

آموزش بهینه رفتار راننده با استفاده از یادگیری عمیق در قالب رویکرد آموزش End-to-End برای هدایت خودروی خودران

مرتضی آقامحمدی^۱، علی جمالی^{۲*}، کامراد خوشحال رودپشتی^۳

۱- دانشجوی دکتری مکانیک طراحی کاربردی، گروه مکانیک، واحد بندر انزلی، دانشگاه آزاد اسلامی، بندر انزلی، ایران

۲- دانشیار، گروه مکانیک، دانشگاه گیلان، رشت، ایران

۳- استادیار، گروه کامپیوتر، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران

رسید مقاله: ۲۲ خرداد ۱۴۰۲

پذیرش مقاله: ۸ آبان ۱۴۰۲

چکیده

یکی از مهم ترین شاخص های اصلی در معیار عملکرد خودروهای خودران، سیاست اتخاذ شده توسط سیستم خودران در خصوص تعیین سرعت خودرو و زاویه فرمان می باشد. برای تعیین این سیاست همواره محققان با چالش انتخاب روش آموزش بهینه ما بین دو رویکرد سنتی مدولار و مدرن End-to-End مواجه بوده اند. اخیراً تحقیقات زیادی در راستای معرفی رویکرد End-to-End و کاربرد آن در این حوزه انجام شده است. در این پژوهش مدلی بهینه برای پیش بینی رفتار راننده با به کارگیری این رویکرد مدرن در قالب یادگیری عمیق برای آموزش شبکه های عصبی مصنوعی ارایه شده است. به عبارتی دستیابی به مدلی با دقت قابل قبول نسبت به کارهای مشابه در هدایت خودروی خودران مدنظر بوده است. برای این منظور بر اساس بررسی های انجام شده بر روی معماری شبکه های موجود، دو معماری که دارای پتانسیل های لازم برای دستیابی به این مهم بوده اند انتخاب گردید. همچنین برای نادیده نگرفتن رابطه زمانی بین اسلایدها و نشان دادن وابستگی های زمانی بصری و بررسی تاثیر آن در نتیجه، در آموزش مدل از ترکیب شبکه های عصبی پیچشی (کانولوشنال) با یک نوع شبکه بازگشتی با عنوان حافظه کوتاه مدت بلند LSTM استفاده شده است. در این پژوهش از یک مجموعه داده کامل که در شرایط رانندگی واقعی جمع آوری شده و دارای برچسب بوده و شامل تصاویر و اطلاعات عمق می باشد، استفاده شد و با طراحی الگوریتم های آموزشی و بهینه سازی پارامترهای آموزش با استفاده از الگوریتم بهینه سازی آدام چندین مدل آموزش دیده ارایه گردید که از بین نتایج به دست آمده برخی از پیش بینی ها بهینه تر از کارهای مشابه بودند و این امر نشان از تاثیر بی بدیل وابستگی های زمانی در آموزش و اثرگذاری شبکه های بازگشتی در کنار پردازش قوی شبکه های پیچشی را دارد.

کلمات کلیدی: خودروی خودران، رویکرد آموزش End-to-End، یادگیری عمیق، شبکه های عصبی مصنوعی عمیق، شبکه های عصبی پیچشی، شبکه بازگشتی با حافظه کوتاه مدت بلند LSTM.

* عهده دار مکاتبات

آدرس الکترونیکی: ali.jamali@guilan.ac.ir

۱ مقدمه

افزایش مداوم تعداد وسایل نقلیه در جاده‌ها منجر به افزایش فشار برای حل مسایلی مانند تراکم ترافیک، آلودگی و ایمنی جاده شده است. وسایل نقلیه خودران این پتانسیل را دارند که سیستم‌های حمل و نقل ما را از نظر ایمنی و کارایی متحول کنند. پاسخ اصلی برای حل این مسایل در میان جامعه تحقیقاتی اتومبیل‌های خودران است. به عنوان مثال طبق گزارش سازمان جهانی بهداشت، سالانه ۱/۳ میلیون نفر در تصادفات جاده‌ای جان خود را از دست می‌دهند. در همین حال، تخمین زده می‌شود که تا ۹۰٪ از تمام تصادفات رانندگی ناشی از خطاهای انسانی است. بنابراین وسایل نقلیه خودران^۱ می‌توانند با حذف خطاهای راننده، پیشرفت‌های ایمنی قابل توجهی را ارائه دهند. مزایای بیشتر ارائه‌شده توسط وسایل نقلیه خودران شامل مصرف سوخت بهتر، کاهش آلودگی، اشتراک‌گذاری خودرو، افزایش بهره‌وری و بهبود جریان ترافیک است. همچنین از زمانی که هوش مصنوعی به‌طور فراگیر به عموم معرفی گردید، یکی از تکنولوژی‌هایی که مردم هر روز انتظار آن را می‌کشند تا به‌طور گسترده در چرخه سیستم حمل و نقل قرار گیرد، خودروهای خودران است [۱]. از سوی دیگر، توسعه علم یادگیری ماشین^۲، و به ویژه یادگیری عمیق^۳، کاوش و پیشرفت تحقیقات در زمینه خودروهای خودران را به‌طور قابل توجهی تسریع کرده است و همین امر بستر وسیعی جهت انجام تحقیقات را پیش روی محققان فراهم آورده است [۲]. یکی از فضاها، تحقیقاتی، شیوه‌های متنوع به کارگیری از شبکه‌های عصبی می‌باشد. به‌طور معمول کاربرد شبکه‌های عصبی عمیق در برآزش مدل‌ها در خصوص هدایت وسایل نقلیه خودران با دو رویکرد، یادگیری ترتیبی^۴ و یادگیری End-to-End ارائه می‌گردد. وسایل نقلیه خودران در روش ترتیبی معمولاً به‌طور کلی از پنج جزء عملکردی، ادراک، محلی‌سازی، برنامه‌ریزی، کنترل و مدیریت سیستم تشکیل شده‌اند. این رویکرد ادراک واسطای به‌طور گسترده در صنعت خودرو نیز مورد استفاده قرار می‌گیرد که به یک سیستم کمکی بزرگ برای تشخیص، پیش‌بینی و تصمیم‌گیری نیاز دارد. اما در مقابل، رویکرد یادگیری End-to-End از نظر پیاده‌سازی سبک‌تر بوده و از یک نظریه متمایز برای رانندگی ماشین استفاده می‌کند. این روش به دنبال ساخت مدل‌های یادگیری ماشین بر اساس تقلید از رانندگی انسان است [۱، ۳، ۴].

در رویکرد End-to-End پیکسل‌های تصاویر به‌عنوان ورودی همراه با رفتار راننده یا همان برچسب‌های زاویه فرمان و سرعت خودرو که توسط انسان کنترل می‌شود، مولفه‌های آموزشی را تشکیل می‌دهند [۵]. هدف اصلی در این رویکرد انتخاب سیاست رانندگی، مستقل از شناسایی ویژگی‌های خاص انسانی در ادراک است. سیاست‌های آموخته‌شده کاملاً فاقد قابلیت تفسیر هستند؛ زیرا شبکه عصبی مانند یک جعبه سیاه است. وقتی یک شبکه عصبی عمیق مستقیماً از مشاهدات خام برای کنترل استفاده می‌کند، نمی‌توانیم نحوه عملکرد آن را توضیح دهیم که البته برخی از محققین این ویژگی را یک اشکال برای این رویکرد می‌دانند در حالی که این ویژگی مدل

¹ Autonomous vehicles

² Machine learning

³ Deep learning

⁴ Modular learning

را قادر می‌سازد تا از اطلاعات خام سنسورهای بسیار مهمی مانند لیدار^۱ که نقاط ابری^۲ را در اختیار ما قرار می‌دهند، ویژگی‌های کاربردی غیر قابل فهم را برای بهبود عملکرد مدل استفاده نماید [۶، ۸، ۹].

در این تحقیق سعی شده است با پیاده سازی معماری‌های مختلف شبکه‌های عصبی عمیق مبتنی بر رویکرد End-to-End و به کارگیری روش بهینه‌سازی متناسب با شبکه‌ها، بر روی یک مجموعه داده واقعی که مشمول تصاویر و اطلاعات عمق می‌شود، مدل‌هایی را برازش کنیم که با کاهش حداکثری خطا نتایج قابل قبولی در خصوص پیش‌بینی رفتار راننده نسبت به کارهای مشابه ارایه نماید. در این تحقیق، الگوریتم‌های یادگیری عمیق مدنظر را بر روی یک مجموعه داده متناسب با اهداف تحقیق که مجموعه ای بزرگ و کامل بوده و در شرایط رانندگی واقعی جمع‌آوری شده است، پیاده‌سازی می‌کنیم. برازش مدل در قالب الگوهای متفاوت انجام شده است تا سیاست‌های رانندگی خودکار در چارچوب یادگیری End-to-End تعیین و سپس نتایج را نسبت به الگوریتم‌های دیگر در کارهای مشابه مقایسه نماییم.

در اولین گام، بررسی‌های انجام‌شده بر روی پیشینه تحقیق ارایه شده است. سپس در بخش سوم، تمامی فرایند مدل‌سازی در این تحقیق شامل، مجموعه داده، الگوریتم‌های پیشنهادی و مبانی نظری آن و روش ارزیابی به تفسیر بیان شده است. پیاده‌سازی آزمایش و ارایه نتایج به‌دست آمده و تحلیل‌های آن در بخش چهارم این تحقیق ارایه شده و در نهایت در بخش پنجم جمع‌بندی نتایج و پتانسیل‌های موجود برای تحقیقات آینده را بیان کرده‌ایم.

۲ پیشینه تحقیق

چنی چن و همکاران سه رویکرد آموزشی در خودروهای خودران را بررسی و مقایسه کردند. دو رویکرد اصلی که بیشترین کاربرد را در تحقیقات این حوزه دارد یعنی ادراک واسطه‌ای^۳ یا همان روش ترتیبی و رویکرد End-to-End که بر اساس بازتابی از تقلید رفتار راننده است. این محققان روش سومی را با نام رویکرد ادراک مستقیم^۴ معرفی می‌کنند که از نظر عملکردی بین دو رویکرد فوق قرار می‌گیرد. در این تحقیق برای آموزش شبکه عصبی از داده‌های ضبط‌شده توسط یک بازی رایانه‌ای استفاده‌شده و سپس مدل برازش‌شده را بر روی داده‌های واقعی KITTI^۵ آزمایش کردند و مدعی شدند که نتایج مطلوبی حاصل گردید [۳]. سپس بوجارسکی و همکاران یک شبکه عصبی کانولوشنی را مبتنی بر رویکرد تقلیدی End-to-End آموزش دادند که تمام خطوط خط پردازش مورد نیاز برای رانندگی یک وسیله نقلیه خودران را بدون نیاز به تشخیص الگو آموزش می‌دهد. انگیزه اصلی این گروه از بین بردن شناخت ویژگی‌های مورد نیاز انسان بود. در واقع آنها می‌خواستند مجموعه‌ای از قوانین «اگر، آنگاه، دیگری» را کنار بگذارند. آنها ابتدا از طریق سخت افزار NVIDIA DRIVE™ PX اقدام به جمع‌آوری داده‌های آموزش کردند. سپس از طریق NVIDIA DevBox اقدام به آموزش شبکه عصبی مدل خود کردند [۷]. همچنین شیوو و همکاران، یک معماری ترکیبی جدیدی را با نام FCM-LSTM

¹ Lidar sensor

² Point cloud

³ Mediated perception

⁴ Direct Perception

⁵ Karlsruhe Institute of Technology and Toyota Technological Institute (KITTI)

معرفی کردند که در این مدل علاوه بر در نظر گرفتن تاثیر زمان و ترکیب آن با شبکه های کاملاً کانولوشنال که توسط مجموعه داده های ویدیویی نسبتاً بزرگ تحت آموزش قرار می گرفتند، از تکنیک بخش بندی صحنه ها برای بهبود عملکرد تحت یک الگوی یادگیری ممتاز استفاده می کردند که این روش با عنوان رویکرد آموزش ممتاز معرفی شد [۴]. پس از آن نظر به رشد روزافزون توجه به روش یادگیری بازتاب رفتاری در خودروهای خودران، فقدان یک مجموعه داده بزرگ و کامل که هم شامل تصاویر و هم اطلاعات عمق تصاویر باشد و در عین حال رفتار راننده را به عنوان برجسته داشته باشد، به شدت احساس می شد. پینگ چن و همکاران، در یک مطالعه نسبتاً کامل، مجموعه داده بزرگی را ارائه کردند که شامل تمامی موارد فوق می باشد و همچنین از این مجموعه داده برای آموزش چندین مدل و نمایش نتایج به صورت مقایسه ای استفاده کردند [۱۰]. یکی دیگر از تحقیقات انجام شده در این حوزه، کدویلا و همکاران بود که در آن می گویند، یادگیری تقلیدی به تنهایی کارایی لازم را در شرایط پیچیده شهری ندارد و برای افزایش دقت و بهبود این روش پیشنهاد می شود که یادگیری تقلیدی مبتنی بر شروطی باشد. همچنین آنها این روش را در شبیه ساز سه بعدی CARLA^۱ و با یک کامیون روباتیک در یک منطقه مسکونی آزمایش کردند [۱۱]. همچنین وانگ و همکاران، که به دنبال کاهش مداخلات انسانی تا حد ممکن و کاهش مشکلات احتمالی در خصوص برآزش بیش از حد و ناپدید شدن گرادیان بودند، توانستند، با ارائه یک مدل CNN در قالب یک رویکرد یادگیری End-to-End و با پیاده سازی تکنیک Dropout به نتایج بهتری نسبت به تحقیق بوجارسکی و همکاران دست پیدا کنند [۱۲]. در تحقیقی دیگر، ای سیاو و همکاران در راستای بهبود نتایج برای عملکرد خودروی خودران با رویکرد End-to-End پنج مدل را برآزش کردند که تفاوت آنها در داده های ورودی و نحوه تلفیق داده های تصویر و لیدار در معماری شبکه بود [۱۳]. همچنین کیشی ایشیهارا و همکاران یادگیری تقلیدی مشروط را مبتنی بر رویکرد End-to-End ارائه دادند که با نام اختصاری CIL^۲ معرفی شد. در این روش علاوه بر این که شبکه به طور تقلیدی تحت آموزش قرار می گیرد برخی از ویژگی های بصری را به عنوان شرط عملکرد یادگیری تقلیدی نیز به صورت فرعی آموزش می بیند و به عنوان مثال تفسیر چراغ راهنمایی را آزمایش کردند [۱۴]. آدیتیا پراکاش و همکاران نیز در تحقیقی که در آن در چهارچوب رویکرد پایان به پایان مدلی را در محیط شبیه ساز کارلا معرفی کرده بودند، مدعی شدند که با نوآوری ارائه شده در روش تلفیق داده های ورودی، تصاویر و نقاط ابری لیدار با نام ترانس فیوزر^۳، نتایج مطلوب تری نسبت به روش های فیوژن در عملکرد مدل برای هدایت خودرو به دست آوردند [۱۵]. پارک مینگو و همکارانش در دانشگاه سونچون هیانگ تحقیقی را در زمینه مشابه ارائه کردند که در آن به جای استفاده از داده های شبیه سازی شده، با استفاده از داده های رانندگی واقعی الگوریتم رانندگی مستقل E2E^۴ را ارائه کردند که دو مزیت را در آماده سازی داده ها به همراه داشت. اول این که داده های بسیار مشابه را که در سرعت های پایین و زمان های توقف خودرو جمع آوری شده بودند را با حفظ صحیح ساختار داده ها، حذف کردند و دوم این که

¹ California Amateur Radio Linking Association (CARLA)

² Conditional imitation learning (CIL)

³ TransFuser

⁴ End-to-End

داده‌های لیدار را برای استفاده در شبکه عصبی بر پایه معادله معرفی شده به تصاویر دو بعدی با سه کانال رنگی که هر یک بیانگر فواصلی خاص بود ارائه دادند. همچنین دیگر ابتکار ارائه شده در این مقاله ترکیب دو معماری به صورت موازی برای استخراج ویژگی‌ها برای دو نوع ورودی ارائه شده بود [۱۶]. و در نهایت دیان چن و همکاران تحقیقی را مبتنی بر یادگیری End-to-End ارائه کردند که در آن برای افزایش دقت عملکرد در سه آیتم تکمیل مسیر، هدایت خودرو و اطلاعات، روشی را با نام LAV^۱ معرفی کردند که نشان می‌دهد با استفاده از جمع‌آوری اطلاعات از خودروهای اطراف آموزش مدل غنی‌تر و عملکردی بهتر خواهد داشت. این تست در محیط شبیه‌ساز انجام شده است [۱۷].

در بررسی پیشینه تحقیق و کارهای مرتبط مشخص گردید که هدف‌گیری اصلی در این تحقیقات، دستیابی به دقت قابل قبول با رویکرد آموزشی مدرن مدنظر بوده است. اما نکته مشترک و قابل تامل در این تحقیقات، چالش انتخاب الگوریتم و استفاده از الگوریتم‌های تکراری می‌باشد. ما نیز تصمیم گرفتیم بر خلاف کارهای مشابه از الگوریتم‌های به‌روزرشده و غیرتکراری استفاده نموده و روش‌های ترکیبی را نیز آزمایش نماییم.

۳ روش‌شناسی تحقیق

در این بخش از تحقیق به تفسیر قسمت‌هایی می‌پردازیم که در کنار یکدیگر فرایند آموزش مدلی را تشکیل می‌دهند که توانایی پیش‌بینی رفتار بهینه راننده را محقق می‌نماید. ابتدا مجموعه داده و خصوصیات آن معرفی شده است و سپس اطلاعات مورد نیاز در خصوص آماده‌سازی مدل جهت پیاده‌سازی بر روی مجموعه داده ارائه گردید. و بعد از آن الگوهای متفاوت جهت آموزش مدل بررسی شده است و در نهایت جهت دستیابی به نتایج مطلوب، ارزیابی مدل و روش بهینه‌سازی تشریح گردید.

۳-۱ مجموعه داده

بدون شک داشتن مجموعه داده با کیفیت می‌تواند در آموزش و اجرای الگوریتم‌های خودروهای خودران بسیار موثر باشد. مجموعه داده‌ها اغلب از طریق شبیه‌سازها و یا با رانندگی وسیله نقلیه در جاده‌های عمومی تولید و جمع‌آوری می‌شوند. تهیه و تولید مجموعه داده در حوزه خودروهای خودران همواره یکی از موضوعات اصلی در تحقیقات این حوزه بوده است. در بسیاری از تحقیقات مشابه به دلیل سادگی کار از مجموعه داده‌های شبیه‌سازی شده استفاده شده است که البته هم دارای معایب و هم مزایایی می‌باشد. ولی در این تحقیق از یک مجموعه داده واقعی استفاده می‌کنیم. تولید چنین مجموعه داده‌های بسیار سخت و زمان‌بر است، به این صورت است که وسیله نقلیه به سنسورهای مختلفی مانند دوربین، لیدار، رادار، جی‌پی‌اس و ... مجهز می‌شود و با رانندگی و هدایت دستی خودرو توسط راننده در جاده‌های مختلف، که نظر به استراتژی تحقیق ممکن است شرایط ترافیکی و آب و هوایی متفاوتی مد نظر باشد، اطلاعات ضبط شده توسط حسگرها به عنوان یک مجموعه داده خام جمع‌آوری می‌شود که قطعاً برای استفاده در مدل‌ها نیاز به پیش‌پردازش‌های زیادی دارد. ولی اگر

¹ Learning from All Vehicles (LAV)

مجموعه داده کامل تری مدنظر باشد و به دنبال مدل سازی با نظارت هستیم، رفتار راننده نیز باید به عنوان برجسب داده ها هم زمان ذخیره سازی گردد که در این حالت مرحله همگام سازی داده ها نقش حیاتی در ارایه این مجموعه داده خواهد داشت. می توان گفت از سال ۲۰۰۹ به بعد، چند سال پس از چالش بزرگ^۱ DARPA، موضوع جمع آوری اطلاعات در جاده های عمومی اهمیت بیشتری پیدا کرد. نظر به این که در این تحقیق، آموزش End-to-End برای مدل در نظر گرفته شده بود و همچنین از آنجایی که به دنبال ارتقای دقت در پیش بینی رفتار راننده با به کار گیری اطلاعات عمق بودیم، می بایست مجموعه داده ای را انتخاب می کردیم که هم دارای برجسب می شد و هم از طریق سنسور لیدار اطلاعات عمق را نیز در اختیار ما قرار می داد در جدول زیر برخی از محبوب ترین مجموعه داده هایی که قابلیت دسترسی برای آن فراهم بود و در تحقیقات مشابه استفاده شده نشان داده شده است [۱۰، ۱۸].


جدول ۱. تعدادی از محبوب ترین و کامل ترین مجموعه داده های جمع آوری شده در حوزه خودروهای خودران [۱۸].

نام مجموعه داده	زمان و مکان	حجم داده	شرایط ترافیکی	حسگرها	فرمت داده
Daimler pedestrian	۲۰۰۶ – ۲۰۱۶ چین	۸۸۳ گیگا بایت	ترافیک شهری	دوربین خاکستری تک چشمی: دید استریو، رنگی یا خاکستری	تصویر (عکس)
Caltech	۲۰۰۹ آمریکا	۱۱ گیگا بایت	ترافیک شهری	دوربین رنگی تک چشمی	ویدئو
Cheddar Gorge	۲۰۱۰ انگلستان	۳۲۹ گیگا بایت	خشک، آفتابی، روشن، سرد	دوربین رنگی دید استریو حسگر لیدار، حسگر چندگانه	تصویر (عکس) نقاط ابری
KITTI	۲۰۱۱ آلمان	۱۸۰ گیگا بایت	شهری، روستایی، بزرگراه	۲ عدد دوربین سیاه و سفید تک چشمی، حسگر لیدار، حسگر چندگانه	تصویر (عکس) نقاط ابری برجسب
Oxford	۲۰۱۴ – ۲۰۱۵ انگلستان	۲۳/۱۵ ترا بایت	شرایط مختلف: نوری و آب و هوایی	۳ دوربین رنگی تک چشمی دید استریو، حسگر لیدار، GPS/INS	تصویر (عکس) نقاط ابری داده موقعیت مکانی
comma.ai	۲۰۱۶ آمریکا	۸۰ گیگا بایت	نور روز، بیشتر بزرگراه	دوربین رنگی تک چشمی، ژيروسکوپ GPS+IMU	تصویر (عکس) داده موقعیت مکانی
Cityscapes	۲۰۱۶ آلمان – سوئیس – فرانسه	۶۳/۱۴ گیگا بایت	نور روز، فاقد شرایط آب و هوایی نامطلوب	دوربین رنگی دید استریو	تصویر (عکس) برجسب
Udacity	۲۰۱۶ آمریکا	۲۲۳ گیگا بایت	آفتابی، ابری، نور روز	دوربین رنگی تک چشمی، GPS+IMU حسگر لیدار،	تصویر (عکس) نقاط ابری، برجسب داده موقعیت مکانی
LiVi-Set	۲۰۰۸ چین	۱۵ گیگا بایت ۱ ترا بایت	شهری، روستایی، شرایط مختلف: نوری و آب و هوایی	دوربین، حسگر لیدار، حسگر چندگانه	تصویر (عکس) نقاط ابری برجسب
CMU	۲۰۱۰ – ۲۰۱۱ آمریکا	۲۲ گیگا بایت	شرایط مختلف: نوری و آب و هوایی	۳ عدد دوربین رنگی تک چشمی، حسگر لیدار، GPS+IMU	تصویر (عکس) نقاط ابری، برجسب داده موقعیت مکانی
Ford	۲۰۰۹ آمریکا	۱۰۰ گیگا بایت	مرکز شهر، حلقه بسته، محوطه دانشگاه	دو نوع حسگر لیدار، دوربین همه جانبه، GPS+IMU	تصویر (عکس) نقاط ابری داده موقعیت مکانی
Stanford	۲۰۰۹ – ۲۰۱۰ آمریکا	۵/۷۲ گیگا بایت	شهری محوطه دانشگاه	حسگر لیدار، GPS+IMU	نقاط ابری داده موقعیت مکانی

¹ Defense Advanced Research Projects Agency

AMUSE	۲۰۱۳	۱/۱۶ ترا بایت	شهری، خارج از شهر، شرایط مختلف: نوری و آب و هوایی	دوربین همه جانبه، سنسور سرعت، ۳ عدد سنسور ارتفاع، GPS+IMU	تصویر(عکس) داده موقعیت مکانی
Elektra	۲۰۱۶	۱۰/۳۱ گیگا بایت	شهری، نور روز، شب در یک مجموعه داده جدا	دوربین تک چشمی دید استریو، سنسور مادون قرمز دور	تصویر(عکس) نقاط ابری
JAAD	۲۰۱۶	-	شهری، روستایی، روز، کمی شب، شرایط آب و هوایی مختلف	دوربین رنگی تک چشمی	ویدئو بر چسب

بر این اساس مجموعه داده Livi-Set که از نظر خواسته‌های مدنظر با اهداف این تحقیق هم راستا بود در نظر گرفته شد. از مواردی که می‌توان به آن اشاره کرد، شرایط ترافیکی و حجم کافی داده‌ها می‌باشد که با بیش از ۱۰ هزار فریم صحنه واقعی خیابان و با مقدار داده در کل بیش از ۱ ترابایت در گروه بزرگ‌ترین مجموعه داده‌ها قرار دارد. این مجموعه داده از نظر شرایط رانندگی دارای تنوع بسیار کاملی است. این تنوع شامل مسیرهای محلی، بلوارها، جاده‌های اصلی، مسیرهای کوهستانی، محدوده مدارس، تعداد زیادی تقاطع، روگذر، پل‌های زیرگذر و ... می‌باشد. همچنین این مجموعه داده صحنه‌هایی با تعداد عابر پیاده متفاوت را نشان می‌دهد. این تنوع صحنه‌ها به خوبی می‌تواند رانندگی در شرایط واقعی را فراهم کند. پس از همگام‌سازی داده‌ها، این مجموعه داده در مجموع ۳۸۸۸۰ فرم تصویر و همین تعداد فایل Las و برچسب‌های مربوطه را در اختیار ما قرار می‌دهد که نشان‌دهنده رفتار راننده است. این مجموعه در قالب ۲۸۴ پوشه شامل هر سه مورد فوق برای آموزش و ۲۰ پوشه برای ارزیابی و در نهایت ۲۰ پوشه برای تست در دسترس بوده است [۱۰]. ساختار مجموعه داده مورد استفاده در تحقیق به شرح زیر است.



شکل ۱. ساختار مجموعه داده Livi-Set

این مجموعه داده توسط یک وسیله نقلیه جمع‌آوری اطلاعات جاده چند منظوره به‌دست آمده است. وسیله نقلیه مورد استفاده یک دستگاه خودروی سواری بیوک GL8 است که دارای چندین اسکنر و سنسور بوده و سه نوع سیگنال، یعنی ابرهای نقطه‌ای، ویدئوها و رفتارهای رانندگی را جمع‌آوری می‌کند. ابرهای نقطه‌ای: دو اسکنر Velo-dyne، یکی HDL-32E، و دیگری VLP-16، برای جمع‌آوری اطلاعات عمق در خودرو مورد نظر استفاده شده است. اما بیشتر ابرهای نقطه‌ای توسط اسکنر HDL-32E جمع‌آوری شده

است که می‌تواند طیف وسیعی از داده‌ها را با دقت بالا جمع‌آوری کند. مشخصات فنی مجموعه داده‌های آن شامل فرکانس ۱۰ هرتز و ۳۲ پرتو لیزر در یک پرتو با عمق ۷۰-۱ متر و وضوح ۲ سانتی‌متر است. همچنین زاویه اسکنر در نمای افقی ۳۶۰ درجه و در نمای عمودی از "۱۰/۶۷+ تا ۳۰/۶۷- درجه، چگالی نقاط حدود ۷۰۰۰۰۰ نقطه در ثانیه است. محل نصب این اسکنرها در قسمت جلو و بالای خودرو نصب می‌شود.

ویدئو: برای ضبط تصاویر از دوربین رنگی استفاده می‌شود که با به‌روزرسانی لحظه‌ای جلوی خودرو بر روی داشبورد نصب می‌شود. این دوربین توانایی فیلم برداری با سرعت ۳۰ فریم بر ثانیه با رزولوشن 1080×1920 را دارد و همچنین با حافظه ۱۲۸ گیگ می‌تواند ۲۰ ساعت فیلم با کیفیت P ۱۰۸۰ به صورت مداوم ضبط کند.

رفتار رانندگی: برای ثبت رفتار راننده که شامل سرعت خودرو و زاویه فرمان است، از نرم افزاری استفاده می‌شود که به صورت بی‌سیم به سیستم کنترل خودرو متصل می‌شود. اطلاعات مورد نظر در مورد سرعت را از طریق سنسورهای دریافت می‌کند که دقت آنها تا ۰/۱ کیلومتر در ساعت است. اما برای زاویه فرمان از سنسور نقاله الکترونیکی استفاده شده که دقت آن ۱ درجه است. این نقاله برای یک سمت از اعداد مثبت و برای طرف دیگر از اعداد منفی استفاده می‌کند تا تفاوت بین زاویه فرمان راست و چپ را نشان دهد.

همان‌طور که در شکل ۱ نشان داده شد، در نهایت این مجموعه داده شامل دو نوع داده می‌باشد. تصاویر ویدئویی ضبط‌شده که عکس‌هایی با زمان‌بندی مشخص از آن استخراج شده و همچنین نقاط ابری مربوط به اطلاعات عمق که از طریق سنسور لیدار ۳۶۰ درجه جمع‌آوری شده است و این مجموعه داده دارای یک فایل CSV^۱ می‌باشد که در واقع به عنوان برجسب مجموعه داده بوده و دو پارامتر کنترلی سرعت خودرو و زاویه فرمان که از سوی راننده اعمال شده است را جمع‌آوری کرده است.

۳-۲ آماده‌سازی مدل

در این تحقیق مدل‌ها در قالب شبکه‌های عصبی عمیق مبتنی بر یادگیری عمیق و با رویکرد آموزشی End-to-End^۲ ارایه شده است. شبکه‌های عصبی عمیق^۲ استفاده شده در این مدل‌ها، الگوریتم پیچشی عمیق و الگوریتم حافظه کوتاه مدت بلند^۳ که از زیرمجموعه شبکه‌های بازگشتی^۴ است می‌باشد.

۳-۲-۱ رویکرد آموزشی End-to-End

یکی از مهم‌ترین چالش‌های حوزه یادگیری ماشین انتخاب روش مناسب جهت حل یک مشکل خاص است. همچنین وجود الگوریتم‌های بیشمار نیز خود چالشی جدی است. ولی آنچه کار را سخت‌تر می‌کند، نیاز ضروری به معماری‌هایی با اجزای آموزشی زیاد در حل مسایل پیچیده نظیر خودروهای خودران است (استخراج ویژگی، بهینه‌سازی، پیش‌بینی، تصمیم‌گیری) که می‌توان الگوریتم‌های متفاوتی را برای هر یک در نظر گرفت. حال مساله

¹ Comma-separated values

² Deep neural networks (DNNs)

³ Long short-term memory (LSTM)

⁴ Recurrent Neural Networks (RNNs)

مهم این است که قطعا برای به دست آوردن نتیجه بهینه نیاز به اعمال تغییرات در لایه‌ها و الگوریتم‌ها می‌باشد، اما از آنجایی که هر یک از این لایه‌ها وظیفه خاصی را دنبال می‌کنند تشخیص این‌که در نتیجه‌گیری کل سیستم تاثیر مثبت داشته باشد یا نه، بسیار دشوار است. با این تفسیر رویکرد جدیدی با عنوان آموزش پایان به پایان E2E ارائه گردید. این روش مبتنی بر یادگیری عمیق می‌باشد که از زیرمجموعه‌های یادگیری ماشین و هوش مصنوعی بوده و اشاره به یک یادگیری پیچیده دارد که هدف آن دور زدن لایه‌های میانی است. این روش با استفاده از ساختار شبکه‌های عمیق DNN می‌تواند محاسبات پیچیده‌ای را بر روی مجموعه داده‌های بزرگ انجام دهد و با تکنیکی به ظاهر ساده با ایجاد یک خط پردازش پیچیده، لایه‌های میانی آموزش را محو می‌کند [۱، ۴، ۱۳]. مدل ارائه شده در این تحقیق نیز در چارچوب E2E آموزش داده شده است.


۳-۲-۲ شبکه‌های عصبی عمیق

بخش آموزش و یادگیری در ساخت مدل‌ها باعث توسعه شبکه‌های عصبی مصنوعی گردید. سپس این شبکه‌ها برای ذخیره و ارزیابی میزان اهمیت هر یک از ورودی‌ها نسبت به خروجی نیاز به مکانی جهت ذخیره‌سازی این اطلاعات داشتند که موجب تشکیل لایه‌های پنهان در دل این شبکه‌ها گردید. شبکه‌های عصبی عمیق با استفاده از مدل‌سازی پیچیده ریاضی، داده‌ها را به روش‌های پیچیده پردازش می‌کنند. در واقع این شبکه‌ها نتیجه تکامل این مسیر در حوزه هوش مصنوعی می‌باشند [۱۹].

در این تحقیق از میان الگوریتم‌های متعدد شبکه‌های عصبی، دو نوع الگوریتم پیچشی و بازگشتی را برای مدل‌ها در نظر گرفتیم و از این بین معماری‌هایی را برگزیدیم که تا این زمان در هیچ یک از تحقیقات مشابه از آنها استفاده نگردیده است. در ادامه معماری‌هایی را که در قالب دو نوع شبکه فوق برای مدل‌سازی در این تحقیق برآزش شده است را شرح خواهیم داد.

معماری ResNext: یکی از معماری‌های انتخاب شده برای این تحقیق، شبکه ResNext بود که از شبکه‌های نسبتا جدید و مبتکرانه‌ای است که در سال ۲۰۱۷ توسط تحقیقات هوش مصنوعی فیس بوک معرفی شد. این شبکه بر اساس نقاط قوت و ضعف شبکه‌های VGG و ResNet است. در واقع ResNext نتیجه ترکیب یک استراتژی تکرار ResNet با یک استراتژی تقسیم-تبدیل-ادغام شبکه Inception است. به عبارت دیگر یک بلوک شبکه ورودی را تقسیم کرده و پس از تبدیل به فرمت مورد نیاز، آن را ادغام می‌کند تا خروجی را در جایی که هر بلوک از توپولوژی یکسانی پیروی می‌کند به دست آورد. یعنی شبکه ResNext در مقایسه با ResNet، یک فراپارامتر به نام کاردینالیت^۱ را برای تنظیم ظرفیت مدل معرفی می‌کند که از الگوی تقسیم-تبدیل-ادغام مدل Inception استفاده می‌کند. شکل ۲ نمای کلی از معماری ResNext را در مقایسه با ResNet، به ویژه در گلوگاه‌ها و تبدیل‌های جمع‌آوری شده، ارائه می‌دهد [۲۰].

¹ cardinality




شکل ۲. بلوک باقیمانده در ResNet (سمت چپ)، بلوک باقیمانده در ResNeXt با Cardinality = 32 (سمت راست) [۲۰].


معماری Xception: دومین معماری انتخاب شده برای این تحقیق، شبکه Xception بود. این شبکه که مخفف Extreme version of Inception، نسخه بهبود یافته Inception V3 است، در سال ۲۰۱۷ توسط Chollet، خالق کتابخانه Keras Deep Learning معرفی شد. این یک معماری شبکه عصبی پیچشی اصلاح شده با پیچیدگی عمیق قابل تفکیک، بر اساس لایه‌های عمیق پیچیده قابل تشخیص است. در واقع، این فرضیه بیان می‌کند که نداشت همبستگی بین کانالی را می‌توان به طور کامل از همبستگی‌های فضایی در نقشه‌های ویژگی شبکه عصبی کانولوشن جدا کرد. در مقایسه با کانولوشن معمولی، ما نیازی به کانال‌ها در همه کانال‌ها نداریم. این به معنای اتصالات کمتر و مدل سبک‌تر است. در این شبکه پردازش داده‌ها در سه مرحله انجام می‌شود. ابتدا داده از جریان ورودی عبور می‌کند و سپس با عبور از جریان میانی هشت بار خود را تکرار می‌کند و در نهایت از جریان خروجی خارج می‌شود. همان‌طور که در شکل زیر مشاهده می‌شود، SeparableConv یک پیچیدگی قابل تشخیص عمیق است. می‌بینیم که SeparableConv ها به عنوان ماژول‌های اولیه در نظر گرفته می‌شوند و در کل معماری یادگیری عمیق تعبیه شده‌اند [۲۱]. شرح کامل عملکرد و تفسیر شبکه در مقاله [۲۱] ارایه شده است.

شبکه LSTM: بدون شک وقتی از رانندگی خودکار صحبت می‌کنیم، پارامتر زمان در همه ابعاد بسیار مهم است. به خصوص تشخیص شرایط محیطی و پیش‌بینی تغییرات احتمالی در واحد زمان تاثیر زیادی بر تصمیم مدل در رانندگی خودران خواهد داشت. به زبان ساده‌تر، بررسی تصاویر و ویژگی‌های استخراج شده با در نظر گرفتن توالی زمانی آنها توسط مدل می‌تواند در افزایش دقت مدل موثر باشد. بنابراین، یک روش مبتنی بر گرادیان کارآمد به نام حافظه کوتاه مدت بلند (LSTM) می‌تواند این تقاضا را برآورده کند [۲۲]. در شکل ۴ نشان داده شده است که این نوع شبکه بازگشتی دارای واحدی می‌باشد که با یک ساختار زنجیره‌ای اطلاعات را در طول زمان به خاطر می‌سپارد در واقع ضعیفی که در شبکه‌های برگشتی در قالب محو شدگی گرادیان^۱ شناخته می‌شود با تکنیک حافظه کوتاه مدت بلند پوشش داده شده است. بر اساس الگوهای آموزشی تعریف شده در این تحقیق اثر به کارگیری این تکنیک مشهود است [۲۳].

^۱ Vanishing Gradient



شکل ۳. معماری شبکه Xception [۲۱].




شکل ۴. واحد برگشتی حافظه کوتاه مدت بلند LSTM. [Image by Dobilas, S. <https://towardsdatascience.com>].

۳-۲-۳ آماده‌سازی اطلاعات عمق


روش‌های مختلفی برای استفاده از داده‌های خام جمع‌آوری شده از حسگرهای لیدار یا نقاط ابری در الگوریتم‌های آموزشی وجود دارد. اما برای این که بتوانیم عملکرد معماری‌های مختلف را به طور دقیق با آثار مشابه مقایسه کنیم، تصمیم گرفتیم از همان تبدیل‌ها به صورت زیر استفاده کنیم. همچنین استفاده از روش‌های بهینه در تبدیل نقاط ابری می‌تواند پیشنهاد خوبی برای کارهای آینده باشد.

POINTNET: این شبکه که توسط چارلز و همکاران در سال ۲۰۱۷ معرفی شد، توانست نقاط ابری پراکنده را به عنوان ورودی مستقیم و با دقت قابل قبولی دریافت کند و ویژگی‌های خاصی را در قالب تصاویر معمولی به عنوان خروجی ارائه دهد. قابل ذکر است که اگر بخواهیم از روش آموزش متوالی استفاده کنیم، باید فاصله بین اجسام تا خودرو را با اتخاذ روشی از طریق داده‌های خام محاسبه و در اختیار مدل قرار دهیم. اما در رویکرد End to End هر خروجی که از شبکه PointNet در قالب یک ویژگی خاص و به صورت جعبه سیاه غیرقابل درک برای ما در اختیار مدل قرار می‌گیرد می‌تواند تعریفی از فواصل اشیاء برای مدل باشد [۲۴].



شکل ۵. ساختار معماری شبکه PointNet [۲۴]

PCM^۱: این روش که در تحقیق پیشنگ یانگ و همکاران ارائه شده است می‌تواند در سه مرحله زیر اطلاعات لازم را از نقاط ابری استخراج کند که عبارتند از: (۱) تعیین وزن نقاط، (۲) تولید تصویر ویژگی جغرافیایی مرجع (تصاویر خاکستری) و (۳) تقسیم‌بندی تصویر به سمت استخراج شی از تصویر ویژگی. تصویر مشخصه ارجاع شده جغرافیایی ایجاد شده از نقاط ابری متحرک می‌تواند توزیع فضایی نقاط اسکن شده را ارائه دهد و ویژگی‌های هندسی محلی مهم اشیاء صحنه خیابان را که انتظارات اصلی ما از نقاط ابری هستند حفظ کند [۲۵]. برای به دست آوردن اطلاعات عمق، شن و همکاران در [۱۰] از این الگوریتم پیشنهادی برای ترسیم نقاط ابری روی داده های لیدار و ارائه مدل اصلی استفاده کردند.



شکل ۶. نمودار جریان روش پیشنهادی در الگوریتم PCM [۲۵]

۳-۲-۴ ارزیابی مدل

ارزیابی مدل‌ها بر خلاف خیلی از تحقیقات این حوزه که به صورت گسسته و در بهترین حالت برای چهار فرمان حرکت رو به جلو و یا توقف و گردش به راست یا چپ انجام می‌شود، در این تحقیق پیش‌بینی از نوع پیوسته

¹ Point Clouds Mapping

است. یعنی برای میزان سرعت خودرو و چرخش زاویه فرمان عدد دقیق پیش‌بینی می‌گردد که مبتنی بر مقایسه خط مشی پیش‌بینی‌شده در خصوص تعیین سرعت و زاویه فرمان خودرو با برجسب مربوطه در داده‌های آزمایشی خواهد بود. از آنجا که در گزارش عملکرد و مهارت یک مدل رگرسیون باید میزان خطا در پیش‌بینی‌ها ارایه گردد و نمی‌توان صحت را محاسبه کرد، امکان محاسبه مستقیم صحت در خصوص مقایسه اعداد پیش‌بینی‌شده با برجسب‌های مورد نظر میسر نمی‌باشد. لذا جلوتر توضیح داده شده است چگونه با تعریف آستانه حد یا به عبارتی با تعریف تoleransi برای پذیرفته‌شدن اعداد پیش‌بینی‌شده در خصوص دو پارامتر مورد نظر این امکان را میسر می‌کنیم. در واقع ما به دنبال آن هستیم که بینیم پیش‌بینی‌ها چقدر به واقعیت نزدیک است و پیش‌بینی رفتار راننده برای رانندگی در شرایط واقعی مناسب و قابل قبول خواهد بود یا خیر. به همین دلیل یکی از سه معیار پر کاربرد در محاسبه خطا در مدل‌های رگرسیون، که ریشه میانگین مربعات خطا^۱ است در این تحقیق نیز مورد استفاده قرار گرفته شده است چرا که استدلال می‌شود با بزرگ‌نمایی مقدار خطا به موازات تعریف آستانه حد حداکثر سختگیری در محاسبه خطا و دقت مدل انجام می‌شود و از این‌رو پیش‌بینی‌ها قابل اعتمادتر خواهد بود به عبارت دیگر پیش‌بینی قرار گرفته‌شده در بازه آستانه حد با توجه به بزرگ‌نمایی محاسبه خطا بوده و این استدلال قابلیت اعتماد به مدل را افزایش می‌دهد [۲۶].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs \rightarrow i} - X_{model,i})^2}{n}} \quad (1)$$

برای محاسبه ریشه‌ی خطای میانگین مربعات در رابطه فوق، X_{obs} مقدار واقعی و X_{model} مقدار پیش‌بینی‌شده و n تعداد نقاط داده غیر از دست‌رفته (تعداد پیش‌بینی) می‌باشد.

لذا از آنجا که این نوع ارزیابی معیار بصری مشخصی در خصوص عملکرد مدل جهت مقایسه القا نمی‌کند، و ما به دنبال بستری مناسب جهت مقایسه نتایج با کارهای مشابه بودیم در کنار محاسبه خطا، با استفاده از تعریف آستانه حد شرایط را برای تعیین صحت مدل نیز فراهم کردیم. بر این اساس باید میزان انحراف قابل قبول از نتایج مطلوب را تعیین می‌نمودیم. لذا جهت ایجاد شرایط یکسان برای ارزیابی و مقایسه با کارهای مشابه، میزان انحراف قابل قبول برای زاویه فرمان را تا ۶ درجه و برای سرعت خودرو تا ۵ کیلومتر در ساعت در نظر گرفتیم. یعنی در واقع کلیه اعداد پیش‌بینی‌شده در بازه آستانه حد به‌عنوان پیش‌بینی صحیح در نظر گرفته می‌شود که بر این اساس از تقسیم تعداد پیش‌بینی‌های درست بر کل پیش‌بینی‌ها می‌توان به صحت^۲ مدل دست یافت [۱۰].

۳-۲-۵ بهینه‌سازی مدل

در این تحقیق از الگوریتم بهینه‌سازی آدام استفاده شده است. در این الگوریتم برای به‌روزرسانی وزن‌های شبکه به‌جای استفاده از روش کلاسیک گرادیان نزولی تصادفی^۳، شبکه بر اساس داده‌های ورودی آموزش فرایند

^۱ Root Mean Square Error (RMSE)

^۲ Accuracy

^۳ Stochastic gradient descent (SGD)

به روزرسانی را انجام می‌دهد. نام این الگوریتم برگرفته از اصطلاح تخمین گشتاور تطبیقی^۱ است که در آن برای به روزرسانی وزن‌های آموزش شبکه از روش تکرار در داده‌های آموزشی استفاده می‌شود. این الگوریتم در واقع ترکیبی از مزایای دو الگوریتم محبوب Adagrad و RMSprop می‌باشد. الگوریتم Adagrad با ثابت نگه داشتن نرخ یادگیری عملکرد قابل قبولی با گرادین‌های پراکنده (گرادین‌های نامتراکم) دارد. این پراکندگی به شدت در مسایل بینایی کامپیوتر و پردازش زبان طبیعی قابل مشاهده است.

AdaGrad

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial L}{\partial w_t} \quad \text{گام اول:}$$

$$v_t = v_{t-1} + \left[\frac{\partial L}{\partial w_t} \right]^2 \quad \text{گام دوم:}$$

در رابطه فوق در گام اول، که به روزرسانی پارامترها انجام می‌شود، α نرخ یادگیری، v_t تخمین گرادین مربعی دوم، و ϵ اپسیلون را خواهیم داشت. پس از آن در گام دوم نوبت به تکرار همگرایی خواهد بود که در آن $\partial L / \partial w_t$ نمایانگر گرادین نسبت به پارامتر w_t است.

الگوریتم RMSprop نیز با حفظ نرخ یادگیری پارامترها که از طریق تطبیق میانگین گرادین‌های مرتبط با وزن‌ها به دست می‌آید که در تنظیمات برخط و مسایلی که نویز زیادی دارند عملکرد بهینه‌ای دارد.

RMS Prop

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial L}{\partial w_t} \quad \text{گام اول:}$$

$$v_t = \beta v_{t-1} + (1 + \beta) \left[\frac{\partial L}{\partial w_t} \right]^2 \quad \text{گام دوم:}$$

در رابطه فوق در گام اول، مجدد به روزرسانی پارامترها انجام می‌شود، α نرخ یادگیری، v_t تخمین گرادین مربعی دوم، و ϵ اپسیلون را خواهیم داشت. پس از آن در گام دوم نوبت به تکرار همگرایی خواهد بود که در آن $\partial L / \partial w_t$ نمایانگر گرادین نسبت به پارامتر w_t بوده و β یک پارامتر تطابق است به آن اضافه شده است.

یکی از دلایل اصلی انتخاب الگوریتم آدام، متناسب بودن مزایای این الگوریتم با چالش‌های پیش رو در آموزش مدل این تحقیق بوده است. حجم بالای داده‌ها و پیاده‌سازی ساده و آسان با حداقل اشغال حافظه و توان محاسباتی کارآمد و متناسب بودن با مسایل دارای گرادین‌های با نویز زیاد. همه و همه از مزایای کاربردی این الگوریتم است. همچنین آدام یک تکنیک بهینه‌سازی تصادفی کارآمد است که فقط به گرادین‌های مرتبه اول نیاز دارد و حافظه بسیار کمی را اشغال می‌کند. در این روش برای پارامترهای مختلف، نرخ یادگیری تطبیقی

¹ Adaptive moment estimation

فردی^۱ با تخمین لحظه‌های اول و دوم گرادیان محاسبه می‌شود. مزیت دیگر این تکنیک این است که مقدار به‌روزرسانی پارامتر در مقایسه با مقیاس مجدد گرادیان ثابت است. چهار پارامتر اصلی وظیفه پیکربندی الگوریتم بهینه‌سازی آدام را بر عهده دارند. اولین پارامتر نسبتی است که به‌روزرسانی وزن‌ها بر اساس آن انجام می‌پذیرد، که به آن نرخ یادگیری^۲ و یا طول گام گفته می‌شود. دومین و سومین پارامتر که برای تخمین‌های گشتاور^۳ اول و لحظه دوم کاربرد دارد، نرخ‌های فروپاشی نمایی^۴ هستند. و آخرین پارامتر هم عددی بسیار کوچک است که برای جلوگیری از تقسیم بر صفر استفاده می‌شود. عملکرد این الگوریتم در روابط (۴) معرفی شده است [۲۷].

(۴)

Adam

$$g_t \leftarrow \nabla_{\theta} f_t(\theta_t - 1) \quad \leftarrow \quad \text{گام اول}$$

$$m_t \leftarrow B_1 M_{t-1} + (1 - B_1) g_t \quad \leftarrow \quad \text{گام دوم}$$

$$u_t \leftarrow B_2 u_{t-1} + (1 - B_2) g_t^2 \quad \leftarrow \quad \text{گام سوم}$$

$$\hat{m}_t \leftarrow m_t / (1 - \beta_1^t) \quad \leftarrow \quad \text{گام چهارم}$$

$$\hat{u}_t \leftarrow u_t / (1 - \beta_2^t) \quad \leftarrow \quad \text{گام پنجم}$$

$$\theta_t \leftarrow \theta_{t-1} - \alpha \hat{m}_t / (\sqrt{\hat{u}_t} + \epsilon) \quad \leftarrow \quad \text{گام ششم}$$

t= شمارنده زمان

 m_t = تخمین گرادیان مربعی اول

= تخمین گرادیان مربعی دوم

 θ_t = مقدار اولیه پارامترها B_1 و B_2 = پارامترهای تطابق هستند که نشان‌دهنده نقش میزان تطابق گرادیان‌های گذشته در به‌روزرسانی وزن‌ها است. ϵ = یک مقدار بسیار کوچک است که به جلوگیری از تقسیم بر صفر در مخرج عبارت تقسیم کننده در روابط کمک می‌کنددر روابط فوق گام اول نشان‌دهنده گرادیان تابع هدف نسبت به پارامترهای مدل در زمان $\theta_t - 1$ است. این

گرادیان نقش اصلی را در فرآیند به‌روزرسانی پارامترها با توجه به اطلاعات جاری داده‌ها ایفا می‌کند. در این

مرحله گرادیان‌ها بدون هدف و کاملاً تصادفی در بازه زمانی t دریافت می‌شوند. گام دوم تخمین گرادیان مربعی

اول، گام سوم تخمین گرادیان مربعی دوم، گام چهارم تصحیح گرادیان مربعی اول، گام پنجم تصحیح گرادیان

مربعی دوم و در نهایت در گام آخر به‌روزرسانی پارامترها را خواهیم داشت.


¹ Individual adaptive learning rates² learning rate³ moment estimate⁴ Exponential decay rates

در معرفی عملکرد الگوریتم آدام در رابطه فوق، در مرحله اول گرادینان ها بدون هدف و کاملاً تصادفی در بازه زمانی t دریافت می شود. در مرحله دوم به روزرسانی تخمین گشتاور اول انجام می شود و در مرحله سوم به روزرسانی تخمین گشتاور دوم و مرحله چهارم، محاسبه بایاس برای تخمین گشتاور اول و محاسبه بایاس برای تخمین گشتاور دوم در مرحله پنجم انجام می شود. در نهایت در مرحله ششم به روزرسانی پارامترها انجام می پذیرد.

۳-۲-۶ تعیین الگوی آموزش


همان طور که اشاره شد، رویکرد انتخاب شده برای یادگیری مدل در خصوص پیش بینی رفتار راننده در این تحقیق، روش End to End است. به این ترتیب، مدل به طور خودکار بازنمایی های داخلی مراحل پردازش، مانند شناسایی ویژگی های مفید جاده را می آموزد. نکته ای که در این قسمت توضیح داده خواهد شد الگوریتم انتخابی برای آموزش بر اساس ورودی های مختلف و در نظر گرفتن وابستگی های زمانی در داده های آموزشی است. بر این اساس دو الگو در نظر گرفته شده است. و برای هر یک از الگوها سه نوع ترکیب ورودی، به شرح زیر تعیین شده است و در نهایت برای هر یک از معماری های معرفی شده ۶ بار آموزش انجام شده است که بر اساس آن ۱۲ نتیجه مختلف برای معرفی صحت مدل ها در بخش ارایه نتایج خواهیم داشت.

الگوی اول: در این الگو آموزش تنها از طریق الگوریتم های شبکه های عصبی عمیق پیچشی بدون در نظر گرفتن وابستگی زمانی انجام می شود. سه نوع ترکیب ورودی برای این مدل در نظر گرفته شده است. در حالت اول A1، فقط تصاویر RGB که از داده های ویدئویی استخراج شده اند. در حالت دوم B1، تصاویر RGB با اطلاعات عمقی که از طریق شبکه PointNet پردازش می شوند و در حالت سوم C1، تصاویر RGB با اطلاعات عمقی که با نگاشت داده های LIDAR در یک شبکه عصبی عمیق با عنوان PCM پردازش می شوند. هر یک از این ترکیب ها به عنوان بردار ورودی با برجسب زاویه فرمان و سرعت خودرو همراه می باشد.



شکل ۷. الگوی اول در الگوریتم آموزش مدل

الگوی دوم: در الگوی دوم ترکیبی از شبکه‌های کانولوشنی و بازگشتی را خواهیم داشت و بر این اساس همان ترکیب ورودی‌های مدل اول حفظ شده است، با این تفاوت که وابستگی زمانی برای آموزش مدل در قالب الگوریتم شبکه LSTM برای هر سه حالت در نظر گرفته شده است. سه ترکیب ورودی این الگو با عنوان A2, B2, C2 ارایه شده است.



شکل ۸. الگوی دوم در الگوریتم آموزش مدل

۴ پیاده‌سازی و تحلیل نتایج

کلیه فرایند تحقیق شامل آماده‌سازی مجموعه داده و مدل‌سازی در بستر زبان برنامه‌نویسی پایتون صورت گرفته و همچنین آموزش مدل‌ها و انجام تست‌ها در فضای رایانش ابری انجام شده است. در این فرایند پس از آماده‌سازی مجموعه داده معرفی شده در بخش ۲-۲ و همچنین ساخت انواع مدل‌های انتخاب شده در بخش ۲-۳ و نیز تعیین سیاست مدنظر برای بردارهای ورودی در قالب الگوهای آموزش، اعتبار مدل‌های پیشنهادی در پیش‌بینی رفتار راننده برآزش گردید. در این مرحله هر یک از معماری‌ها را در قالب دو مدل (شبکه عصبی عمیق و شبکه عصبی عمیق به همراه حافظه کوتاه مدت بلند) و با سه نوع بردار ورودی که در بخش الگوی آموزش شرح داده شده است آموزش داده و پس از آن با ۲۰ درصد از داده‌ها باقیمانده که برای تست در نظر گرفته شده بود، مدل‌های آموزش دیده را در گام آزمایش قرار دادیم که نتایج به دست آمده در خصوص صحت مدل‌ها در چهارچوب آستانه حد تعریف شده، به شرح جدول زیر می‌باشد:

جدول ۲. ارزیابی عملکرد الگوریتم‌های پیشنهادی با ورودی‌های مختلف

شبکه‌ها	ارزیابی مدل‌ها از نظر صحت	DNN			DNN+LSTM		
		A1	B1	C1	A2	B2	C2
Xception	سرعت خودرو	۶۹/۷	۷۹/۴	۶۸/۸	۷۴/۲	۷۷/۶	۷۹/۱
	زاویه فرمان	۷۰/۱	۸۱/۲	۷۶/۴	۷۹/۳	۸۰/۸	۸۳/۴
ResNext	سرعت خودرو	۷۲/۶	۷۸/۵	۷۱/۷	۷۵/۸	۷۵/۹	۸۱/۶
	زاویه فرمان	۶۸/۲	۷۹/۹	۶۹/۳	۷۸/۷	۷۹/۲	۸۴/۳

نتایج حاصله در ستون‌های A برای هر دو نوع معماری به معنای عملکرد مدل‌های فاقد اطلاعات عمق می‌باشد و همان‌طور که انتظار داشتیم قطعا باید دقت کمتری نسبت به دیگر مدل‌ها را ارایه می‌نمود. البته مقایسه ستون‌های A1 و A2 این استدلال را نیز به ما می‌دهد که هر زمان از تصاویر به تنهایی به عنوان ورودی برای مدل استفاده می‌نماییم، اطلاعات توالی تصاویر که حاصل به کارگیری حافظه کوتاه مدت بلند است نتایج بهینه‌تری را در اختیار ما قرار می‌دهد. اما نتایج ستون‌های B و C مشمول اطلاعات عمق یا در واقع شناسایی فواصل اشیاء می‌باشد و ضمن اینکه اهمیت وجود اطلاعات عمق را در مقایسه با نتایج ستون‌های A آشکار می‌کند، بیان‌کننده چالش به کارگیری این اطلاعات نیز می‌باشد. تفاوت نتایج ما بین ستون‌های B و C نشان می‌دهد که تکنیک‌های به کارگیری اطلاعات عمق می‌تواند تاثیر فراوانی بر نتایج داشته باشد. به عنوان مثال وقتی از تکنیک PCM برای استخراج اطلاعات عمق در مدل‌های DNN+LSTM استفاده کردیم، برخلاف انتظار باعث کاهش دقت نسبت به مدل‌های DNN گردید. ولی در مقابل تکنیک PointNet در مدل‌های DNN+LSTM به خوبی جواب داده و بهینه‌ترین نتایج را منتج شده است. این در حالی می‌باشد که به کارگیری تکنیک PCM در مدل‌های DNN کارایی بهتری نسبت به تکنیک PointNet نشان داده بود. بنابراین نتیجه می‌گیریم استخراج اطلاعات عمق بشیوه الگوریتم PCM زمانی که می‌خواهیم از الگوریتم LSTM استفاده نماییم نمی‌تواند نتایج مطلوبی را در پی داشته باشد. لذا به کارگیری روش‌های استفاده از اطلاعات عمق خود به تنهایی نیز می‌تواند بستر فراوانی جهت انجام تحقیقات در آینده باشد. اما نکته برجسته در بررسی نتایج عملکرد بهتر مدل‌های زیرستون DNN+LSTM نسبت به مدل‌های DNN بوده است. بی شک این نتایج گویای اثر بخشی توالی‌های زمانی در تصمیم‌گیری مدل می‌باشد. هر چند روش آموزش E2E خارج از قدرت تحلیل انسانی می‌باشد؛ ولی مشاهده می‌شود هر چه اطلاعات بیشتری در اختیار این جعبه سیاه آموزشی قرار گیرد که امکان استخراج ویژگی‌هایی نظیر فواصل اشیاء و همچنین وابستگی‌های زمانی را بتواند فراهم نماید، قطعا نتایج مطلوب‌تری حاصل خواهد شد.

۵ نتیجه‌گیری و پیشنهادات

در این مطالعه برای پیش‌بینی رفتار راننده در تعیین میزان سرعت خودرو و زاویه فرمان، مدل‌های متفاوتی ارایه گردید که نتایج حاصل هر یک از مدل‌ها گویای تاثیرگذاری برخی از عوامل بسیار مهم در دستیابی به این هدف بودند. ابتدا دو مورد از معماری‌های جدید و موفق در حوزه یادگیری E2E که در هیچ یک از کارهای مشابه

در خودروهای خودران استفاده نشده بود با استفاده از یک مجموعه داده بسیار کامل مورد آزمایش قرار گرفت که نتایج مطلوب تری نسبت به کارهای مشابه حاصل گردید. همچنین نتایج این مطالعه به وضوح نشان می دهد دو عامل اصلی، یکی اطلاعات عمق که در قالب دو نوع الگوریتم به کار گرفته شده و دیگری اثر بخشی وابستگی زمانی که در ترکیب الگوریتم LSTM با مدل های پایه اعمال گردید اثر مطلوبی در آموزش مدل ها داشته است. بنابراین نتایج این تحقیق و کارهای مشابه نشان می دهد با افزایش روز افزون مجموعه داده های این حوزه و به کارگیری تکنیک های متفاوت در پیاده سازی آموزش E2E می تواند زمینه اعتماد سازی در خصوص به کارگیری این روش در خودروهای خودران را فراهم آورد. همچنین بر اساس تجربیات به دست آمده در این تحقیق می توان سه محور تحقیقاتی برای کارهای آینده پیشنهاد داد. ابتدا در خصوص جمع آوری مجموعه داده بومی و متناسب با شرایط ترافیکی کشور و دوم تمرکز بروی الگوریتم های استخراج ویژگی برای داده های خام لیدار که می توانند تاثیرات قابل توجهی بروی نتایج مدل داشته باشند. و در نهایت برای بهینه سازی مدل، ارایه ترکیبی از ژنتیک الگوریتم و الگوریتم آدام در تعیین پارامترهای اصلی پیکربندی می تواند نوآوری قابل توجهی باشد.

قدردانی

با سپاس از خانم دکتر یسینگ چن از تیم DBNet که در تهیه مجموعه داده ما را یاری نمودند.

منابع

- [1] Kuutti.S., Fallah.S., Bowden.R., Barber.P. (2019). Deep Learning for Autonomous Vehicle Control, Algorithms, State-of-the-Art and Future Prospects. University of Waterloo. Copyright©by Morgan & Claypool
- [2] Kocić. J., Jovičić. N., Drndarević.V. (2019). An End-to-End Deep Neural Network for Autonomous Driving Designed for Embedded Automotive Platforms. MDPI, Sensors 2019, 19(9), 2064; <https://doi.org/10.3390/s19092064>
- [3] Chen. C., Seff. A., Kornhauser. A., and Xiao. J.(2015). Deepdriving: Learning affordance for direct perception in autonomous driving. In Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), ICCV '15, pages 2722– 2730, Washington, DC, USA, 2015. IEEE Computer Society.
- [4] Xu. H., Gao. Y., Yu. F., and Darrell. T.,(2016). End-to-end learning of driving models from large-scale video datasets. arXiv:1612.01079 [cs.CV]. CoRR, abs/1612.01079, 2016.
- [5] Pfeiffer. M., Schaeuble. M., Nieto. J., Siegwart. R., and Cadena. C., (2018) From Perception to Decision: A Data-driven Approach to End-to-end Motion Planning for Autonomous Ground Robots. arXiv:1609.07910v3 [cs.RO] .
- [6] Codevilla. F., Lopez. A.M., Koltun. V., and Dosovitskiy. A., (2018) On Offline Evaluation of Vision-based Driving Models. arXiv:1809.04843v1 [cs.CV].
- [7] Bojarski. M., Testa. D. D., Dworakowski. D., Firner. B., Flepp. B., Goyal. P., Jackel. L.D., Monfort. M., Muller. U., Zhang. J., Zhang. X., Zhao. J., and Zieba. K., (2016) End to end learning for self-driving cars. CoRR, abs/1604.07316, 2016.
- [8] Eraqi. H.M., Moustafa. M.N., and Honer. J., (2017) End-to-End Deep Learning for Steering Autonomous Vehicles Considering Temporal Dependencies. arXiv:1710.03804v3 [cs.LG].
- [9] Chen. J., Eben. S., Tomizuka. Li. M., (2020) Interpretable End-to-end Urban Autonomous Driving with Latent Deep Reinforcement Learning. arXiv:2001.08726v3 [cs.RO].

- [10] Chen. Y., Wang. J., Li. J., Lu. C., Luo. Z., Xue. H., Wang. C., (2018) Lidar-video driving dataset: Learning driving policies effectively. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 18–22 June 2018; pp. 5870–5878
- [11] Codevilla. F., Muller. M., Lopez. A., Koltun. V., Dosovitskiy. A., (2018) End-to-end Driving via Conditional Imitation Learning. arXiv:1710.02410v2 [cs.RO].
- [12] Wang. Y., Liu. D., Jeon. H., Chu. Z., and Matson. E., (2019). End-to-end Learning Approach for Autonomous Driving: A Convolutional Neural Network Model. n Proceedings of the 11th International Conference on Agents and Artificial Intelligence (ICAART 2019), pages 833-839 ISBN: 978-989-758-350-6
- [13] Xiao. Y., Codevilla. F., Gurram. A., Urfalioglu. O., Lopez. A. M., (2020). Multimodal End-to-End Autonomous Driving. arXiv:1906.03199v2 [cs.CV].
- [14] Ishihara. K., Kanervisto. A., Miura. J., Hautamaki. V., (2021). Multi-task Learning with Attention for End-to-end Autonomous Driving. arXiv:2104.10753v1 [cs.RO].
- [15] Prakash. A., Chitta. K., Geiger. A., (2021). Multi-Modal Fusion Transformer for End-to-End Autonomous Driving. arXiv:2104.09224v1 [cs.CV].
- [16] Park. M., Kim and S. Park,; A Convolutional Neural Network-Based End-to-End Self-Driving Using LiDAR and Camera Fusion: Analysis Perspectives in a Real-World Environment. MDPI. Electronics 2021, 10(21), 2608; <https://doi.org/10.3390/electronics10212608>.
- [17] Chen. D., Krahenbuhl. P., (2022). Learning from All Vehicles. arXiv:2203.11934v2 [cs.RO].
- [18] Yin. H., and Berger. C., (2017). When to use what data set for your self-driving car algorithm: An overview of publicly available driving datasets. IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), pp. 1-8, doi: 10.1109/ITSC.2017.8317828
- [19] Johnson. J., (2020). A hands-on introduction to math, stats, and machine learning / What's a Deep Neural Network?. e-book; <https://www.bmc.com/blogs/deep-neural-network>.
- [20] Xie. S., Girshick. R., Dollar. P., Tu. Z., He. K., (2017). Aggregated Residual Transformations for Deep Neural Networks. arXiv:1611.05431v2 [cs.CV].
- [21] Chollet. F., (2017). Xception: Deep Learning with Depthwise Separable Convolutions. arXiv:1610.02357v3 [cs.CV].
- [22] Hochreiter. S., Schmidhuber. J., (1997). LONG SHORT-TERM MEMORY. Neural Computation 9(8):1735- 1780, 1997 - ieeexplore.ieee.org
- [23] Donahue. J., Hendricks. L. A., Rohrbach. M., Venugopalan. S., Guadarrama. S., Saenko. K., Darrell. T., (2016). Long-term Recurrent Convolutional Networks for Visual Recognition and Description. arXiv:1411.4389v4 [cs.CV].
- [24] Qi. C. R., Su. H., Mo. K., Guibas. L. J., (2017). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. arXiv:1612.00593v2 [cs.CV].
- [25] Yang. B., Wei. Z., Li. Q., and Li. J., (2012). Automated extraction of street-scene objects from mobile lidar point clouds. International Journal of Remote Sensing - INT J REMOTE SENS.
- [26] Acharya. S., (2021). What are RMSE and MAE? Published in Towards Data Science. <https://towardsdatascience.com/what-are-rmse-and-mae-e405ce230383>.
- [27] Kingma. D. P., Lei Ba. J., (2017). ADAM: A method for stochastic optimization. arXiv:1412.6980v9 [cs.LG].