورها و محور عمودی میزان یادآوری را نشان می‌دهد. تحلیل نتایج نشان می‌دهد که الگوریتم پیشنهادی (خط چین آبی) در مقایسه با دو الگوریتم دیگر، یعنی FedAvg (خط قرمز) و AFL (خط نارنجی)، عملکرد بهتری دارد. الگوریتم پیشنهادی از همان ابتدا میزان یادآوری بالاتری دارد و با افزایش تعداد دورها بهبود بیشتری نیز نشان می‌دهد. در حالی که FedAvg و AFL با وجود افزایش دورها، به میزان یادآوری بالاتری نمی‌رسند. این نتایج نشان می‌دهند که الگوریتم پیشنهادی توانسته است با دقت و سرعت بیشتری به مدل بهینه نزدیک شود و در تشخیص نمونه‌های مثبت واقعی عملکرد بهتری دارد. این نکته مهم است که الگوریتم پیشنهادی در برابر تغییرات داده‌ها و تعداد دورها، پایداری بیشتری از خود نشان داده است.



شکل ۵: مقایسه Recall را برای سه روش FedAvg، AFL و روش پیشنهادی

نمودار شکل ۶ به مقایسه عملکرد سه الگوریتم یادگیری فدرال FedAvg، Proposed و afl در مجموعه داده KITTI با استفاده از معیار F1-Score می‌پردازد. این نمودار نشان‌دهنده بهبود مداوم و قابل توجه الگوریتم پیشنهادی (Proposed) در مقایسه با دو الگوریتم دیگر است. این

[12] S. Wu et al., "Motley: Benchmarking heterogeneity and personalization in federated learning," arXiv preprint arXiv:2206.09262, 2022.

[13] A. Kendall et al., "Learning to drive in a day," in 2019 international conference on robotics and automation (ICRA), 2019: IEEE, pp. 8248-8254.

[14] L. Anzalone, S. Barra, and M. Nappi, "Reinforced curriculum learning for autonomous driving in CARLA," in 2021 IEEE International Conference on Image Processing (ICIP), 2021: IEEE, pp. 3318-3322.

[15] X. Tang, J. Zhang, Y. Fu, C. Li, N. Cheng, and X. Yuan, "A Fair and Efficient Federated Learning Algorithm for Autonomous Driving," in 2023 IEEE 98th Vehicular Technology Conference (VTC2023-Fall), 2023: IEEE, pp. 1-5.

[16] S. Khanal, K. Thar, and E.-N. Huh, "Route-based proactive content caching using self-attention in hierarchical federated learning," IEEE Access, vol. 10, pp. 29514-29527, 2022.

[17] L. Fantauzzo et al., "Feddrive: Generalizing federated learning to semantic segmentation in autonomous driving," in 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2022: IEEE, pp. 11504-11511.

[18] K. Yang, Y. Shi, Y. Zhou, Z. Yang, L. Fu, and W. Chen, "Federated machine learning for intelligent IoT via reconfigurable intelligent surface," IEEE network, vol. 34, no. 5, pp. 16-22, 2020.

[19] M. Aparna, R. Gandhiraj, and M. Panda, "Steering angle prediction for autonomous driving using federated learning: The impact of vehicle-to-everything communication," in 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT), 2021: IEEE, pp. 1-7.

[20] J.-H. Chen, M.-R. Chen, G.-Q. Zeng, and J.-S. Weng, "BDFL: A byzantine-fault-tolerance decentralized federated learning method for autonomous vehicle," IEEE Transactions on Vehicular Technology, vol. 70, no. 9, pp. 8639-8652, 2021.

[21] A. Yadav and A. Kaur, "BIFT: A federated learning System for Connected and Autonomous Vehicles Based on Blockchain," in 2023 3rd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), 2023: IEEE, pp. 1724-1727.

[22] A. Mollanejad, A. H. Navin, and S. Ghanbari, "Fairness-aware loss history based federated learning heuristic algorithm," Knowledge-Based Systems, p. 111467, 2024.

[23] C. Zhao, Z. Gao, Q. Wang, K. Xiao, Z. Mo, and M. J. Deen, "FedSup: A communication-efficient federated learning fatigue driving behaviors supervision approach," Future Generation Computer Systems, vol. 138, pp. 52-60, 2023.

[24] K. Doshi and Y. Yilmaz, "Federated learning-based driver activity recognition for edge devices," in Proceedings of the IEEE/CVF Conference on computer Vision and Pattern Recognition, 2022, pp. 3338-3346.

[25] G. Rjoub, O. A. Wahab, J. Bentahar, and A. S. Bataineh, "Improving autonomous vehicles safety in snow weather using federated YOLO CNN learning," in International Conference on Mobile Web and Intelligent Information Systems, 2021:

الگوریتم ما با استفاده از نرمال سازی خطاها و وزن دهی نمایی توانست دقت بالاتر، میزان همگرایی سریع تر و هزینه های ارتباطی کمتری را فراهم کند. علاوه بر این، این روش توانست انصاف را در فرآیند یادگیری بهبود بخشد و مشترکین با داده های نامتوازن نیز به عملکرد بهتری دست یابند.

منابع

[1] J. Kabzan, L. Hewing, A. Liniger, and M. N. Zeilinger, "Learning-based model predictive control for autonomous racing," IEEE Robotics and Automation Letters, vol. 4, no. 4, pp. 3363-3370, 2019.

[2] H. Ye, L. Liang, G. Y. Li, J. Kim, L. Lu, and M. Wu, "Machine learning for vehicular networks: Recent advances and application examples," IEEE vehicular technology magazine, vol. 13, no. 2, pp. 94-101, 2018.

[3] N. Darapaneni et al., "Autonomous car driving using deep learning," in 2021 2nd International Conference on Secure Cyber Computing and Communications (ICSCCC), 2021: IEEE, pp. 29-33.

[4] L. Paulino, M. Zhu, and W. Wang, "Learning Autonomous Driving in Tangible Practice: Development and On-Road Applications of a 1/10-Scale Autonomous Vehicle," in 2021 IEEE Frontiers in Education Conference (FIE), 2021: IEEE, pp. 1-4.

[5] S. Shalev-Shwartz, S. Shammah, and A. Shashua, "Safe, multi-agent, reinforcement learning for autonomous driving," arXiv preprint arXiv:1610.03295, 2016.

[6] A. Kendall et al., "Learning to Drive in a Day," 2019 International Conference on Robotics and Automation (ICRA), pp. 8248-8254, 2018.

[7] M. Kuderer, S. Gulati, and W. Burgard, "Learning driving styles for autonomous vehicles from demonstration," in 2015 IEEE international conference on robotics and automation (ICRA), 2015: IEEE, pp. 2641-2646.

[8] S. Lefevre, A. Carvalho, and F. Borrelli, "A learning-based framework for velocity control in autonomous driving," IEEE Transactions on Automation Science and Engineering, vol. 13, no. 1, pp. 32-42, 2015.

[9] S. Grigorescu, B. Trasnea, T. Cocias, and G. Macesanu, "A survey of deep learning techniques for autonomous driving," Journal of field robotics, vol. 37, no. 3, pp. 362-386, 2020.

[10] R. Parekh et al., "Gefl: Gradient encryption-aided privacy preserved federated learning for autonomous vehicles," IEEE Access, vol. 11, pp. 1825-1839, 2023.

[11] V. P. Chellapandi, L. Yuan, S. H. Žak, and Z. Wang, "A survey of federated learning for connected and automated vehicles," in 2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC), 2023: IEEE, pp. 2485-2492.

Springer, pp. 121-134.

[26] L. U. Khan, Y. K. Tun, M. Alsenwi, M. Imran, Z. Han, and C. S. Hong, "A dispersed federated learning framework for 6G-enabled autonomous driving cars," *IEEE Transactions on Network Science and Engineering*, 2022.

[27] X. Liang, Y. Liu, T. Chen, M. Liu, and Q. Yang, "Federated transfer reinforcement learning for autonomous driving," in *Federated and Transfer Learning*: Springer, 2022, pp. 357-371.

[28] A. Nguyen et al., "Deep federated learning for autonomous driving," in *2022 IEEE Intelligent Vehicles Symposium (IV)*, 2022: IEEE, pp. 1824-1830.

[29] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, "Communication-efficient learning of deep networks from decentralized data," in *Artificial Intelligence and Statistics*, 2017: PMLR, pp. 1273-1282.

[30] T. Li, M. Sanjabi, A. Beirami, and V. Smith, "Fair resource allocation in federated learning," *arXiv preprint arXiv:1905.10497*, 2019.

[31] J. Stallkamp, M. Schlipsing, J. Salmen, and C. Igel, "The German Traffic Sign Recognition Benchmark: A multi-class classification competition," in *The 2011 International Joint Conference on Neural Networks*, 31 July-5 Aug. 2011 2011, pp. 1453-1460, doi: 10.1109/IJCNN.2011.6033395.