

## طراحی و پیاده‌سازی کنترل‌کننده‌های عصبی یادگیرنده عمیق در مقایسه با کنترل‌کننده‌های کلاسیک در کاربرد ماشین خودران

عباس محمدی<sup>۱</sup>، کمال جمشیدی<sup>۱\*</sup>، حامد شهبازی<sup>۲</sup>، مهران رضایی<sup>۱</sup>

۱- مهندسی کامپیوتر، دانشگاه اصفهان، اصفهان، ایران  
۲- هندسی مکترونیک، دانشگاه اصفهان، اصفهان، ایران

### تاریخچه داوری:

دریافت: ۱۳۹۸/۱۲/۰۸  
بازنگری: ۱۳۹۹/۰۵/۱۱  
پذیرش: ۱۳۹۹/۰۸/۱۰  
ارائه آنلاین: ۱۳۹۹/۰۹/۰۳

### کلمات کلیدی:

سیستم‌های فیزیکی - رایانشی  
سیستم انسان در حلقه  
یادگیری عمیق  
کنترل انتها- به- انتها  
ماشین خودران

**خلاصه:** در این مقاله کنترل‌کننده‌های عصبی یادگیرنده عمیق در کاربرد ماشین خودران که یکی از معروفترین سیستم‌های انسان در حلقه است بررسی شده‌است. این کنترل‌کننده مدرن با دو کنترل‌کننده معروف کلاسیک تناسبی-انتگرال- مشتتگیر و کنترل پیشبین مدل، از نظر پارامترهای کیفی و کمی مقایسه شده‌است. این پارامترها انعکاس‌دهنده چالش‌های زمان طراحی شامل وابستگی به مدل و پارامترهای طراحی؛ چالش‌های زمان پیاده‌سازی شامل سهولت پیاده‌سازی و بار محاسباتی؛ و همچنین پارامترهای مهم در زمان اجرا در کاربرد ماشین خودران شامل دقت، سرعت، هزینه یا تلاش کنترلی، استهلاک و انرژی هستند. در روش پیشنهادی، بستری فراهم آورده شده‌است که طراحان قادر باشند کنترل‌کننده‌های مدرن و کلاسیک را با یکدیگر مقایسه نمایند. در روش پیشنهادی از کنترل‌کننده عصبی یادگیرنده عمیق به صورت انتها- به- انتها که ساختار آن متشکل از لایه‌های کانولوشن و لایه‌های تماماً متصل است، به عنوان کنترل‌کننده مدرن استفاده شده‌است. این کنترل‌کننده در ابتدا از رانندگی انسان می‌آموزد سپس به عنوان کنترل‌کننده خودرو مورد استفاده قرار می‌گیرد. عدم وابستگی این کنترل‌کننده به مدل سیستم کنترل‌شونده (ماشین خودران) و محیط و همچنین قابلیت یادگیری مهمترین مزیت آن است. از نقطه نظر پارامترهای مهم در کنترل ماشین خودران در مقایسه با کنترل‌کننده‌های تناسبی-انتگرال-مشتتگیر و کنترل پیشبین مدل، کارایی قابل قبولی از خود به نمایش می‌گذارد.

### ۱- مقدمه

سیستم‌های ارتباطی و حتی صنعت بازی و سرگرمی، امروزه مطرح هستند. نیازمندیهای کنترلی سیستم‌های فیزیکی- رایانشی در اثر توسعه و پیشرفت این کاربردها، پویایی بخش محاسباتی از یک سو و بخش فیزیکی و همچنین شبکه‌ای که ارتباط این دو را برقرار می‌نماید نیز از سوی دیگر روز به روز گسترده‌تر و پیچیده‌تر می‌شود [۱].

در دسته‌ی خاصی از این سیستم‌ها، انسان به‌عنوان بخش اصلی سیستم که به‌صورت غیرقابل‌پیش‌بینی بر روی حلقه‌ی کنترلی تأثیرگذار است، در نظر گرفته می‌شود. این سیستم‌ها به سیستم‌های انسان در حلقه<sup>۲</sup> معروف هستند [۲]. ماشین خودران به دلیل نقش

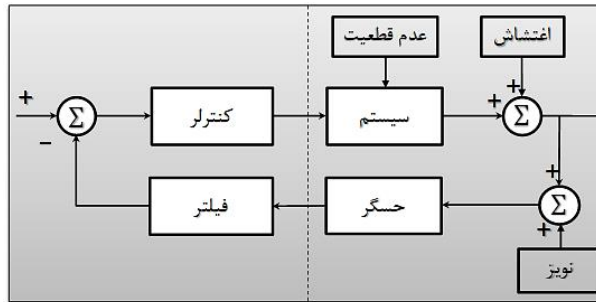
هوشمندسازی سیستم‌های فیزیکی- رایانشی<sup>۱</sup> در راستای برآوردن نیازمندیهای بشر از یک سو و کاربرد روزافزون این سیستم‌ها در کاربردهای بحرانی- ایمن<sup>۲</sup> از سوی دیگر سبب شده‌است تا این موضوع مورد توجه بسیاری از محققان قرار بگیرد. این کاربردها در حوزه‌های مختلف: پزشکی و کمک به زندگی، صنعت حمل‌ونقل، ایمنی جاده‌ها و کنترل ترافیک، سیستم‌های پیشرفته خودرو، کنترل فرآیندهای صنعتی، کنترل انرژی، محافظت از منابع محیط زیست، صنایع هوافضا، صنایع دفاعی، رباتیک، ساختمان‌های هوشمند،

1 Cyber Physical Systems  
2 Safety Critical

\* نویسنده عهده‌دار مکاتبات: jamshidi@eng.ui.ac.ir

3 Human in The Loop (HITL)





شکل ۱. دیاگرام سیستم کنترلی  
Fig. 1. Control system diagram

انتها- به- انتها استفاده شده است. بررسی های ما نشان می دهد که این مقاله اولین مطالعه مقایسه ای کنترل کننده های ذکر شده در کاربرد ماشین خودران است.

در این مقاله در بخش ۲ پیش زمینه و کارهای مرتبط مورد بررسی قرار داده شده است. در بخش ۳ روش پیشنهادی شرح داده شده است و در بخش ۴ نتایج بدست آمده از آزمایش ها ارائه شده است. در پایان در بخش ۵ نتیجه گیری و جمع بندی ارائه شده است.

## ۲- پیش زمینه و کارهای مرتبط

### ۲-۱- کنترل کلاسیک

یکی از مهمترین اهداف در طراحی کلاسیک سیستم های کنترلی مدل سازی عدم قطعیت ها و اغتشاشات فیزیکی است و روش های متنوعی را شامل می شود. اما با گسترش سطح مجتمع سازی سیستم های کنترلی با فن آوری اطلاعات از یک سو و همچنین انسان محور بودن سیستم های انسان در حلقه از سوی دیگر، سیستم های کنترلی با عدم قطعیت از جانب رفتار انسان، دنیای فیزیکی و دنیای رایانشی مواجه است.

مسئله تحلیل و طراحی سیستم های کنترلی کلاسیک به شکل های متفاوتی مطرح می گردد. این تفاوت بر اساس مؤلفه های تعداد ورودی- خروجی، دیدگاه داخلی از سیستم، خطی یا غیرخطی بودن عناصر سیستم، بهینگی در سیستم، پارامترها و میزان معلوم و نامعلوم بودن سیستم است. امروزه سیستم های فیزیکی- رایانشی که عمدتاً سیستم های نامعلوم با پارامترهای نامعین و متغیر هستند، بسیار مورد توجه قرار گرفته اند و راهکارهای کنترلی که برای این سیستم ها پیشنهاد می گردند شامل کنترل مقاوم، کنترل تطبیقی، هوشمند

مهم خودرو در زندگی روزمره انسان ها یکی از مهمترین سیستم های فیزیکی- رایانشی انسان در حلقه است که طراحی و پیاده سازی کنترل کننده های کارآمد برای این سیستم ها بسیار مورد توجه است. مسائل مختلفی در این راستا مطرح است از جمله رانندگی خودکار، مسیریابی هوشمند، اجتناب از تصادف و همچنین بررسی رفتار و شرایط روحی و جسمی راننده که محققان روش های مختلفی برای حل آن ها ارائه نموده اند. دو رویکرد برای حل این مسائل مطرح است، رویکرد اول استفاده از روش های کلاسیک کنترلی و رویکرد دوم استفاده از روش های مدرن مبتنی بر یادگیری ماشین می باشد. استفاده از رویکردهای کنترلی کلاسیک برای حل چنین مسائلی با توجه به پویایی پیچیده و غیرخطی که مدل سازی ریاضی آن یا بسیار دشوار یا غیر ممکن یا با خطا روبروست، با چالش های جدی مواجه است [۱، ۳].

از این رو توجه طراحان را به سمت روش های مبتنی بر یادگیری ماشین و هوش مصنوعی هدایت نموده است. یکی از روش های معروف کنترل مبتنی بر یادگیری ماشین، استفاده از شبکه های عصبی مصنوعی عمیق با رویکرد یادگیری انتها- به- انتها<sup>۱</sup> است. در این مقاله استفاده از این نوع خاص کنترل کننده بر روی دسته خاصی از سیستم های انسان در حلقه یعنی ماشین های خودران هم در محیط شبیه سازی و هم در نمونه واقعی با ابعاد کوچک مورد تحلیل و بررسی قرار گرفته است. لازم به ذکر است در این تحقیق از کنترل کننده های تناسبی- انتگرال- مشتقگیر<sup>۲</sup> و کنترل پیشبین مدل<sup>۳</sup> که از معروفترین کنترل کننده های کلاسیک هستند، برای مقایسه با روش کنترلی

1 End to End  
2 proportional-integral-derivative (PID)  
3 Model predictive control (MPC)

حرکت به دست آورد. لازم به ذکر است کنترل‌کننده‌های یادگیرنده برای سیستم‌هایی که عملیات یکسانی را تحت شرایط عملیاتی یکسان اجرا می‌کنند مطرح می‌شوند.

کنترل‌کننده غیریادگیرنده از خطا در هر مرحله سودی نمی‌برد درحالی‌که کنترل‌کننده یادگیرنده از این خطا به‌عنوان اطلاعاتی ارزشمند برای بهبود کارایی کنترل‌کننده در تکرارهای بعدی عملکرد موردنظر، بهره می‌برد. بدین ترتیب کنترل‌کننده با وجود عدم قطعیت بالای مدل و همچنین اغتشاشات می‌تواند به کارایی بالایی برسد. کنترل یادگیرنده یک تفاوت بنیادی با دیگر استراتژی‌های کنترل مانند کنترل تطبیقی و شبکه عصبی کنترلی دارد. کنترل تطبیقی و شبکه عصبی کنترلی در طول فرآیند یادگیری در جهت رسیدن به کارایی بالاتر به دست‌کاری و تنظیم پارامترهای کنترلی سیستم کنترل‌کننده می‌پردازند درحالی‌که کنترل یادگیرنده از طریق تغییر ورودی‌های کنترلی که از جنس سیگنال هستند عملیات کنترل را انجام می‌دهد [۶].


چالش عمده در مسائل کنترلی مطرح است که برای بشر اجرای آن آسان است اما بیان رسمی و فرمول‌بندی آن بسیار مشکل است. این مسائل ادراکی به‌صورت خودکار و سریع توسط انسان حل می‌شوند (مانند تشخیص چهره‌ها در یک تصویر). راه‌حل کامپیوتری این مسائل این است که به کامپیوترها اجازه داده شود از تجارب درس بگیرند و جهان را بر مبنای سلسله‌مراتبی از مفاهیم درک کنند که این مفاهیم بر اساس روابطشان با مفاهیم ساده‌تر تعریف می‌گردند. همین امر این روش را از ارائه بیان رسمی و فرمول‌بندی یک مسئله تا حد زیادی بی‌نیاز می‌نماید. مسائل کنترلی در دنیای واقعی که روزمره با آن سروکار داریم بیشتر موضوعی و ادراکی هستند و همچنین دارای دینامیک پیچیده هستند و تحقیقات نشان داده است که استفاده از یادگیری عمیق در جهت پیاده‌سازی سیستم کنترلی مستقل از مدل کارایی خوبی ارائه می‌نماید [۷]. در بخش بعدی به طور مفصل در مورد یادگیری عمیق بحث خواهد شد.

به‌طور خلاصه با توجه به پیچیدگی روزافزون سیستم‌های فیزیکی-رایانشی، کنترل دستی این سیستم‌ها بسیار دشوار و غالباً غیرممکن است. بنابراین روش‌های کنترل خودکار در این شرایط پیشنهاد گردید. برای کنترل خودکار این سیستم‌ها اولین راهکار این است که به مدل ریاضی آن دست یافت و از طریق مدل، طراحی کنترل‌کننده

و کنترل تصادفی است. گسترش استفاده از این سیستم‌ها از یک سو و لزوم ارائه کنترل‌کننده مناسب برای آن‌ها از سوی دیگر سبب شده است که روزبه‌روز توجه بیشتری را هم از نظر تئوری و هم از نظر عملی به خود جلب نماید. از میان روش‌های ذکرشده روش‌های کنترلی تطبیقی یا خودتنظیم‌شونده یا خودکنترل‌شونده که مبتنی بر کنترل حلقه‌بسته دارای بازخورد هستند، بهتر از هر روش دیگری نیازمندی‌های سیستم‌های موردبحث را فراهم می‌نمایند [۴].

با توجه به شکل ۱، هدف سیستم‌های کنترلی خودکنترل‌شونده، کنترل سیستم‌های نامعلوم با پارامترهای نامعین و متغیر است. مطالعات تئوری مؤلفه‌های پایداری، مقاومت، کارایی و همگرایی الگوریتم پیشنهادی را موردتوجه و بررسی قرار می‌دهند. درحالی‌که مطالعات عملی به پتانسیل آن به‌عنوان یک ابزار کنترلی ساده و کارآمد می‌پردازند. هر دو این مطالعات در کنار هم سبب ایجاد روشی مناسب برای کنترل می‌شوند. در گام اول بیشتر مطالعات بر روی کنترل تطبیقی سیستم‌های خطی صورت پذیرفته است. کنترل تطبیقی در اثر بررسی و حل مسائل ایده‌آل تحت شرایط ایده‌آل به وجود آمد که اثبات می‌کند که روش‌های کنترل تطبیقی تحت شرایط ایده‌آل پایدار هستند. پس‌از آن مسئله مقاومت کنترل‌کننده تطبیقی با توجه به شرایط غیرایده‌آل مانند اغتشاشات خارجی و دینامیک مدل نشده، عدم قطعیت و همچنین نویز موردتوجه قرار گرفته که سبب پیدایش تعداد زیادی از روش‌های مختلف کنترل تطبیقی شده است. در همین زمان تلاش‌های بسیاری در جهت کاهش وابستگی به دانش قبلی از سیستم کنترل‌شونده و همچنین افزایش کارایی گذرا سیستم صورت پذیرفته است. در سال‌های اخیر کنترل تطبیقی سیستم‌های متغیر با زمان و غیرخطی در جهت رسیدن به هدف ارائه سیستم‌های خودکنترل‌شونده برای کاربردهای دنیای واقعی بسیار مورد توجه قرار گرفته است [۵].

کنترل یادگیرنده یکی از مهم‌ترین روش‌های پیاده‌سازی سیستم‌های خودکنترل‌شونده است، جایی که در آن به تقلید فرآیند یادگیری انسان پرداخته می‌شود. اگرچه خیلی از جنبه‌های یادگیری انسان هنوز ناشناخته باقی‌مانده اما پیشرفت‌های بسیاری در این زمینه بدست آمده است. به عنوان مثال در سیستم حرکتی یک ربات، یادگیری انسان به‌گونه‌ای تقلید می‌گردد که ربات توانایی اجرای یک حرکت پیچیده را با یادگیری قدم‌به‌قدم مهارت‌های لازم برای آن



شکل ۲. نمودار بررسی مقیاس پذیری کارایی در ازای میزان داده بر گرفته از مرجع [۹]

Fig. 2. Performance scalability of algorithms with respect to training data set size [9]

است فاقد داده مقصد است و از طرفی مسئول تولید مجموعه مقادیر اولیه است به گونه‌ای که سبب یادگیری بهتر شبکه شود [۸]. اما سوال مهمی که مطرح است این است که با وجود اینکه ایده اولیه شبکه‌های عصبی عمیق در حدود ۴ دهه پیش مطرح شده چه عاملی سبب ظهور دوباره و پیشرفت‌های چشمگیر در این زمینه شده‌است. اولین و مهمترین پاسخ به این سوال توجه به این حقیقت است که کارایی نه تنها به میزان داده موجود در مرحله آموزش، بلکه به ساختار شبکه نیز وابسته است. سیر مقیاس‌پذیری کارایی به ازای افزایش داده در شکل ۲ آورده شده‌است [۹]. همانطور که مشاهده می‌شود افزایش میزان داده به سرعت سبب بهبود کارایی همه روش‌ها می‌شود. اما در روش‌های سنتی به همان سرعت کارایی آن‌ها با افزایش بیشتر میزان داده به اشباع می‌رسد. از طرفی استفاده از شبکه‌های عصبی با تعداد لایه بیشتر سبب بهبود کارایی در ازای افزایش میزان داده است.

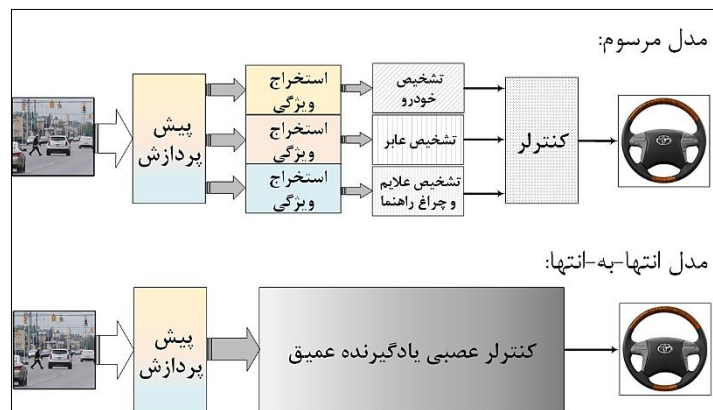
پاسخ دیگری که در راستای سوال مطرح‌شده لازم به ذکر است، پیشرفت‌های چشمگیر در ساخت بسترهای سخت‌افزاری پیاده‌سازی شبکه‌های عصبی عمیق است که بتوانند تسریع مناسبی نه تنها در فاز آموزش بلکه در فاز اجرا هم فراهم آورند. چرا که شبکه‌های عصبی عمیق بوضوح از نظر محاسباتی بسیار هزینه‌بر و سنگین هستند. از طرف دیگر سخت‌افزار و نرم‌افزار پیاده‌سازی مدل یادگیری عمیق در کارایی آن نقش بسیار مهمی را ایفا می‌کند. تعداد نرون‌ها، تعداد اتصال‌های بین نرون‌ها، توپولوژی، پیکربندی و عملکرد هر یک از نرون‌ها در شبکه عصبی مصنوعی از جمله مهم‌ترین ملاحظات طراحی

و کنترل آن صورت پذیرد. اما این روش به دلیل پیچیدگی‌ها و عوامل بسیاری که در زمان اجرا در فرآیند کنترل تأثیرگذار هستند، در اکثر موارد امکان‌پذیر نیست. از این رو تمایل و گرایش مهندسان به سمت روش‌هایی از کنترل خودکار است که فرآیند کنترل را بی‌نیاز از تجربه، دانش و مدل از پیش تعیین‌شده سیستم تحت کنترل می‌نماید. از طرفی با توجه به نیازمندی‌های کاربردهای امروزی سیستم‌های انسان در حلقه، استفاده از روش‌های پیاده‌سازی سخت‌افزاری با قابلیت‌های بالای محاسباتی، دقت، انعطاف‌پذیری، قابلیت مقیاس‌پذیری و بهینگی در مصرف انرژی و اتکالپذیری بسیار مورد توجه است.

## ۲-۲- یادگیری عمیق

ایده اولیه یادگیری عمیق، در اواخر قرن بیستم با الهام از ساختار سلسله‌مراتبی سیستم ادراک و تولید گفتار انسان مطرح گردید. جهش بزرگ در یادگیری عمیق در سال ۲۰۰۶ زمانی رخ داد که آقای هینتون ساختار نوینی برای یادگیری عمیق به نام شبکه باور عمیق<sup>۱</sup> ارائه نمود. در این ساختار فرآیند یادگیری متشکل از دو مرحله پیش آموزش و تنظیم دقیق است. در مرحله اول بردار مشاهده به‌عنوان ورودی در جهت پیش آموزش و تولید بردار داده میانی و همچنین از همه مهم‌تر تولید وزن‌های اولیه برای مرحله بعدی است. در مرحله بعدی (تنظیم دقیق) که در ساده‌ترین حالت از سه لایه تشکیل شده‌است، هسته اصلی تفاوت این نوع یادگیری با روش‌های قبلی یادگیری می‌شود و از آنجائیکه مبتنی بر یادگیری بدون نظارت

1 Deep Belief Network (DBN)



شکل ۳. مقایسه معماری مدل کلاسیک کنترل با مدل ETE برگرفته از [۱۱]

Fig 3. Classic control model vs. ETE model (adapted from [11])

کراس<sup>۵</sup> و متلب<sup>۶</sup> برای پیاده‌سازی الگوریتم‌ها و شبکه‌های یادگیری عمیق دیده می‌شود.

• یادگیری عمیق به حل دقیق‌تر مسائلی می‌پردازد که روزبه‌روز

پیچیده‌تر می‌شوند و این دقت روزبه‌روز بیشتر می‌شود.

یکی از قدیمی‌ترین و پرکاربردترین ساختار ارائه‌شده برای شبکه عصبی عمیق، شبکه‌های عصبی کانولوشنی<sup>۷</sup> است. این ساختار به طور کلی متشکل از لایه‌های استخراج‌کننده ویژگی در کنار لایه‌های تماماً متصل یا طبقه‌بند است. لایه‌های استخراج‌کننده ویژگی، متشکل از هسته‌های مربعی با ابعاد فرد است (۳×۳، ۵×۵، ۷×۷ و ...) و تعداد متفاوت است. اعمال این هسته‌ها همانند اعمال فیلتر بر روی تصاویر، منجر به شکلگیری ویژگی‌های مختلف استخراج‌شده می‌گردند. مقادیر وزن‌های این هسته‌ها در زمان آموزش براساس داده‌های آموزش تعیین می‌شوند اما تعداد و ابعاد را طراحان در زمان تعیین ساختار شبکه مشخص می‌نمایند. تفاوت در ساختار بکارگیری این لایه‌ها در کنار استفاده از تعدادی از لایه‌های تماماً متصل با تعداد نرون متفاوت در هرلایه، سبب شکلگیری شبکه‌های عصبی عمیق برای کاربردهای متفاوتی از جمله دسته‌بندی و قطعه‌بندی تصاویر می‌شود. کاربرد مورد نظر ما در این مقاله استفاده از شبکه عصبی عمیق برای کاربرد رگرسیون است یعنی نگاشت مستقیم تصاویر جاده به زاویه فرمان خودرو که برای انجام این مهم تغییراتی در شبکه

هستند که تعیین‌کننده اصلی کارایی و دقت می‌باشند. از طرف دیگر تطبیق و تغییر شبکه در زمان اجرا نیز نیازمندی دیگری است که باید مورد توجه قرار بگیرد. مجموع این عوامل توجه خاص طراحان را معطوف به انتخاب دقیق روش پیاده‌سازی و همچنین چگونگی پیاده‌سازی می‌نماید که بتواند کارایی لازم را تضمین کند [۱۰].

به طور خلاصه، در روش‌های ارائه‌شده مبتنی بر یادگیری عمیق، روندهای زیر مشاهده می‌شوند که عبارت‌اند از:

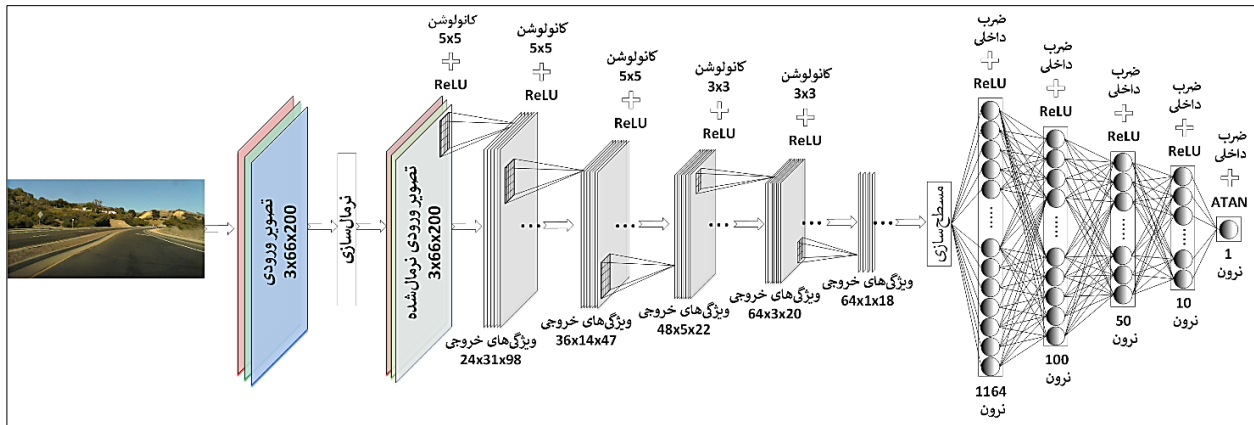
• یادگیری عمیق در مسیر تاریخچه طولانی و غنی خود با اسامی مختلفی که برگرفته از نقطه‌نظرهای متفاوت فلسفی است مطرح شده‌است.

• یادگیری عمیق در جایی سودمندی بیشتری خواهد داشت که مقدار داده‌های آموزشی موجود افزایش یابد. لازم به ذکر است میزان داده مورد نیاز وابسته به نوع کاربرد و نوع داده آن و همچنین ساختار شبکه عصبی عمیق متفاوت است.

• مدل‌های یادگیری عمیق با بهبود زیرساخت‌های سخت‌افزاری و نرم‌افزاری، از نظر سایز روزبه‌روز رشد می‌نمایند. این بهبود در سخت‌افزارهایی چون واحد پردازنده گرافیکی<sup>۱</sup>، واحد پردازشی تنسور<sup>۲</sup> و آرایه‌های منطقی برنامه‌پذیر<sup>۳</sup> با معرفی معماری‌های بهینه‌شده برای کاربرد یادگیری عمیق و در نرم‌افزار با ارائه ابزارهایی چون تنسورفلو<sup>۴</sup>،

5 Keras  
6 MATLAB  
7 Convolutional Neural Network (CNN)

1 Graphics Processing Unit (GPU)  
2 Tensor Processing Unit (TPU)  
3 Filed Programmable Gate Arrays (FPGA)  
4 TensorFlow



شکل ۴. ساختار شبکه عصبی عمیق استفاده شده در روش پیشنهادی

Fig. 4. Deep neural network structure utilized in our proposed method

آموزش به صورت برون-خطی بر روی پردازنده‌های گرافیکی انجام می‌شود با توجه به این مسئله که در این مرحله میزان برون‌دهی بستر سخت‌افزاری مورد توجه است. مرحله اجرا از نظر محاسباتی سبک‌تر از مرحله یادگیری است اما پارامتر تاخیر حتی بیشتر از میزان برون‌دهی اهمیت دارد بویژه در کاربردهایی که دارای قیدها و نیازمندی‌های اکید بلادرنگی هستند [۱۳].

خط لوله مربوط به بارکاری اجرا متشکل از مراحل زیر است:

- در قدم اول می‌بایست از طریق حسگرهای مختلف قادر به درک محیط پیرامون خود باشد
- در قدم بعدی می‌بایست داده‌های درک‌شده را در راستای استخراج ویژگی‌های مورد نیاز پردازش نماید
- پس از آن سیستم در نقش کنترل‌کننده موتورها به برنامه‌ریزی و کنترل رانندگی وسیله نقلیه می‌پردازد
- این روش در بسیاری از مسائل کنترلی بلادرنگ شامل رباتیک و کاربردهای دیگر سیستم‌های فیزیکی-رایانشی و بحرانی-ایمن مورد بررسی قرار گرفته است [۱۲].

#### ۲-۴- ساختار کنترل‌کننده عصبی یادگیرنده عمیق

در طراحی کنترل‌کننده‌های عصبی یادگیرنده عمیق مهمترین مسئله انتخاب ساختار شبکه مناسب جهت کاربرد مورد نظر است. در کاربرد کنترل ماشین‌های خودران، در روش انتها-به-انتها لازم است تا یک شبکه عصبی عمیق به طور مستقیم از رفتار انسان در حین

عصبی عمیق دسته‌بند تصاویر صورت می‌پذیرد که در بخش روش پیشنهادی توضیح داده شده‌است.

#### ۲-۳- یادگیری انتها-به-انتها

استفاده از روش‌های مبتنی بر ادراک برای حل مسئله ماشین خودران در گذشته گسترش چشمگیری داشته است. همانطور که در شکل ۳ نمایش داده شده‌است، در این روش‌ها مسئله به چندین زیر مسئله مانند تشخیص خودرو، تشخیص عابر، تشخیص علائم و چراغ راهنما و همچنین برنامه‌ریزی مسیر و کنترل سطح پائین شکسته می‌شود و این اجزا با همدیگر تشکیل یک خط لوله محاسباتی می‌دهند [۱۱]. اما نقاط ضعفی که ناشی از عدم یادگیری و تطبیق، پیچیدگی طراحی و خاص منظوره بودن استخراج‌کننده‌های ویژگی است سبب کاهش محبوبیت این روش‌ها و توجه بیشتر به سمت روش‌های انتها-به-انتها شده‌است. این روش از طریق تولید مستقیم خروجی‌های کنترلی از روی ورودی سنسورها، خط لوله محاسباتی مورد نیاز را به طور چشمگیری ساده‌سازی می‌نماید. سادگی مفهوم و همچنین الگوی محاسباتی روش‌های انتها-به-انتها سبب موفقیت این روش‌ها در کاربردهای مختلف هدایت وسائل نقلیه در محیط‌های داخلی و خارجی مانند اجتناب از موانع، سیستم هدایت خودکار خارج از جاده و رانندگی خودکار شده‌است [۱۲]. وظیفه کنترل با استفاده از این روش شامل بارکاری آموزش و بارکاری اجراست. بیشتر توجه در اکثر کارهای تحقیقاتی معطوف به بارکاری اجراست. مرحله

هسته  $5 \times 5$  و پس از آن از ۲ لایه کانولوشن  $3 \times 3$  به دنبال یافتن ویژگی‌های مختلف تصویر مانند لبه به صورت خودکار هستیم. ویژگی‌های تولیدشده طی عملیات مسطح‌سازی به صورت تک بعدی وارد لایه اول شبکه تماماً متصل با ۱۱۶۴ نرون می‌شوند. لایه‌های بعدی شبکه تماماً متصل به ترتیب ۱۰۰، ۵۰ و ۱۰ نرون محاسباتی دارند که عملیات ضرب داخلی ورودی‌ها و وزن‌ها را انجام می‌دهند. تابع فعالیت همه لایه‌ها تابع واحد یکسوشده‌ی خطی<sup>۲</sup> است به جز تک نرون خروجی که تابع آرکتانژانت<sup>۳</sup> است (به این تک نرون در خروجی لایه رگرسیون نیز گفته می‌شود). دلیل این امر این است که بازه مقادیر تابع واحد یکسوشده‌ی خطی از ۰ تا ۱ است اما آرکتانژانت می‌تواند در بازه  $-90$  تا  $+90$  در خروجی عدد تولید نماید. اضافه‌شدن این تک نرون به انتهای شبکه در حقیقت شبکه دست‌بند تصاویر را به شبکه رگرسور تبدیل می‌کند که قادر به انجام عملیات رگرسیون برای تولید مستقیم تصاویر جاده به زاویه فرمان خودرو است.

روش کار استفاده‌شده شامل آموزش شبکه‌های عصبی عمیق برای استفاده در کنترل انتها- به- انتها ماشین خودران، اجرا در محیط واقعی و مقایسه با روش‌های سنتی در محیط شبیه‌سازی و همچنین بهینه‌سازی روش پیشنهادی است. روال کلی کار در شکل ۶ نمایش داده شده‌است. همانطور که در شکل نمایش داده شده‌است، این روال از دو فاز اصلی آموزش و اجرا تشکیل شده‌است. پس از اجرای این دو فاز اصلی، در روش پیشنهادی قابلیت پیاده‌سازی و مقایسه تعبیه شده‌است که در ادامه به شرح آن می‌پردازیم.

### ۳-۱- فاز آموزش

با توجه به اینکه روش کنترلی انتها- به- انتها داده- محور است، برای آموزش کنترل‌کننده عصبی عمیق لازم است تا ابتدا داده‌های آموزش تولید شوند. در این مرحله برای تولید داده‌ها از محیط شبیه‌سازی مبتنی بر موتور بازی‌سازی یونیتی<sup>۴</sup> استفاده شد. این محیط دارای قابلیت‌ها و ابزار لازم جهت راندگی خودکار/غیرخودکار، ضبط رویدادها و همچنین تولید خروجی‌های لازم از قبیل تصویر سه دوربین (چپ، راست، وسط)، زاویه ماشین، سرعت و میزان ترمز است [۱۹]. در فاز آموزش پس از جمع‌آوری داده‌های راندگی انسان،

راندگی یاد بگیرد و در زمان اجرا از طریق نگاشت تصاویر دوربین به زاویه چرخش فرمان، میزان فشار پدال گاز و میزان قدرت ترمز گرفتن، وسیله نقلیه را کنترل و مسیریابی نماید.

استفاده از روش یادگیری انتها- به- انتها در کاربرد ماشین خودران ابتدا در اواخر سال ۱۹۸۰ ارائه گردید که در آن نویسندگان سعی داشتند که از شبکه‌های عصبی مصنوعی کاملاً متصل سه لایه برای هدایت کردن وسیله نقلیه استفاده کنند [۱۴]. پس از آن در قالب پروژه وسیله نقلیه خودکار در آژانس پروژه‌های تحقیقاتی پیشرفته دفاعی ایالات متحده از شبکه‌های عصبی کانولوشنی شش لایه برای کنترل انتها- به- انتها استفاده شد [۱۵]. در سال ۲۰۱۶ در شرکت انویدیا در پروژه‌ای از ساختار ۹ لایه (شکل ۴) به شکلی استفاده شد که به صورت مستقیم تصاویر دوربین به دستورات کنترلی برای موتورهای تبدیل شود و کلیه لایه‌های میانی سنتی که به صورت دستی طراحی می‌شدند حذف شدند [۱۶-۱۸].

این ساختار ۹ لایه با استفاده لایه‌های کانولوشنی به استخراج ویژگی‌های تصاویر ورودی می‌پردازد و سپس عملیات دست‌بندی در لایه‌های تماماً متصل شکل می‌گیرد. تک نرون خروجی نتیجه این عملیات را به زاویه خروجی تبدیل می‌کند. عملکرد مناسب این شبکه کنترلی برای کاربرد ماشین خودران و از سوی دیگر ساختار نه‌چندان پیچیده آن سبب شده‌است تا در روش پیشنهادی از آن استفاده شود. در روش پیشنهادی بخش‌هایی به این شبکه اضافه شدند که در بخش بعدی توضیح داده می‌شوند.

### ۳-۲ روش پیشنهادی

همانطور که در بخش قبل توضیح داده شد، ساختار شبکه عصبی عمیق کنترلی بر پایه شبکه پایلوت<sup>۱</sup> است. علاوه بر این در راستای بهبود عملکرد و همچنین تطبیق آن با بستر آزمایش تغییراتی بر روی آن صورت گرفته‌است. در مرحله اول بر روی تصاویر ورودی پیش‌پردازش انجام می‌شود. این پیش‌پردازش می‌تواند شامل کاهش ابعاد ورودی، اعمال فیلتر، کوانتیزه کردن، کاهش حجم داده و تغییر در مقادیر پیکسل و... باشد. در روش پیشنهادی از نرمال‌سازی مقادیر پیکسل‌ها به مقدار میانه برای نرمال‌سازی توزیع مقادیر آن‌ها استفاده شده‌است. در این ساختار با استفاده از ۳ لایه کانولوشن با اندازه

2 ReLU  
3 Arctangent  
4 Unity


1 Pilot Net

جدول ۱. پیکربندی فاز آموزش

Table 1. Parameters of training phase

مقدار	پارامتر
آدام <sup>۱</sup>	الگوریتم بهینه‌سازی
$1 \times 10^{-4}$	نرخ آموزش اولیه
۰/۵	نرخ حذف تصادفی
۲۰۰۰	حداکثر تعداد دوره <sup>۲</sup> آموزش
۱۰۰	اندازه دسته <sup>۳</sup>

<sup>۱</sup> Adam



شکل ۵. نمودار مقادیر loss فاز آموزش

Fig. 5. Training and validation loss

نحوه دسته‌بندی داده‌های آموزش فرآیند آموزش را در راستای بدست‌آوردن دقت و سرعت آموزش مورد نظر تنظیم نمود. پیکربندی مرحله آموزش در جدول ۱ آورده شده‌است. یکی از مهمترین تفاوت‌های ساختار شبکه در فاز آموزش و اجرا استفاده از لایه حذف تصادفی<sup>۱</sup> است. به این معنی که به عدد تعیین‌شده برای این پارامتر احتمال حذف برای نرون‌ها در فاز آموزش در نظر گرفته می‌شود و نرون مذکور نادیده گرفته می‌شود. محل قرارگرفتن این لایه در ساختار استفاده‌شده در این مقاله، بعد از اولین لایه تماماً متصل است. لازم به ذکر است بیشتر مقادیر پیکربندی با استفاده از سعی و خطا و پارامترهای پیشنهادی در مقالات تعیین شده‌است.

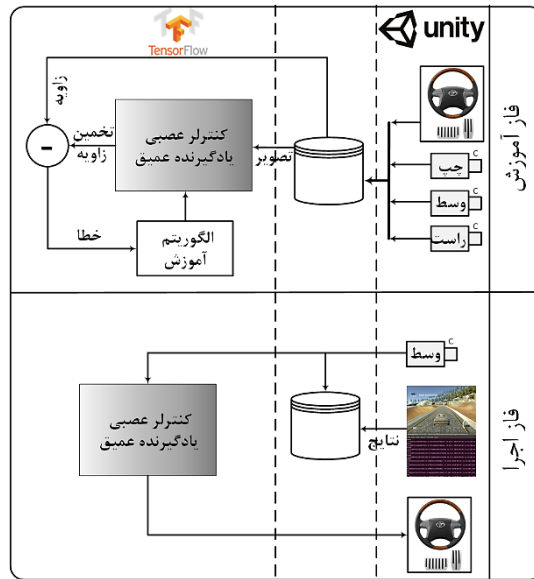
در فاز آموزش ماشین خودران سایز کوچک و در محیط واقعی،

1 Dropout

این داده‌ها در فرمت مورد نظر خروجی گرفته می‌شوند و سپس بر روی دیسک ذخیره می‌شوند. لازم به ذکر است داده‌هایی که انسان بدون خطا مسیر در نظر گرفته‌شده را طی می‌کند برای آموزش شبکه کنترلی انتخاب می‌شوند. این داده‌ها شامل تصویر، زاویه فرمان و میزان گاز و ترمز است. در مرحله بعدی با استفاده از ابزار یادگیری عمیق تنسورفلو (نسخه ۲) ابتدا ساختار مورد نظر پیاده‌سازی و سپس الگوریتم آموزش شبکه عمیق برنامه‌نویسی می‌شوند.

پس از این مرحله الگوریتم آموزش، تصاویر و زاویه‌های جمع‌آوری‌شده از رانندگی انسان را بارگذاری می‌کند و پارامترهای شبکه عصبی عمیق را در راستای حداقل‌سازی خطا آموزش می‌دهد. در این مرحله می‌توان با بهره‌گیری از پارامترهای مختلف شامل الگوریتم بهینه‌سازی، نرخ یادگیری، تعداد تکرار آموزش و همچنین





شکل ۶. روش پیشنهادی برای آموزش و اجرای کنترل کننده ETE

Fig. 6. Proposed model for both training and inference phases of ETE control system

از مقادیر بدست آمده نمونه برداری می شود و در انتها بهترین نمونه به عنوان مقادیر نهایی پارامترهای شبکه ذخیره می شوند. نمودار مقادیر تابع هزینه<sup>۱</sup> برای آموزش و مرحله اعتبارسنجی<sup>۲</sup> در شکل ۵ آورده شده است. پس از اتمام این مرحله، پارامترهای تعیین شده در مرحله آموزش می تواند در فاز اجرا مورد استفاده قرار بگیرد.

### ۳-۲- فاز اجرا

در این مرحله شبکه عمیق آموزش دیده در محیط تنسورفلو بارگذاری می شود و تصویر دوربین وسط به آن اعمال می شود و زاویه تخمین زده شده و همچنین میزان فشار پدال گاز و ترمز به محیط شبیه سازی ارسال می شود. محیط شبیه سازی براساس این زاویه و سرعت تعیین شده توسط کنترل کننده عامل ماشین خودران را در مسیر تعیین شده به حرکت در می آورد. این مسیر دارای اشیاء و مناظر مختلف و همچنین جاده با الگوهای متفاوت است.

در مورد اجرای شبکه بر روی بستر واقعی آزمایش، در این مرحله شبکه آموزش دیده به برد پردازشی جهت اجرا و ارزیابی بر روی مسیر واقعی منتقل می شود. در فاز اجرا، ماشین خودران در تکرارهای

ماشین خودران سایز کوچک توسط انسان طی ۳۱ مرحله بر روی مسیر نمایش داده شده در شکل ۱۰، هدایت شده و داده های مربوط به دوربین و هدایت انسان بر روی حافظه برد پردازشی ذخیره می شود. لازم به ذکر است در هر بار اجرای این مرحله، نقطه شروع و زاویه حرکت به صورت تصادفی و غیر تکراری تعیین شده است.

پس از اتمام این مرحله، فایل های ذخیره شده بر روی حافظه برد پردازشی به کامپیوتر برای اجرای فاز آموزش انتقال داده می شوند. این فایل ها به سه دسته شامل آموزش، تست و ارزیابی تقسیم می شوند. نسبت در نظر گرفته برای این تقسیم بندی به نسبت کل داده ها به ترتیب عبارتست از: ۲۰، ۷۰ و ۱۰ درصد. پس از آن الگوریتم آموزش شبکه عصبی عمیق در ابزار تنسورفلو اجرا، و وزن ها و پارامترهای شبکه تعیین می شوند. لازم به ذکر است پیکربندی آزمایشها شامل تعداد و نوع لایه های شبکه عصبی عمیق و همچنین پارامترهای الگوریتم آموزش مانند آزمایش های بخش ۴ در نظر گرفته شده است. الگوریتم آموزش پس از طی ۱۰ گام، به دقت آموزش ۹۹ درصد و دقت ارزیابی ۹۸ درصد رسید.

فاز آموزش بر روی کامپیوتر با مشخصات جدول ۹ پیاده سازی و اجرا شده است. نکته قابل توجه در مورد مرحله آموزش این است که در این مرحله در نقطه های مختلف، در بازه های زمانی مشخص،

1 Loss Function  
2 Validation

به چگونگی این وابستگی پرداخته می‌شود.

### ۳-۳-۲- کنترل کننده کنترل پیشبین مدل

این کنترل کننده که یکی از روش‌های کنترلی پیشرفته است، از مدل ریاضی دینامیکی سیستم تحت کنترل برای پیش‌بینی رفتار آینده آن استفاده می‌کند و دنباله‌ای از ورودی‌های کنترلی بهینه به گونه‌ای محاسبه می‌نماید که محدودیت‌های داده شده را نقض نکند و همچنین کارایی بهینه مورد نظر را بدست آورد. مدل دینامیکی سیستم می‌تواند به صورت رابطه گسسته- زمان (رابطه ۲) در نظر گرفته شود:

$$x_{k+1} = f(x_k, u_k) \quad (2)$$

که در آن  $x_k \in R^n$  بیانگر وضعیت سیستم در زمان  $k$  است و  $u_k \in R^m$  ورودی کنترلی است. یکی از نقاط قوت کنترل کننده MPC، قابلیت اعمال آن به سیستم‌های غیرخطی، در نظر گرفتن محدودیت‌های کلی و همچنین وظایف کنترلی متفاوت به نسبت سیستم‌های کنترلی کلاسیک دنبال کننده نقطه هدف<sup>۱</sup> است. چالش مهم استفاده از کنترل کننده‌های کنترل پیشبین مدل این است که پیاده‌سازی آنها نیازمند یک حل برخط از مسئله بهینه‌سازی که در رابطه (۳) آورده شده است، در هر زمان نمونه‌برداری است.

$$\begin{aligned} \min_{u_k} \quad & \sum_{k=0}^{N-1} J(x_k, u_k) \\ \text{subject to} \quad & x_{k+1} = f(x_k, u_k), x_0 = \hat{x} \\ & g(x_k, u_k) \leq 0 \end{aligned} \quad (3)$$

در این رابطه  $g$ ، توصیف کننده محدودیت‌های کلی و  $\hat{x}$  وضعیت فعلی سیستم است که این کمیت می‌بایست به ازای هر محاسبه برای بدست آوردن دستور کنترلی یا اندازه گیری شود یا تخمین زده شود. معیار کارایی در حقیقت همان تابع هزینه است که با  $J$  بیان می‌شود و  $N$  پنجره پیش‌بینی است. در هر مرحله از دنباله کنترلی بهینه

مختلف در نقاط مختلف مسیر و زاویه شروع به حرکت مختلف قرار داده می‌شود و فرمان شروع از طریق نرم افزار واسط که به زبان پایتون نوشته شده است، صادر می‌شود. برد پردازشی شبکه عصبی آموزش دیده را از طریق ابزار تنسورفلو نصب شده بر روی سیستم عامل خود اجرا و نرم افزار واسط تصاویر ورودی از دوربین را به شبکه اعمال و خروجی شبکه را به راه انداز موتورها ارسال می‌نماید. نرم افزار واسط به صورتی طراحی شده است که می‌تواند کنترل ماشین خودران را از حالت خودکار به حالت دستی و هدایت انسان تغییر دهد. علاوه بر تغییر نقطه و زاویه شروع حرکت، سرعت‌های مختلف نیز برای حرکت ماشین نیز در نظر گرفته شده است.

### ۳-۳-۳- مقایسه


در مرحله مقایسه از دو کنترل کننده کلاسیک پر کاربرد یعنی کنترل کننده‌های تناسبی- انتگرال- مشتقگیر و کنترل پیشبین مدل استاندارد استفاده شده است. از آنجائیکه این کنترل کننده‌ها بدون قابلیت یادگیری هستند در مرحله اجرا به جای استفاده از تنسورفلو و کنترل کننده عصبی یادگیرنده عمیق، از آن کنترل کننده‌ها استفاده شده است. در ادامه به تعریف این کنترل کننده‌ها و چالش‌هایی که در استفاده از آنها وجود دارد پرداخته می‌شود.

### ۳-۳-۱- کنترل کننده تناسبی- انتگرال- مشتقگیر

یکی از متداولترین انواع کنترل کننده بازخوردی موجود کنترل کننده تناسبی- انتگرال- مشتقگیر است. این کنترل کننده به صورت پیوسته یک تابع خطا محاسبه می‌کند و به سیستم کنترل شونده به گونه‌ای فرمان‌های اصلاحی ارسال می‌کند تا خطا به حداقل برسد. براساس رابطه (۱) این کار براساس تجمیع سه جمله تناسب (P)، انتگرال (I) و مشتق (D) صورت می‌پذیرد. که در آن  $e$  بیانگر خطا و  $u$  خروجی کنترل کننده است.

$$u(t) = K_p e(t) + K_I \int_0^t e(\tau) d\tau + K_D \frac{de(t)}{dt} \quad (1)$$

لازم به ذکر است رفتار این کنترل کننده به مقدار تعیین شده برای ضرایب یا بهره‌های  $K_p, K_I, K_D$  بستگی دارد. در ادامه در بخش نتایج



شکل ۷. مدل خودرو

Fig. 7. Vehicle's model

پیش‌بینی رفتار آینده سیستم کنترل شونده مورد نیاز است. در این مقاله از مدل پیشنهادی [۲۰] برای خودرو استفاده شده است. این مدل در شکل ۷ مشخص شده است. براساس این مدل روابط غیر خطی پیوسته- زمان مربوط به حرکت خودرو عبارتند از:

$$\beta = \tan^{-1}\left(\frac{l_r}{l_r + l_f} \tan(\delta_f)\right) \quad (۴)$$

$$\dot{x} = v \cos(\psi + \beta)$$

$$\dot{y} = v \sin(\psi + \beta)$$

$$\dot{\psi} = \frac{v}{l_r} \sin(\beta)$$

$$\dot{v} = a$$

در کاربرد ماشین‌های خودران نه تنها خودرو بلکه محیط پیرامون دارای دینامیک پیچیده و عدم قطعیت هستند که بیان ریاضی آن بسیار دشوار و معمولاً غیردقیق است. این در حالیست که کنترل‌کننده انتها-به-انتهای مدل دقیق از خودرو و محیط نیاز ندارد. از این نقطه نظر این کنترل‌کننده‌ها به دو روش کلاسیک کنترلی برتری دارند.

#### ۴-۲- وابستگی به پارامترها

همانطور که قبلاً هم بیان شد رفتار کنترل‌کننده تناسبی-انتگرال- مشتقگیر به پارامترهای  $K_p, K_I, K_D$  وابستگی دارد. این

محاسبه‌شده یعنی  $(u_0, \dots, u_{N-1})$  تنها اولین عنصر  $u$  به سیستم اعمال می‌شود و در مرحله بعدی مسئله بهینه‌سازی یکسانی برای وضعیت جدید سیستم محاسبه می‌شود.

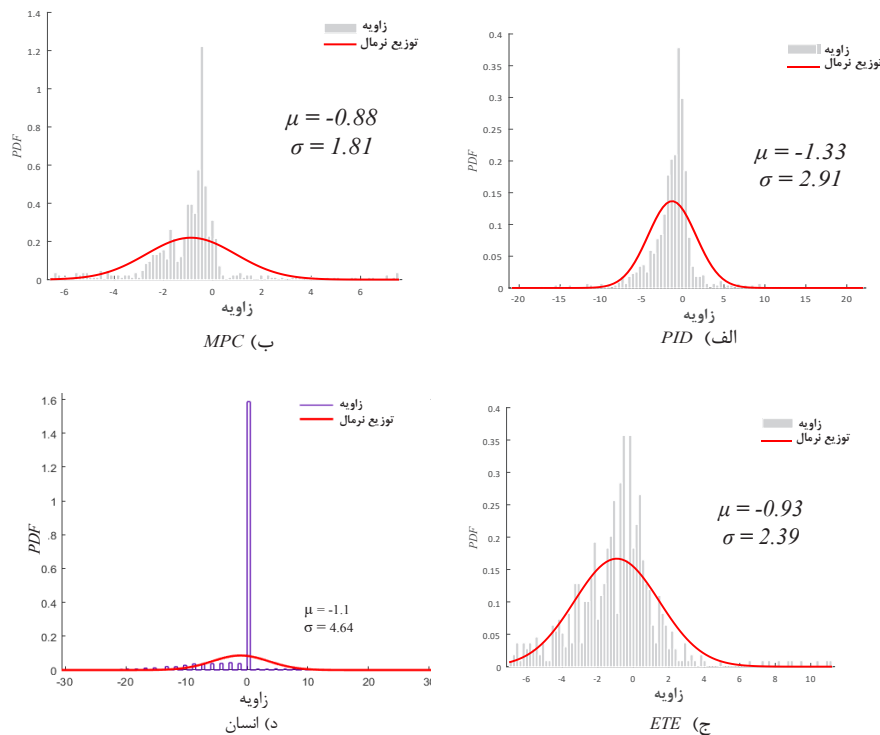
اگر چه در سال‌های اخیر پیشرفت‌های بسیاری در سخت‌افزارها و الگوریتم‌های پیاده‌سازی این روش کنترلی بدست آمده است، اما برای کاربردهایی که به زمان نمونه‌برداری در محدوده میکروثانیه نیاز باشد حل معادلات و رابطه‌های ذکرشده در زمان اجرا می‌تواند چالش بسیار بزرگی باشد [۳].

#### ۴- نتایج

در این بخش در ابتدا به صورت کیفی کنترل‌کننده یادگیرنده عمیق با کنترل‌کننده‌های کلاسیک تناسبی-انتگرال-مشتقگیر و کنترل پیشبین مدل مقایسه می‌شوند. سپس براساس نتایج بدست‌آمده از آزمایش‌ها این کنترل‌کننده‌ها برای کاربرد ماشین خودران به صورت کمی با یکدیگر مقایسه می‌شوند.

#### ۴-۱- وابستگی به مدل

هر دو کنترل‌کننده تناسبی-انتگرال-مشتقگیر و کنترل پیشبین مدل نیازمند مدل دقیقی از سیستم کنترل شونده هستند. البته نوع وابستگی به مدل برای این دو کنترل‌کننده متفاوت است. برای کنترل‌کننده تناسبی-انتگرال-مشتقگیر مدل سیستم کنترل شونده برای تنظیم ضرائب یا بهره‌های کنترلی برای بدست‌آمدن حالت بهینه مورد نیاز است در حالیکه در کنترل‌کننده کنترل پیشبین مدل، برای



شکل ۸. توزیع آماری خروجی زاویه کنترل کننده‌ها و انسان

Fig. 8. Statistical distribution functions of output angles (PID, MPC, ETE, and human)

کنترل‌کننده به صورت پیوسته بر اساس مشتق، انتگرال و جمع خطا و ضرایب آن‌ها یک فرمان اصلاحی به سیستم کنترل‌شونده ارسال می‌کند. ضریب  $K_p$  تعیین‌کننده میزان تاثیر بزرگی خطا در تغییر خروجی است. اگر میزان این ضریب به درستی تعیین نشود می‌تواند ناپایدار شود. ضریب انتگرال یعنی  $K_I$  هم در بزرگی و هم در مدت زمان خطا مشارکت دارد. این جمله باعث حذف خطای حالت پایدار باقیمانده که مشکل اساسی کنترل‌کننده‌های P نیز هست، می‌شود. ضریب مشتق خطا،  $K_d$  تعیین‌کننده میزان تاثیر تغییر نرخ خطا در فرمان کنترلی است. به عبارت دیگر هر چقدر به نقطه هدف مطلوب نزدیکتر شویم می‌بایست فرمان کنترلی نرمتری صادر شود تا جهش اضافه در سیستم اتفاق نیفتد. این ضریب به پایداری و زمان استقرار سیستم کمک می‌کند.

کنترل‌کننده کنترل پیشبین مدل، مبتنی بر مدل دینامیکی سیستم کنترل‌شونده است و بر خلاف کنترل‌کننده تناسبی-انتگرال-مشتقگیر قابلیت پیشبینی رخداد‌های آینده و تصمیم‌گیری کنترلی براساس آن را دارد. در حقیقت رفتار کنترلی بازه زمانی فعلی این کنترل‌کننده براساس بازه‌های زمانی آینده بهینه‌سازی می‌شود. رفتار این کنترل‌کننده علاوه بر مدل دینامیکی، به تعیین دقیق محدودیت‌های سیستم کنترل‌شونده مانند محدودیت پاسخ عملگرهای سیستم و همچنین یک تابع هزینه دقیق است که در جهت بهینه‌سازی رفتار این کنترل‌کننده مورد استفاده قرار می‌گیرد. محدوده پیش‌بینی یکی دیگر از پارامترهای مهم در کارایی کنترل‌کننده کنترل پیشبین مدل است. این پارامتر از رابطه (۵) بدست می‌آید.

با توجه به مطالب بالا تعیین دقیق ضرایب، تعیین‌کننده کارایی کنترل‌کننده تناسبی-انتگرال-مشتقگیر است و این درحالیست که این موضوع نیازمند در اختیارداشتن مدل ریاضی دقیق از سیستم

جدول ۲. مشخصات آماری زاویه های خروجی (برحسب درجه)

Table 2. Characteristics of output angles (in terms of degree)

کنترل کننده	واریانس	انحراف معیار	حداکثر	حداقل
تناسبی-انتگرال-مشتقگیر	۶/۲۹	۲/۵۰	۲۱/۹۹	۰/۰۰۱۵
کنترل پیشبین مدل	۲/۲۳	۱/۴۹	۷/۵۵	۰/۰۰۴۱
انتها-به-انتها	۳/۲۶	۱/۸۰	۱۱/۱۷	۰/۰۰۲۷
انسان	۲۱/۵۴	۴/۶۴	۳۰	۰

جدول ۳. داده های آماری کنترل سرعت (برحسب کیلومتر بر ساعت)

Table 3. Statistical parameters of speed control (in terms of kph)

کنترل کننده	واریانس	انحراف معیار	حداکثر	حداقل
تناسبی-انتگرال-مشتقگیر	۱۸/۷۱	۴/۳۲	۴۲/۴	۰
کنترل پیشبین مدل	۳۴/۶۴	۵/۸۸	۵۱/۶۶	۰
انتها-به-انتها	۱۹/۴۳	۴/۴۰	۴۲/۷۳	۰
انسان	۱۱/۲۹	۳/۳۶	۳۵/۳۲	۰

با افزایش تعداد متغیرهایی که می بایست برای بهینه سازی در نظر بگیرد، افزایش می یابد. تعداد متغیرهای بهینه سازی متناسب با  $N$  است و چالش کار این است که  $T$  بزرگ و  $dt$  کوچک منجر به  $N$  بزرگ می شود. کنترل کننده های انتها-به-انتها، از نظر بار محاسباتی وابسته به ابعاد ورودی، ساختار و ابعاد لایه های تشکیل دهنده آن هستند.

نکته مهم دیگر که از این نقطه نظر اهمیت دارد وابستگی کنترل پیشبین مدل به الگوریتم های تشخیص خط است که موجب تحمیل بارکاری اضافه علاوه بر بار کاری اجرای الگوریتم کنترلی به بستر پیاده سازی است. در حالیکه روش انتها-به-انتها پایه علاوه بر محاسبات لایه های اصلی نیازی به محاسبات اضافه دیگری ندارد.

$$T = N * dt \quad (5)$$

که در آن  $N$  تعداد بازه های زمانی و  $dt$  طول هر بازه است. افزایش بیش از اندازه  $dt$  سبب افزایش زمان بین تصمیم گیری کنترل کننده می شود که این سبب می شود که سیستم به سختی بتواند یک مسیر مرجع پیوسته را دنبال نماید. که با آن خطای گسسته سازی گفته می شود. اگر چه افزایش اندازه  $T$  سبب افزایش محدوده پیش بینی می شود اما در دنیای واقع پیش بینی زمان های خیلی دور، منطقی به نظر نمی رسد و در شبیه سازی انجام شده افزایش بیش از حد این پارامتر سبب خروج خودرو از خط می شود.

#### ۴-۴- توزیع آماری زاویه خروجی

در این بخش رفتار کنترل کننده های مورد بررسی از نظر زاویه خروجی محاسبه شده توسط آنها مورد بررسی قرار داده شده است. این بررسی از جهت استهلاک خودرو، آسایش سرنشینان و ایمنی مورد توجه است. در شکل ۸ تابع چگالی احتمال زاویه خروجی کنترل کننده های

#### ۴-۳- بار محاسباتی

بار محاسباتی کنترل کننده های تناسبی-انتگرال-مشتقگیر به پارامترهای کنترلی وابستگی ندارد و تنها به نرخ نمونه برداری سیستم وابسته است و بار محاسباتی کمتری نسبت به دو کنترل کننده دیگر دارد. در حالیکه در کنترل کننده کنترل پیشبین مدل بار محاسباتی

جدول ۴. استفاده از ترمز

Table 4. Utilization of brake system

کنترل کننده	تعداد دفعات تخطی از آستانه	حداکثر شتاب ترمز (m/s <sup>2</sup> )	واریانس شتاب (m/s <sup>2</sup> )
تناسبی-انتگرال-مشتقگیر	۹	۸/۰۹	۱/۸۲
کنترل پیشبین مدل	۱۷۷	۸/۴	۳۰/۷۵
انتها-به-انتها	۲۹	۸/۹۴	۱۸/۲

جدول ۵. خطای تصمیم گیری

Table 5. Decision making errors

کنترل کننده	خطای سرعت	خطای ترمز	خطای گاز	خطای زاویه فرمان
تناسبی-انتگرال-مشتقگیر	۱۶۱/۸۳	$1 \times 10^{-4}$	۰/۰۵۷۱	۰/۰۳۶۵
کنترل پیشبین مدل	۲۴۰/۰۷	۰/۲	۰/۵۲۸۲	۰/۰۲۶۵
انتها-به-انتها	۱۶۸/۷۶	۰	۰/۰۵۳۷	۰/۰۳۲۳

همچنین زمان رسیدن به مقصد مورد توجه است. در آزمایش‌های انجام شده برای این مقاله حداکثر سرعت ۳۰ مایل بر ساعت (۴۸٫۲ کیلومتر بر ساعت) تعیین شده است. همانطور که در جدول ۳ مشاهده می‌شود کنترل کننده کنترل پیشبین مدل این محدوده مجاز را نقض کرده است و کنترل کننده تناسبی-انتگرال-مشتقگیر نیز نمی‌تواند از سرعت مجاز بهره کافی ببرد و در صورت اجبار کنترل کننده به استفاده از سرعت‌های بالاتر منجر به خروج خودرو از جاده می‌شود. در حالیکه کنترل کننده انتها-به-انتها محدوده مجاز سرعت را نقض نمی‌کند و تا حد ممکن به حداکثر سرعت مجاز نزدیک می‌شود.

از نظر سرعت رسیدن به مقصد کنترل پیشبین مدل و بعد از آن کنترل کننده انتها-به-انتها بهترین رفتار را دارند این در حالیست که نوسانات شدید سرعت در کنترل پیشبین مدل هم سبب ایجاد استهلاک و مصرف سوخت بیشتر و هم ایجاد حالت نامتعادل و احساس نامطلوب در سرنشینان می‌شود. اما کنترل کننده انتها-به-انتها استراتژی متعادلی از این نظر اتخاذ می‌کند که هم بتواند از حداکثر مجاز سرعت بهره کافی ببر و زمان رسیدن به مقصد طولانی نشود و هم اینکه تغییرات سرعت کمتری به نسبت کنترل پیشبین مدل داشته باشد.

#### ۴-۶- تغییرات شتاب و استفاده از ترمز

پارامتر دیگری که می‌تواند در مقایسه کنترل کننده‌های ماشین خودران مورد استفاده قرار بگیرد میزان و نحوه استفاده از ترمز است.

تناسبی-انتگرال-مشتقگیر (الف)، کنترل پیشبین مدل (ب)، انتها-به-انتها (ج) و رانندگی توسط انسان (د) آورده شده است.

در این شکل نزدیکترین توزیع نرمال برای تابع چگالی احتمال داده‌های خروجی کنترل کننده‌ها و همچنین میانگین و انحراف از معیار نیز گزارش شده است. مشخصات آماری زاویه‌های خروجی کنترلی بر حسب درجه در جدول ۲ آورده شده است.

این نتایج نشان می‌دهد تناسبی-انتگرال-مشتقگیر دستورات با زاویه تند (میانه و حداکثر بیشتر) و میزان تغییرات بیشتر (انحراف از معیار بیشتر) صادر می‌کند و این امر سبب فشار و استهلاک بیشتر به خودرو، ایجاد حالت نامطلوب برای سرنشینان و همچنین ایمنی کمتر در شرایط لغزندگی جاده می‌شود. از این نقطه نظر کنترل پیشبین مدل بهترین رفتار را از خود نشان می‌دهد و کنترل کننده انتها-به-انتها با اختلاف کم نسبت به آن عملکرد بهتری نسبت به تناسبی-انتگرال-مشتقگیر از خود نشان می‌دهد. علاوه بر این زوایای خروجی از کنترل پیشبین مدل میانه نزدیکتری به زاویه صفر دارند و از این نظر کنترل کننده انتها-به-انتها عملکرد بهتری نسبت به تناسبی-انتگرال-مشتقگیر دارد.

#### ۴-۵- کنترل سرعت

در این بخش نحوه کنترل سرعت کنترل کننده‌ها مورد توجه است. این پارامتر با توجه به ملاحظات ایمنی، مصرف سوخت و انرژی و

جدول ۶. مسافت طی شده کنترل‌کننده‌ها بر حسب متر

Table 6. Traveling distance of the controllers (in terms of meters)

کنترل‌کننده	مسافت طی شده
تناسبی-انتگرال-مشتقگیر	۱۱۷۰
کنترل پیشبین مدل	۱۴۲۳
انتها-به-انتها	۱۰۹۳

جدول ۷. مشخصات پیکربندی آزمایش

Table 7. Experimental setup configuration

پردازنده	اینتل i7-7700
حافظه اصلی	۱۶ گیگابایت
دیسک سخت	۲۵۶ گیگابایت
پردازنده گرافیکی	اینتل ۳۶۰
سیستم‌عامل	لینوکس ابونتو ۱۸/۰۴

در نظر گرفتن خطا در تصمیم‌گیری در مقایسه با رانندگی انسان است این تصمیم‌گیری شامل زاویه فرمان خودرو، میزان گاز و میزان ترمز است. برای مقایسه خطای کنترل‌کننده‌ها از رابطه (۶) استفاده شده است. که در آن میانگین مربعات اختلاف مقادیر اندازه‌گیری شده و مقدار مرجع که مربوط به رانندگی انسان است محاسبه شده است. نتایج این مقایسه در جدول ۵ آورده شده است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (6)$$

همانطور که مشاهده می‌شود، کنترل‌کننده انتها-به-انتها در مقایسه با دو کنترلر دیگر از نقطه نظر میزان ترمز و گاز عملکرد بهتری دارد. اما از نظر زاویه فرمان و سرعت در جایگاه دوم و به ترتیب پس از کنترل پیشبین مدل و تناسبی-انتگرال-مشتقگیر قرار گرفته است و می‌بایست عملکرد آن در این زمینه بهبود یابد.


#### ۴-۸-ایمنی

اگرچه برای ایمنی می‌توان تعاریف متعددی ارائه نمود، در این تحقیق با توجه به محیط شبیه‌سازی و همچنین صورت مسئله یعنی

در جدول ۵ داده‌های مربوط به این کمیت آورده شده است. با توجه به اینکه مکانیزم کنترلی انتها-به-انتها رانندگی را از انسان آموزش می‌بیند رفتار بهینه‌ای در این خصوص از خود نشان می‌دهد و سعی می‌کند با کنترل میزان گاز خودرو را تحت کنترل داشته باشد در حالیکه کنترل پیشبین مدل به وفور از ترمز استفاده می‌کند. این موضوع نشان می‌دهد که کنترل پیشبین مدل سبب اعمال استهلاک بیشتر به خودرو می‌شود. همچنین استفاده متعدد از ترمز می‌تواند سبب احساس نامطلوب در سرنشینان خودرو شود. آستانه احساس نامطلوب در اثر ترمز گرفتن برای سرنشینان حداکثر شتاب  $2 \text{ m/s}^2$  است [۲۱]، که در جدول ۴ تعداد دفعات تخطی از این آستانه برای کنترل‌کننده‌ها آورده شده است. البته لازم به ذکر است که این رفتار می‌تواند با تغییر پارامترهای این کنترل‌کننده‌ها تاحدی اصلاح گردد و نیازمند سعی و خطای بسیار و تجربه فراوان است. واریانس استفاده از پدال گاز و ترمز که راننده بر عکس یکدیگر از آن استفاده می‌کند نشان‌دهنده تغییرات شتاب خودرو است در جدول ۶ تحت عنوان واریانس شتاب آورده شده است.


#### ۴-۷-خطا

یکی از مهمترین پارامترهای برای انتخاب کنترل‌کننده بهتر



شکل ۹. ماشین خودران مقیاس کوچک از زوایای مختلف

Fig 9. Small scale unmanned vehicle used in this research (different perspectives)



شکل ۱۰. مسیر تعیین شده برای ماشین خودران

Fig 10. Our real testbed and the defined route for Small scale unmanned vehicle

کنترل کننده مسافت کمتری طی کند، میزان سوخت و انرژی کمتری برای طی نمودن مسیر نیاز دارد. به صورت تقریبی اعداد بدست آمده از محیط شبیه سازی در جدول ۶ آورده شده است. همانطور که مشاهده می شود کنترل کننده انتها- به- انتها با توجه به انحراف کمتر از مرکز جاده مسافت کمتری را نسبت به دیگر کنترل کننده ها طی می کند.

#### ۵- پیکربندی سیستم شبیه سازی

برای انجام آزمایش های این مقاله از محیط شبیه سازی متن باز مبتنی بر موتور بازی سازی یونیتی استفاده شده است. برای پیاده سازی کنترل کننده ها از زبان برنامه نویسی پایتون استفاده شده است. ساختار کنترل کننده انتها- به- انتها با استفاده از محیط تنسورفلو پیاده سازی و در کد اصلی به زبان پایتون مورد استفاده قرار

دنبال کردن جاده، ملاک ایمن بودن رفتار کنترل کننده میزان فاصله از خطوط کنار جاده تعریف می شود. در آزمایش های انجام شده، خودرو تحت کنترل، در صورت استفاده از کنترل کننده های تناسبی- انتگرال- مشتقگیر و کنترل پیشبین مدل خطوط کناری جاده را در پیچ های تند قطع می کند در حالیکه در کنترل کننده انتها- به- انتها فاصله ایمن از خطوط کناری جاده را حفظ می کند.

#### ۴-۹- مسافت

از آنجائیکه مسافت جاده ای که خودرو در محیط شبیه سازی می بایست طی کند برای هر سه کنترل کننده ثابت است، می توان میزان مسافتی که کیلومتر شمار خودرو نمایش می دهد را برای مقایسه کارآمدی کنترل کننده استفاده نمود. چرا که هر چقدر



جدول ۸. وضعیت رانندگی کنترل کننده ETE

Table 8. Driving status of ETE controlle

سرعت (m/s)	زمان طی ۱ دور مسیر (ثانیه)	تماس با خطوط کناری	خارج شدن از خطوط کناری	خارج شدن از مسیر
۰/۴۶	۲۸	۵	۲	۱
۰/۳۹	۳۳	۳	۱	۰
۰/۲۹	۴۴	۲	۰	۰
۰/۲۱	۶۱	۱	۰	۰

نتایج به دست آمده از این آزمایش نشان می دهد که کنترل کننده انتها- به- انتها قابلیت یادگیری رانندگی انسان و رانندگی بدون دخالت انسان را داراست. سیکل زمانی حلقه کنترل در روش استفاده شده به طور میانگین ۴۰ میلی ثانیه است. این زمان شامل دریافت تصاویر از دوربین، اجرای شبکه عصبی عمیق کنترلی بر روی برد پردازشی و ارسال دستورها به راه انداز موتور هاست. برای بررسی عملکرد انتها- به- انتها طی اجراهای مختلف پارامترهای تماس با خطوط کناری مسیر تعیین شده که در شکل ۱۰ مشخص است، خارج شدن از خطوط کناری و همچنین خارج شدن از مسیر (در این حالت با کنترل دستی ماشین به مسیر بازگردانده می شود) در سعی های مختلف مورد بررسی قرار گرفته است. جدول ۸ وضعیت کلی رانندگی کنترل کننده انتها- به- انتها را در ۲ بار طی شدن مسیر نشان می دهد. براساس این نتایج عملکرد کنترلی کنترل کننده انتها- به- انتها با کاهش سرعت بهبود می یابد. دلیل این امر ایده آل نبودن سیستم مکانیکی ماشین و لغزندگی و همچنین نویز و اعوجاج بیشتر تصاویر دوربین در سرعت های بالاتر است. پیوند [۲۳] حاوی فیلم حرکت این ماشین است.

۷- نتیجه گیری و جمع بندی

در این مقاله سعی شد از نقطه نظرهای مختلف استفاده از شبکه های عصبی عمیق انتها- به- انتها در کنترل ماشین خودران با کنترل کننده های کلاسیک پر کاربرد تناسبی- انتگرال- مشتقگیر و کنترل پیشبین مدل مقایسه گردد. این مقایسه می تواند در انتخاب کنترل کننده مناسب توسط طراحان مورد استفاده قرار گیرد. اگر چه به طور کلی کنترل کننده کنترل پیشبین مدل رفتار بهتری به

گرفته است. سخت افزاری که کدها و محیط شبیه سازی بر روی آن اجرا شده است کامپیوتر رومیزی با مشخصات جدول ۷ است. لازم به ذکر است روش پیشنهادی بر روی کامپیوترهای با کارایی و قیمت پائین تر و حتی کامپیوترهای نهفته نیز قابلیت پیاده سازی و اجرا را دارد. اما ملاحظات زمان اجرا و حافظه مورد نیاز برای پارامترها، برای شبکه های بزرگتر از شبکه استفاده شده در این مقاله می بایست مورد توجه قرار بگیرد. کدهای پیاده سازی شده در این مقاله در [۲۲] قابل دسترسی است.

۶- پیاده سازی عملی

در راستای بررسی کارآمدی عملی روش انتها- به- انتها، این روش کنترلی بر روی ماشین خودران مقیاس کوچک ساخته شده در آزمایشگاه با ابعاد ۱۵در۱۵ سانتی متر، پیاده سازی و آزمایش شده است. همانطور که در شکل ۹ قابل مشاهده است، این ماشین خودران از اجزا ساده و کم هزینه شامل کفی، جعبه دنده و پیچ و مهره و موتور جریان مستقیم<sup>۱</sup> کوچک تشکیل شده است.

در شکل علاوه بر اجزای مکانیکی، اجزای سخت افزاری این بستر آزمایش که شامل برد پردازشی رزپبری پای ۲، دوربین، برد واسط، برد تغذیه و شارژ باتری و همچنین راه انداز موتور جریان مستقیم هستند، مشخص است. شبکه عصبی عمیق معرفی شده در شکل ۴، با استفاده از ابزار یادگیری عمیق تنسورفلو نسخه ۲ پیاده سازی، آموزش و اجرا شده است. لازم به ذکر است مراحل پیاده سازی و فاز آموزش بر روی کامپیوتر با مشخصات جدول ۷ و براساس روش بیان شده در شکل ۶ صورت پذیرفته، اما فاز اجرا بر روی برد پردازشی انجام شده است.

1 Direct Current (DC)

## مراجع

- [1] S.K. Khaitan, J.D. McCalley, Design techniques and applications of cyberphysical systems: A survey, *IEEE Systems Journal*, 365-350 (2014) (2)9.
- [2] M. Jirgl, Z. Bradac, P. Fiedler, Human-in-the-loop issue in context of the cyber-physical systems, *IFAC-PapersOnLine*, 230-225 (2018) (6)51.
- [3] I. Lenz, R.A. Knepper, A. Saxena, DeepMPC: Learning deep latent features for model predictive control, in: *Robotics: Science and Systems*, Rome, Italy, 2015.
- [4] Q. Zhu, T. Başar, Robust and resilient control design for cyber-physical systems with an application to power systems, in: *50 2011th IEEE Conference on Decision and Control and European Control Conference*, IEEE, 2011, pp. 4071-4066.
- [5] P.A. Ioannou, J. Sun, *Robust adaptive control*, Courier Corporation, 2012.
- [6] J.-X. Xu, Y. Tan, *Linear and nonlinear iterative learning control*, Springer, 2003.
- [7] S.M. Grigorescu, B. Trasnea, L. Marina, A. Vasilcoi, T. Cocias, Neurotrajectory: a neuroevolutionary approach to local state trajectory learning for autonomous vehicles, *IEEE Robotics and Automation Letters*, -3441 (2019) (4)4 3448.
- [8] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, F.E. Alsaadi, A survey of deep neural network architectures and their applications, *Neurocomputing*, 26-11 (2017) 234.
- [9] A. Zappone, M. Di Renzo, M. Debbah, Wireless networks design in the era of deep learning: Model-based, AI-based, or both?, *IEEE Transactions on Communications*, (10)67 7376-7331 (2019).
- [10] G.E. Hinton, S. Osindero, Y.-W. Teh, A fast learning algorithm for deep belief nets, *Neural computation*, (7)18 1554-1527 (2006).
- [11] N. O'Mahony, S. Campbell, A. Carvalho, S. Harapanahalli, G.V. Hernandez, L. Krpalkova, D. Riordan, J. Walsh, Deep learning vs. traditional computer vision, in: *Science and Information Conference*, Springer, 2019, pp. 144-128.
- [12] S. Levine, C. Finn, T. Darrell, P. Abbeel, End-to-end

نسبت کنترل کننده انتها- به- انتها از خود نشان می دهد اما پیچیدگی طراحی و پیاده سازی کنترل کننده های کنترل پیشبین مدل می تواند دلیل دیگری بر استقبال از کنترل کننده های انتها- به- انتها باشد. به علاوه وابستگی کنترل کننده کنترل پیشبین مدل به مدل دینامیکی دقیق از سیستم و همچنین وابستگی شدید عملکرد و همچنین بار محاسباتی این کنترل کننده به پارامترهای کنترل کننده چالش مهمی است که می بایست در نظر گرفته شود. دقت بالاتر و همچنین قابلیت یادگیری انتها- به- انتها یکی دیگر از عوامل محبوبیت این کنترل کننده ها است. این نکته حائز اهمیت است که با توجه همزمان به مقادیر واریانس شتاب، زاویه و سرعت خودرو برای ۳ کنترل کننده بررسی شده، می توان نتیجه گرفت که تلاش کنترلی کنترل پیشبین مدل بسیار بالاتر از بقیه است و کنترل کننده انتها- به- انتها با اختلاف بسیار در رتبه دوم قرار دارد.

در این مقاله با استفاده از محیط شبیه سازی، کنترل کننده انتها- به- انتها بر روی ماشین خودران بدون دراختیار داشتن مدل خودرو و همچنین محیط پیرامون با موفقیت و بدون خطا و خروج از خطوط کناری جاده آزمایش شده است. لازم به ذکر است در این مقاله از شبکه عصبی عمیق کانولوشنی به صورت مستقیم و از داده های تصویر دوربین به عنوان ورودی آن و بدون استفاده از هیچ ماجول دیگری برای کنترل خودرو استفاده شده است. این در حالیست که کنترلر کنترل پیشبین مدل به سنسورهای سرعت، زاویه و همچنین الگوریتم تشخیص خط نیز نیازمند است.

از آنجائیکه برای مقایسه از الگوریتم های پایه هر سه کنترل کننده استفاده شده است در کارهای آتی قصد داریم تا از الگوریتم های بهینه سازی شده کنترل کننده تناسبی- انتگرال- مشتقگیر و کنترل پیشبین مدل و همچنین ساختارهای دیگر شبکه عصبی عمیق مانند حافظه طولانی کوتاه- مدت<sup>۱</sup> و ماجول های کمکی دیگر و روش های پیاده سازی سخت افزاری بهینه که می تواند در بهبود عملکرد این کنترل کننده ها تاثیر بسزایی داشته باشد استفاده و مقایسه نمائیم. رویکرد دیگر برای کارهای آتی استفاده از روش های ترکیبی برای بهره گرفتن از نقاط قوت کنترل کننده کنترل پیشبین مدل در کنار کنترل کننده انتها- به- انتها است.

1 Long Short-Term Memory (LSTM)

- visualizing cnns for autonomous driving, arXiv preprint arXiv:2016) 2 ,1611.05418).
- [18] M. Bojarski, D. Del Testa, D. Dworakowski, B. Firner, B. Flepp, P. Goyal, L.D. Jackel, M. Monfort, U. Muller, J. Zhang, End to end learning for self-driving cars, arXiv preprint arXiv:2016) ,1604.07316).
- [19] Udacity, Public driving dataset, in, <https://www.udacity.com/self-driving-car>, 2020.
- [20] J. Kong, M. Pfeiffer, G. Schildbach, F. Borrelli, Kinematic and dynamic vehicle models for autonomous driving control design, in: 2015 IEEE Intelligent Vehicles Symposium (IV), IEEE, 2015, pp. 1099-1094.
- [21] Z. Wu, Y. Liu, G. Pan, A smart car control model for brake comfort based on car following, IEEE transactions on intelligent transportation systems, 46-42 (2008) (1)10.
- [22] A. Mohammadi, Code repository, in, Github, <https://github.com/abbasmohammadi/ETE>, 2020.
- [23] A. Mohammadi, Short video of our self-driving car, in, [https://b2n.ir/2019\\_738589](https://b2n.ir/2019_738589).
- training of deep visuomotor policies, The Journal of Machine Learning Research, 1373-1334 (2016) (1)17.
- [13] R. Raina, A. Madhavan, A.Y. Ng, Large-scale deep unsupervised learning using graphics processors, in: Proceedings of the 26th annual international conference on machine learning, 2009, pp. 880-873.
- [14] D.A. Pomerleau, Alvin: An autonomous land vehicle in a neural network, in: Advances in neural information processing systems, 1989, pp. 313-305.
- [15] U. Muller, J. Ben, E. Cosatto, B. Flepp, Y.L. Cun, Off-road obstacle avoidance through end-to-end learning, in: Advances in neural information processing systems, 2006, pp. 746-739.
- [16] M. Bojarski, A. Choromanska, K. Choromanski, B. Firner, L. Jackel, U. Muller, K. Zieba, Visualbackprop: efficient visualization of cnns, arXiv preprint arXiv:1611.05418 (2016)).
- [17] M. Bojarski, A. Choromanska, K. Choromanski, B. Firner, L. Jackel, U. Muller, K. Zieba, Visualbackprop:

چگونه به این مقاله ارجاع دهیم

A. Mohammadi, K. Jamshidi, H. Shahbazi, M. Rezaei, A comparison study of deep neural controllers and classic controllers in self-driving car application, *AmirKabir J. Mech. Eng.*, 53(Special Issue 4) (2021) 2439-2458.

DOI: [10.22060/mej.2020.18008.6708](https://doi.org/10.22060/mej.2020.18008.6708)



