

Intelligent vehicle velocity forecasting based on the real highway data

Mostafa Khanalipour, Mohsen Mohammadi*, Hossein Mohammadi

School of Mechanical Engineering, Shiraz University, Shiraz, Iran

ABSTRACT

Accurate vehicle velocity forecasting reduces energy consumption and improves the safety of intelligent vehicles. Considering the available data in intelligent transportation systems and the capability of deep neural networks to exploit these data, an intelligent velocity forecasting method based on deep neural networks is proposed. Velocity forecasting is performed using the velocity history of the target vehicle and its preceding vehicles. To enhance forecasting accuracy, a novel normalization method for vehicle velocity data is introduced, which leads to a reduction in prediction error. Furthermore, to address practical driving challenges, uncertainty in the available length of velocity history and the number of preceding vehicles is incorporated into the proposed method. In this study, velocity forecasting is conducted with a very short time step, which is more challenging and has not been reported in previous studies. The velocity forecasting models are trained using real-world highway data. The results demonstrate that the proposed method achieves higher accuracy, particularly in the initial time steps, and is free of offset. Moreover, unlike existing studies, velocity forecasting remains feasible even in the absence of a preceding vehicle, and the prediction accuracy under this condition exceeds that of conventional analytical methods. The mean absolute prediction error over a six-second horizon using the proposed method is 0.2410 m/s, representing the prediction error reduction of at least a 29.30% compared to analytical models and at least 13.18% compared to cases without the proposed normalization.

KEYWORDS

Vehicle velocity forecasting, Machine learning, Data normalization, Connected automated vehicles, Deep learning

* Corresponding Author: Email: mohsen_mohammadi@shirazu.ac.ir

1. Introduction

Vehicle velocity forecasting is a key component in connected automated vehicles, particularly for energy management [1] and predictive cruise control [2]. In car-following scenarios, accurately predicting the preceding vehicle's velocity is critical, as it directly influences the follower's behavior and energy consumption [3].

Existing methods include analytical, statistical, and data-driven approaches. Analytical methods such as constant velocity and acceleration perform well short term but degrade over longer horizons. Data-driven approaches, including deep neural networks (DNN) [4, 5], long short-term memory (LSTM) networks [4] and gated recurrent unit (GRU) [6], generally achieve better performance.

Despite progress, velocity forecasting remains challenging due to high uncertainty, especially with short time steps that require capturing small variations over long horizons. Incorporating information from preceding vehicles can improve accuracy. [4, 6].

This study proposes a velocity forecasting method using the velocity history of a target vehicle and up to four preceding vehicles, explicitly accounting for uncertainty. Unlike typical data-driven methods with large time steps and short horizons, the proposed approach uses a 6-second horizon with a 0.04-second step and introduces a tailored normalization method. Combined with an appropriate model, this approach outperforms existing methods.

2. Dataset description and Data preparation

The highD dataset [7], a large-scale highway vehicle trajectory dataset, is used in this study.

It is assumed that preceding vehicle data are available via V2V communication. Velocity histories of the target vehicle and up to four preceding vehicles over a 10-second interval are extracted. Using a 1-second sliding window, a dataset of 21,969 samples from 2,564 vehicles is generated, with a time step of 0.04 seconds.

A new normalization method, called special normalization, is proposed to better match the problem characteristics and improve forecasting accuracy. In this approach, the target variable (future velocity) is expressed as a relative velocity with respect to the latest velocity of the target vehicle, while input velocity histories remain unchanged. The normalized target data are computed using Equation (1).

$$\bar{v}_{T,k+i} = v_{T,k+i} - v_{T,k}, \quad (i = 0, 1, \dots, n) \quad (1)$$

Where $\bar{v}_{T,k+i}$ and $v_{T,k+i}$ are the normalized and raw velocity of the target vehicle at time step $k+i$ and n is number of time steps.

3. Velocity forecasting models

In this study, three data-driven approaches, deep neural networks (DNN), long short-term memory (LSTM) networks, and gated recurrent units (GRU), are employed for velocity forecasting. In addition, constant velocity, constant acceleration, and exponential decay acceleration models are considered as baseline analytical methods.

The performance of the forecasting models is evaluated using the mean absolute error (MAE), while the training loss is defined based on the mean squared error (MSE).

4. Results and Discussion

In this study, the three data-driven models are trained on two datasets. The first is the dataset processed using the special normalization method, and the second is the raw velocity dataset without any normalization. In addition, the three analytical methods mentioned are used as baseline comparisons. The dataset is split into training, validation, and test sets, comprising 60%, 10%, and 20% of the data, respectively, with minimal overlap between the sets. After training all models with appropriately tuned hyperparameters, the performance of all models is evaluated on the test set.

As shown in Table 1, the velocity forecasting model based on gated recurrent units (GRU) trained on the normalized dataset achieves the lowest error in both the 6- and 2-second horizons. In the 6-second horizon, the forecasting error of the GRU model compared to constant velocity, constant acceleration, and variable acceleration models is reduced by 58.12%, 33.18%, and 24.30%, respectively. Furthermore, the GRU model trained on normalized data achieves 13.18% lower error than the long short-term memory (LSTM) model trained on raw data, which is the best-performing model among those trained on raw data.

Although models trained on raw data show comparable performance to those trained on normalized data in terms of average error, their performance degrades in the short term, particularly during the initial time steps. As shown in Table 1, models trained on raw data can exhibit significantly higher errors in the first step or the first few steps. It is evident that this early-stage error behavior is a key limitation of models trained without normalization.

Table 1. Mean absolute error of velocity forecasting in 6 and 2 seconds and maximum forecasting error of first step on the entire test dataset.

Model	Prediction in six second	Prediction in two second	Maximum error in first step	Mean absolute error in first step
LSTM	0.2499	0.0613	0.0434	0.0043
LSTM-Raw	0.2776	0.1309	1.5794	0.1212
GRU	0.2410	0.0578	0.0336	0.0044
GRU-Raw	0.2970	0.1624	1.5127	0.1817
DNN	0.3240	0.1311	0.0642	0.0073
DNN-Raw	0.3686	0.1793	1.4332	0.1420
CV	0.5761	0.1931	0.0900	0.0080
CA	0.3641	0.0603	0.0120	0.0036
EDA	0.3409	0.591	0.0120	0.0036

Figure 1 shows velocity forecasting results for different models. Data-driven models capture trends more accurately than analytical methods. Models trained on raw data exhibit a noticeable offset (Figure 1a), while those trained on normalized data achieve higher accuracy in both short- and long-term predictions.




Figure 1. Velocity forecasting plot of six trained models and constant velocity, constant acceleration and exponential decay acceleration methods in: (a) low velocity scenario, (b) high speed scenario.

5. Conclusions

In this study, multiple deep learning models are evaluated using both normalized and raw datasets for highway vehicle velocity forecasting. A prediction model based on the velocity history of the target and its preceding vehicles is proposed.

Velocity data are first processed using the proposed normalization method, and models are trained with a 0.04-second time step. The combination of special

normalization, suitable neural networks, and preceding vehicle information significantly improves accuracy. Models trained on normalized data outperform those using raw data, showing minimal initial offset and lower prediction error. Additionally, the approach remains effective even without full preceding vehicle history and is robust to variations in the number of preceding vehicle inputs.

The gated recurrent unit (GRU) was the best-performing model among the tested methods and achieved the lowest forecasting error. The mean absolute error of its predictions in the 6-second and 2-second horizons is 0.2410 m/s and 0.0578 m/s, respectively. The prediction error in the 6-second horizon is reduced by 58.12%, 33.18%, and 24.30% compared to constant velocity, constant acceleration, and variable acceleration models, respectively. The forecasting error is also 13.18% lower than that of models trained on raw data.

6. References

- [1] X. Li, W. Lin, Y. Jin, D. Chen, T. chen, Dynamic Energy Management Strategy of Hybrid Electric Vehicles based on Velocity Prediction, *IFAC-PapersOnLine*, 54(10) (2021) 363–369.
- [2] B. Li, W. Zhuang, B. Chen, H. Zhang, S. Yu, J. Zhang, G. Yin, Predictive Ecological Cooperative Control of Electric Vehicles Platoon on Hilly Roads, *Chin. J. Mech. Eng.*, 38(1) (2025) 37.
- [3] E. Hyeon, Y. Kim, N. Prakash, A.G. Stefanopoulou, Influence of Speed Forecasting on the Performance of Ecological Adaptive Cruise Control, in: *ASME 2019 Dynamic Systems and Control Conference*, American Society of Mechanical Engineers Digital Collection, 2019.
- [4] M. Wegener, F. Herrmann, L. Koch, R. Savelsberg, J. Andert, Longitudinal Vehicle Motion Prediction in Urban Settings With Traffic Light Interaction, *IEEE Transactions on Intelligent Vehicles*, 8(1) (2023) 204–215.
- [5] C. Pan, Y. Li, J. Wang, J. Liang, H. Jinyama, Research on multi-lane energy-saving driving strategy of connected electric vehicle based on vehicle speed prediction, *Green Energy and Intelligent Transportation*, 2(6) (2023) 100127.
- [6] S.K. Chada, D. Görges, A. Ebert, R. Teutsch, Deep Learning-Based Vehicle Speed Prediction for Ecological Adaptive Cruise Control in Urban and Highway Scenarios, *IFAC-PapersOnLine*, 56(2) (2023) 1107–1114.
- [7] R. Krajewski, J. Bock, L. Kloeker, L. Eckstein, The highD Dataset: A Drone Dataset of Naturalistic Vehicle Trajectories on German Highways for Validation of Highly Automated Driving Systems, in: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, pp. 2118–2125.

پیش‌بینی هوشمند سرعت خودرو بر اساس مجموعه داده واقعی بزرگراه

مصطفی خانعلی پور، محسن محمدی*، حسین محمدی

دانشکده مهندسی مکانیک، دانشگاه شیراز، شیراز، ایران

* آدرس پست الکترونیک نویسنده مسئول: mohsen_mohammadi@shirazu.ac.ir

چکیده

پیش‌بینی دقیق سرعت خودرو موجب کاهش مصرف انرژی و افزایش ایمنی خودروهای هوشمند می‌شود. با توجه به داده‌های موجود در سیستم‌های حمل و نقل هوشمند و ظرفیت شبکه‌های عصبی عمیق در بهره برداری از این داده‌ها، یک روش هوشمند برای پیش‌بینی سرعت با استفاده از شبکه‌های عصبی عمیق ارائه شده است. پیش‌بینی سرعت با استفاده از سابقه سرعت خودروی هدف و خودروهای جلویی آن انجام می‌شود. به منظور افزایش دقت پیش‌بینی، یک روش نوآورانه برای نرمال‌سازی داده‌های سرعت خودرو معرفی شده است که منجر به کاهش خطای پیش‌بینی می‌شود. علاوه بر این، برای مواجهه با چالش‌هایی که در عمل برای رانندگی وجود دارد، عدم قطعیت در میزان سابقه سرعت در دسترس و تعداد خودروهای جلویی در روش توسعه یافته لحاظ شده است. در این پژوهش، پیش‌بینی سرعت با گام زمانی بسیار کوتاه، که در مطالعات پیشین گزارش نشده و چالش برانگیزتر است، انجام شده است. برای آموزش مدل‌های پیش‌بین سرعت هوشمند از داده‌های واقعی بزرگراه استفاده شده است. نتایج نشان می‌دهد که روش پیشنهادی، به‌ویژه در گام‌های زمانی اولیه، دقت بالاتری داشته دارد و فاقد آفست است. همچنین، برخلاف تحقیقات موجود، حتی در صورت عدم وجود خودروی جلویی نیز امکان پیش‌بینی سرعت وجود دارد و دقت پیش‌بینی در این شرایط از روش‌های تحلیلی رایج بیشتر است. میانگین خطای مطلق پیش‌بینی در افق شش ثانیه‌ای با روش پیشنهادی برابر با 0.2410 متر بر ثانیه است که نسبت به مدل‌های تحلیلی حداقل $29/30$ درصد و نسبت به حالتی که از روش نرمال‌سازی ارائه شده استفاده نشده است حداقل $13/18$ درصد کاهش نشان می‌دهد.

کلمات کلیدی

پیش‌بینی سرعت خودرو، یادگیری ماشین، نرمال‌سازی داده، خودروهای هوشمند متصل، یادگیری عمیق

پیش‌بینی سرعت خودرو یکی از مؤلفه‌های کلیدی در توسعه خودروهای هوشمند و خودکار به شمار می‌رود و نقش مهمی در بهبود عملکرد الگوریتم‌های کنترلی و بهینه‌سازی مصرف انرژی دارد. این موضوع به‌ویژه در خودروهای برقی و هیبریدی، در کاربردهایی مانند مدیریت انرژی [۱، ۲] و کروزر کنترل پیش‌بین [۳، ۴] از اهمیت بالایی برخوردار است. دلیل این اهمیت آن است که آگاهی از روند تغییرات آینده سرعت، امکان برنامه‌ریزی نرم‌تر و کارآمدتر سیستم‌های کنترلی را فراهم کرده و در نهایت منجر به کاهش مصرف انرژی می‌شود. با پیشرفت فناوری خودروهای متصل و خودکار، پیاده‌سازی راهکارهای کنترلی مبتنی بر پیش‌بینی بیش از گذشته امکان‌پذیر شده و چشم‌اندازهای نوینی برای ارتقای بهره‌وری انرژی خودروها فراهم شده است [۵].

در این میان، پیش‌بینی سرعت خودروی جلویی در سناریوهای دنبال کردن خودرو اهمیت دوچندانی دارد، زیرا رفتار حرکتی خودروی دنبال‌کننده به‌طور مستقیم تحت تأثیر تغییرات سرعت خودروی پیش‌رو قرار می‌گیرد. هرچند سرعت لحظه‌ای خودروی جلویی با استفاده از حسگرهای سامانه‌های کمک‌راننده قابل اندازه‌گیری است، اما سرعت‌های آینده آن قابل مشاهده نیستند و باید از طریق الگوریتم‌های پیش‌بینی تخمین زده شوند. پیش‌بینی سرعت می‌تواند در سیستم مدیریت انرژی ادغام شود تا مصرف انرژی را کاهش دهد، یا با ادغام در سیستم جلوگیری از برخورد، ایمنی رانندگی را بیشتر کند. میزان کاهش مصرف انرژی به‌طور مستقیم به دقت و صحت سرعت پیش‌بینی شده بستگی دارد [۶].

داده سرعت خودرو برای سناریو و مکان‌های متفاوت به فراوانی وجود ندارد و این می‌تواند یک محدودیت در توسعه مدل‌های پیش‌بین سرعت داده محور باشد. برای حل این چالش می‌توان از روش یادگیری انتقالی استفاده کرد و از مدل‌های آموزش داده شده روی یک مجموعه داده بزرگ برای ایجاد مدل‌های پیش‌بین سرعت روی مجموعه داده دلخواه محدود استفاده کرد [۷].

علاوه بر این، توسعه زیرساخت‌های ارتباطی نظیر ارتباط خودرو با خودرو و ارتباط خودرو با زیرساخت، بستر مناسبی برای بهبود دقت پیش‌بینی فراهم کرده است. تبادل اطلاعاتی مانند موقعیت، سرعت و جهت حرکت خودروها از طریق پیام‌های ایمنی پایه، و همچنین دسترسی به اطلاعات فاز و زمان‌بندی چراغ‌های راهنمایی در تقاطع‌ها، امکان تصمیم‌گیری هوشمندانه‌تر و مدیریت بهینه انرژی را در سامانه‌های رانندگی خودکار فراهم می‌سازد [۸]. با توجه به نقش محوری سرعت به‌عنوان یکی از مهم‌ترین متغیرهای توصیف‌کننده وضعیت حرکت خودرو، توسعه روش‌های قابل اعتماد و دقیق برای پیش‌بینی سرعت خودرو، به‌عنوان یکی از پیش‌نیازهای اساسی سامانه‌های هوشمند حمل‌ونقل، ضروری بوده و می‌تواند به بهبود هم‌زمان ایمنی، راحتی حرکت و بهره‌وری انرژی منجر شود.

در ادبیات پژوهش، روش‌های متعددی برای پیش‌بینی سرعت خودرو ارائه شده است. روش سرعت ثابت و روش شتاب ثابت دو رویکرد رایج برای پیش‌بینی سرعت خودرو است [۹]. در روش شتاب ثابت، فرض می‌شود که خودرو حرکت خود را با شتاب فعلی و به‌صورت ثابت ادامه می‌دهد، در حالی که در روش سرعت ثابت، فرض بر این است که خودرو سرعت فعلی خود را در آینده حفظ می‌کند. این دو روش عمدتاً در کاربردهای پیش‌بینی برخورد مورد استفاده قرار می‌گیرند [۱۰]. هرچند این روش‌ها در پیش‌بینی کوتاه‌مدت عملکرد قابل قبولی دارند، در بازه‌های زمانی بلندمدت نسبت به روش‌های داده‌محور با خطای بیشتری همراه هستند. روش‌های داده محور شامل روش‌های آماری و روش‌های یادگیری ماشین می‌شود. از جمله روش‌های آماری به‌کاررفته برای پیش‌بینی سرعت خودرو می‌توان به روش زنجیره مارکوف [۱۱، ۱۲]، گاوس خطی شرطی^۱ [۱۱، ۱۳] و رگرسیون چند جمله‌ای [۱۴-۱۶] اشاره کرد. در صورت استفاده از تاریخچه سرعت خودرو، مسئله پیش‌بینی سرعت را می‌توان به‌عنوان یک مسئله پیش‌بینی سری زمانی در نظر گرفت. در این زمینه، روش‌های ARIMA^۲ [۱۷] و NARX^۳ [۱۱، ۱۸] از جمله روش‌های رایج برای پیش‌بینی سرعت بر اساس سابقه حرکتی خودرو هستند. استفاده از روش‌های یادگیری ماشین برای پیش‌بینی سرعت خودرو نیز به‌طور گسترده‌ای مورد توجه قرار گرفته است. از روش‌های متداول در این حوزه می‌توان به شبکه عصبی عمیق^۴ [۱۳، ۱۹]، حافظه کوتاه بلند مدت^۵ [۱۳، ۲۰]، واحد بازگشتی دروازه‌ای^۶

¹ Conditional Linear Gauss (CLG)

² Autoregressive integrated moving average (ARIMA)

³ Nonlinear autoregressive exogenous model (NARX)

⁴ Deep neural network (DNN)

⁵ Long short-term memory (LSTM)

⁶ Gated recurrent unit (GRU)

[۲۱, ۲۲] اشاره کرد. به طور کلی، مدل‌های بازگشتی به دلیل وجود سازوکار حافظه در ساختار خود، در پیش‌بینی‌های بلندمدت عملکرد بهتری از خود نشان می‌دهند.

در ادبیات پژوهش مدل‌های پیش‌بینی سرعت برای هر دو سناریوی رانندگی شهری و بزرگراه مورد بررسی قرار گرفته‌اند. با این حال، در اغلب مطالعات، پیش‌بینی سرعت بر اساس یک سیکل رانندگی شهری انجام شده و تنها اطلاعات مربوط به اولین خودروی جلویی مورد استفاده قرار گرفته است. این در حالی است که نتایج برخی پژوهش‌ها نشان می‌دهد در نظر گرفتن اطلاعات چند خودروی جلویی می‌تواند دقت پیش‌بینی را به طور قابل توجهی افزایش دهد [۱۳, ۲۱].

در پیش‌بینی کوتاه‌مدت سرعت، معمولاً افق پیش‌بینی ثابت و کوتاه در نظر گرفته می‌شود، اما این افق می‌تواند با انتخاب گام‌های زمانی کوتاه به تعداد زیادی گام پیش‌بینی تقسیم شود. در برخی مطالعات، برای ساده‌سازی مسئله، از گام‌های زمانی بزرگ‌تر استفاده می‌شود که منجر به کاهش تعداد گام‌های پیش‌بینی می‌گردد. اگرچه این رویکرد پیچیدگی مدل را کاهش می‌دهد، اما مستلزم درونیابی سرعت‌های میانی بوده و می‌تواند باعث افزایش خطای کلی و کاهش دقت پیش‌بینی شود.

ژنگ^۱ و همکاران [۲۳] از شبکه‌های عصبی زنجیره‌ای^۲ برای پیش‌بینی سرعت خودرو با هدف مدیریت مصرف انرژی استفاده کردند. در این پژوهش، آموزش و ارزیابی مدل بر اساس داده‌های یک سیکل رانندگی انجام شد و گام زمانی پیش‌بینی یک ثانیه در نظر گرفته شد. دقت پیش‌بینی برای افق‌های زمانی یک تا ۲۰ گام بررسی و عملکرد روش پیشنهادی نسبت به یک شبکه عصبی پیشخور ساده بهبود یافته گزارش شد.

چادا^۳ و همکاران [۲۱] با استفاده از شبکه حافظه کوتاه بلند مدت، سرعت خودرو را برای افق‌های ۵ و ۱۰ ثانیه آینده پیش‌بینی کردند. داده‌های آموزشی این مدل از شبیه‌سازی به دست آمده و گام زمانی پیش‌بینی برابر با ۰/۲ ثانیه بوده است. میانگین قدر مطلق خطای پیش‌بینی برای افق‌های ۵ و ۱۰ ثانیه به ترتیب ۱/۷۵ و ۲/۹۲ گزارش شده است. با این حال، برای رانندگی واقعی در بزرگراه، این میزان خطا نسبتاً بالا تلقی می‌شود، چراکه تغییرات سرعت در بازه‌های زمانی کوتاه معمولاً شدید نیست. همچنین در این پژوهش نشان داده شد که در نظر گرفتن داده‌های مربوط به چند خودروی جلویی موجب افزایش دقت مدل می‌شود.

اهمیت پیش‌بینی دقیق سرعت در افق‌های زمانی نزدیک بیش از افق‌های دور است، چراکه تأثیر مستقیم‌تری بر عملکرد الگوریتم‌های کنترلی و مصرف انرژی دارد [۲۴]. ونگ^۴ و همکاران [۲۰] از شبکه حافظه کوتاه بلند مدت برای پیش‌بینی سرعت یک ثانیه آینده با استفاده از سابقه سرعت و موقعیت خودرو بهره گرفتند. اگرچه تعداد گام‌های پیش‌بینی در این کار ۲۵ در نظر گرفته شده است، بر اساس نتایج گزارش شده، حتی در پیش‌بینی یک ثانیه آینده نیز سرعت پیش‌بینی شده دارای نوعی آفست بوده و در گام‌های ابتدایی دقت مطلوبی مشاهده نمی‌شود.

وگنر^۵ و همکاران [۱۳] با استفاده از مدل گاوس خطی شرطی و دو نوع شبکه عصبی عمیق، پیش‌بینی سرعت خودرو را در محیط شهری بررسی کردند. در این پژوهش، اطلاعاتی نظیر سابقه سرعت خودروهای جلویی، فاصله نسبی و وضعیت چراغ راهنمایی به عنوان داده‌های ورودی مورد استفاده قرار گرفت. نتایج نشان داد که مدل حافظه کوتاه بلند مدت نسبت به سایر روش‌ها دقت بالاتری دارد و افزودن اطلاعات مربوط به دو خودروی جلویی موجب بهبود بیشتر عملکرد پیش‌بینی می‌شود.

با وجود پیشرفت‌های قابل توجه، پیش‌بینی سرعت خودرو همچنان با عدم قطعیت بالایی همراه بوده و یک مسئله چالش‌برانگیز محسوب می‌شود. این چالش به‌ویژه در شرایطی که گام زمانی بسیار کوتاه و تعداد گام‌های پیش‌بینی زیاد باشد، تشدید می‌شود. در اغلب مطالعات موجود، پیش‌بینی برای افق‌های زمانی چند ثانیه‌ای با گام‌های زمانی نسبتاً بزرگ انجام شده است، در حالی که افزایش تعداد گام‌ها همراه با کاهش گام زمانی، دشواری مسئله را به طور چشمگیری افزایش می‌دهد. از سوی دیگر، در ادبیات پژوهش به ندرت از سابقه طولانی سرعت خودرو که در شبکه خودرو به خودرو به صورت بالقوه در دسترس است، استفاده شده است. یکی از دلایل این امر، عدم تضمین در دسترس بودن همیشگی این داده‌ها است.

¹ Zhang

² Chaining neural network

³ Chada

⁴ Wang

⁵ Wegener

در این پژوهش، پیش‌بینی سرعت خودروی هدف با استفاده از داده‌های سابقه سرعت خود و چهار خودروی جلویی آن که از ارتباط خودرو به خودرو بدست می‌آید انجام می‌شود. در روش ارائه شده عدم قطعیت در در میزان سابقه سرعت در دسترس و تعداد خودرو جلویی در نظر گرفته شده است.

استفاده از گام زمانی کوتاه باعث افزایش تعداد نقاط پیش‌بینی و کاهش فاصله بین آنها می‌شود و در این حالت پیش‌بینی هر گام زمانی باید دقیق‌تر باشد. با وجود اینکه در این حالت می‌توان پیش‌بینی سرعت دقیق‌تری داشت ولی باید فیزیک مسئله به نوعی در پیش‌بینی سرعت آینده خودرو افزوده شود. در عمل سرعت آینده خودرو تغییرات شدید و غیرواقعی ندارد و خودرو با شتاب نسبتاً کمی حرکت می‌کند. در روش‌های پیش‌بینی سرعت گزارش شده در ادبیات این موضوع بررسی نشده است و به همین دلیل با کاهش گام زمانی، خطای پیش‌بینی کم نمی‌شود و برای داشتن پیش‌بینی قابل قبول با روش‌های داده محور باید گام زمانی زیاد باشد. در این کار برای نشان داده این چالش و حل آن، مسئله پیش‌بینی سرعت خودرو در بزرگراه با استفاده از گام زمانی بسیار کوتاه مورد بررسی قرار می‌گیرد، به طوری که سرعت خودرو برای افق ۶ ثانیه آینده با گام زمانی ۰/۰۴ ثانیه پیش‌بینی می‌شود. استفاده از این گام زمانی برای پیش‌بینی چند ثانیه سرعت خودرو با روش‌های داده محور در پژوهش‌های گذشته مشاهده نشده است. اگرچه روش‌های نرمال‌سازی متداول در مطالعات پیشین نتایج قابل قبولی ارائه کرده‌اند، اما در شرایطی که گام زمانی پیش‌بینی کوتاه و تغییرات سرعت در هر گام اندک باشد، مانند رانندگی در بزرگراه، این روش‌ها با محدودیت‌هایی مواجه می‌شوند. از این رو، در این پژوهش یک روش نرمال‌سازی جدید متناسب با مسئله پیش‌بینی سرعت خودرو، که نوعی روش تبدیل داده است، ارائه می‌شود و این نرمال‌سازی ویژه باعث افزایش دقت پیش‌بینی سرعت می‌شود.

ساختار این مقاله به شرح زیر است. در فصل ۲، نحوه آماده‌سازی، پردازش و نرمال‌سازی داده‌ها تشریح می‌شود. در فصل ۳، الگوریتم‌های پیشنهادی برای پیش‌بینی سرعت معرفی می‌گردند. در فصل ۴، فرآیند آموزش شبکه‌ها و ارزیابی عملکرد آن‌ها ارائه و تحلیل می‌شود. در نهایت، فصل ۵ به جمع‌بندی نتایج و نتیجه‌گیری اختصاص دارد.

۲- توصیف مجموعه داده

در این کار از روش‌های پیش‌بینی سرعت داده محور استفاده شده است. در نتیجه برای پیش‌بینی سرعت خودرو با استفاده از مدل‌های هوشمند داده محور نیاز به داده مناسب داریم. در این پژوهش از مجموعه داده highD، که یک مجموعه داده واقعی است، برای توسعه و بررسی روش پیشنهادی استفاده شده است [۲۵]. در این بخش داده استفاده شده برای آموزش داده و آماده سازی آنها تشریح می‌شود. در ادامه نحوه پردازش و آماده‌سازی داده آورده شده است.

۲-۱- مجموعه داده

مجموعه داده highD یکی از شناخته‌شده‌ترین پایگاه‌های داده حرکتی خودروها است که در بزرگراه‌های آلمان ضبط شده و به منظور تحلیل رفتار ترافیکی و مطالعه مانورهای رانندگی با دقت بالا گردآوری شده است. این داده‌ها بر اساس فیلم‌برداری هوایی توسط کوادکوپتر در شش موقعیت مختلف در بزرگراه‌های اطراف شهر کلن طی سال‌های ۲۰۱۷ و ۲۰۱۸ ثبت شده‌اند. هر ضبط بخشی از مسیر به طول تقریبی ۴۲۰ متر را پوشش می‌دهد و در مجموع ۶۰ ضبط با میانگین مدت ۱۷ دقیقه انجام شده است که برابر با ۱۶/۵ ساعت داده خام است. ویدیوهای ثبت شده با استفاده از الگوریتم‌های پیشرفته بینایی ماشین پردازش شده‌اند تا مسیر حرکتی، نوع، ابعاد و مانورهای هر وسیله نقلیه استخراج شود. دقت موقعیت‌یابی کمتر از ۱۰ سانتی‌متر گزارش شده که این مجموعه داده را برای تحلیل‌های دقیق، مدل‌سازی رفتار راننده و کاربردهای مرتبط با سامانه‌های خودران مناسب می‌سازد.

خروجی پردازش این ویدیوها شامل مسیرهای پس‌پردازش‌شده‌ی حدود ۱۱۰ هزار وسیله نقلیه است که مجموعاً ۴۵ هزار کیلومتر پیمایش را پوشش می‌دهند. در این مجموعه داده، هر وسیله نقلیه به‌طور متوسط ۱۳/۶ ثانیه قابل مشاهده است و ۵۶۰۰ مانور تغییر خط کامل ثبت شده است. برای هر وسیله نقلیه اطلاعاتی مانند موقعیت، سرعت و شتاب با دقت بالا استخراج شده و زیرساخت‌های جاده‌ای نیز به صورت دستی حاشیه‌نویسی شده‌اند. این سطح از دقت و جامعیت باعث شده است که مجموعه داده highD به عنوان یک مرجع

معتبر در پژوهش‌های مربوط به تحلیل الگوهای ترافیک، مدل‌سازی رانندگی و توسعه محیط‌های شبیه‌سازی مورد استفاده قرار گیرد. در مطالعه حاضر نیز از داده سرعت این مجموعه برای ساخت مدل‌های پیش‌بین سرعت استفاده شده است.


۲-۲- آماده سازی داده

روش‌های پیش‌بینی سرعت ارائه شده بر اساس سابقه سرعت خودرو هدف و خودروهای جلویی آن سرعت خودرو هدف را پیش‌بینی می‌کنند. در این پژوهش فرض شده است که داده‌های خودروهای جلویی با ارتباط خودرو-به-خودرو برای هر خودرو در دسترس است. در این پژوهش، پیش‌بینی سرعت بر اساس سابقه سرعت خودرو هدف و حداکثر تا چهار خودرو جلویی است. در شکل ۱ سناریو در نظر گرفته شده برای پیش‌بینی سرعت خودرو نشان داده شده است. در سناریوهای واقعی رانندگی همیشه خودرو جلویی وجود ندارد. حتی در صورت وجود یک یا چند خودرو در جلوی خودرو هدف، ممکن است تاریخچه سرعت در دسترس کمتر از مقدار از پیش تعیین شده باشد. در توسعه مدل‌های پیش‌بین سرعت این عدم قطعیت‌ها در نظر گرفته شد. در واقع در آماده سازی داده‌های استفاده شده در این پژوهش این موارد در نظر گرفته شد. در پردازش این داده‌ها عدم قطعیت‌هایی مانند در دسترس نبودن یا کامل بودن سابقه سرعت خودرو جلویی و وجود نداشتن خودرو جلویی در نظر گرفته شده است. برای استخراج داده از مجموعه داده، سابقه سرعت خودرو هدف در ده ثانیه قبل و سابقه سرعت تا چهار خودرو جلویی موجود در ده ثانیه قبل برای پیش‌بینی سرعت خودرو هدف در شش ثانیه آینده در نظر گرفته شده است.

در استخراج داده‌ها از مجموعه داده highD قیدهای زیر در نظر گرفته شده است:

- سرعت خودروها از حداکثر سرعت مجاز بیشتر نباشد.
- خودروها کل مسیر را رانندگی کرده باشند.

پس از بدست آوردن داده خودروها از مجموعه داده، از روش پنجره لغزان^۱ با پنجره زمانی یک ثانیه برای ایجاد مجموعه داده سرعت خودروها استفاده شد. در واقع داده‌های استخراج شده از یک خودرو دارای نه ثانیه همپوشانی هستند. مجموعه داده سرعت بدست آمده شامل ۲۱۹۶۹ نمونه داده از ۲۵۶۴ خودرو است. داده موجود با فرکانس ۲۵ هرتز ثبت شده است. پس گام زمانی داده‌های در دسترس ۰/۰۴ ثانیه است. در این کار از داده با همین گام زمانی استفاده شده است.



شکل ۱: شماتیک وضعیت خودروها برای پیش‌بینی سرعت خودرو بر اساس سابقه سرعت خودرو هدف و خودروهای جلویی

Fig. 1. Schematic of the vehicles used for velocity forecasting, based on the velocity histories of the target vehicle and its preceding vehicles.

نرمال‌سازی داده‌ها برای آموزش الگوریتم‌های یادگیری عمیق رایج و در بسیاری از موارد ضروری است. نرمال‌سازی داده‌ها باعث می‌شود شبکه‌های یادگیری عمیق بدون توجه و مقیاس داده‌ها، رابطه بین ورودی و خروجی را تخمین بزنند. اگر داده‌ها در یک مقیاس باشند هم داشتن توزیع نرمال می‌تواند باعث بهبود فرایند آموزش و پیش‌بینی الگوریتم‌ها شود.

¹ Sliding window

در این پژوهش یک روش نرمال‌سازی جدید پیشنهاد شده است که با داده‌های موجود سازگاری بیشتری دارد و دقت پیش‌بینی الگوریتم را بیشتر می‌کند. این روش پیشنهادی در واقع یک نوع روش تبدیل داده است و در این مقاله روش نرمال‌سازی ویژه نامیده می‌شود. روش نرمال‌سازی ویژه به این صورت است که داده‌های هدف، که همان سرعت آینده خودرو هدف است، نسبت به آخرین سرعت خودرو هدف سنجیده می‌شوند. روش‌های رایج نرمال‌سازی مانند نرمال‌سازی کمینه-بیشینه و استانداردسازی روی داده‌ها اعمال شده است ولی هیچکدام نتیجه مطلوبی نداشتند و پیش‌بینی همیشه با آفست همراه است. روش پیشنهادی از سایر روش‌های نرمال‌سازی نتیجه بهتری دارد و سرعت خودرو بدون آفست پیش‌بینی می‌شود. سرعت آینده خودرو همیشه به صورت نسبی و نسبت به سرعت فعلی آن تغییر می‌کند و علاوه بر آن دارای پیوستگی است. به عبارت دیگر تغییرات شتاب و ناپیوستگی شدیدی در آن وجود ندارد. در نتیجه در مسئله پیش‌بینی سرعت خودرو، در واقع تغییرات سرعت را باید حول وضعیت قبلی آن، نه حول وضعیت صفر میانگین داده‌ها بررسی کنیم. این یعنی در این مسئله نقطه صفر در هر پیش‌بینی متمایز و برابر سرعت فعلی خودرو هدف است. از طرف دیگر در این روش فقط از سابقه سرعت برای پیش‌بینی سرعت آینده استفاده شده است و همه داده‌ها دارای یک مقیاس و واحد هستند. به هم دلیل بدون نرمال‌سازی داده و اعمال روش نرمال‌سازی ویژه نتیجه بهتری می‌گیریم. در روش نرمال‌سازی ویژه، سابقه سرعت به صورت مقدار واقعی در نظر گرفته می‌شوند ولی داده‌های هدف به صورت نسبی و نسبت به آخرین سرعت خودرو هدف در نظر گرفته می‌شوند. در روش نرمال‌سازی ویژه سرعت داده هدف به صورتی که در معادله (۱) آورده شده است محاسبه می‌شود.

$$\bar{v}_{T,k+i} = v_{T,k+i} - v_{T,k}, \quad (i = 0, 1, \dots, n) \quad (1)$$

که در آن $\bar{v}_{T,k+i}$ سرعت نرمال شده خودرو هدف در گام زمانی $k+i$ ، $v_{T,k+i}$ سرعت خودرو هدف در گام زمانی $k+i$ ، $v_{T,k}$ سرعت خودرو هدف در گام زمانی k و n تعداد گام‌های زمانی است.

این روش نرمال‌سازی ویژه نوآوری این مقاله است و داده‌های آموزش و هدف به صورتی که در معادله (۲) آورده شده است در نظر گرفته شده‌اند. داده ورودی مدل حافظه کوتاه بلند مدت و واحد دروازه‌ای بازگشتی در معادله (۲-الف) و داده‌های مدل شبکه عصبی عمیق در معادله (۲-ب) نشان داده شده است. داده هدف مدل‌هایی که روی داده نرمال‌سازی شده آموزش داده شده اند به صورت معادله (۲-ج) و برای مدل‌های دیگر به صورت معادله (۲-د) است.

$$\mathbf{X} = \begin{bmatrix} v_{T,1} & v_{T,2} & \dots & v_{T,k} \\ v_{1,1} & v_{1,2} & \dots & v_{1,k} \\ \vdots & & & \\ v_{4,1} & v_{4,2} & \dots & v_{4,k} \end{bmatrix} \quad (2\text{-الف})$$

$$\mathbf{X} = [v_{T,1} \quad \dots \quad v_{T,k} \quad v_{1,1} \quad \dots \quad v_{1,k} \quad \dots \quad \dots \quad v_{4,k}] \quad (2\text{-ب})$$

$$\mathbf{Y} = [\bar{v}_{T,k} \quad \bar{v}_{T,k+1} \quad \dots \quad \bar{v}_{T,k+n}] \quad (2\text{-ج})$$

$$\mathbf{Y} = [v_{T,k} \quad v_{T,k+1} \quad \dots \quad v_{T,k+n}] \quad (2\text{-د})$$

که در آن $v_{T,k}$ سرعت خودرو هدف در گام زمانی k و $v_{4,k}$ سرعت خودرو شماره ۴ در گام زمانی k است. شماره گذاری خودروها به ترتیبی است که در شکل ۱ مشاهده می‌شود.

۳- الگوریتم‌های پیش‌بینی کننده سرعت خودرو

روش‌های یادگیری عمیق توانایی خوبی در پیش‌بینی داده‌های سری زمانی دارند و به همین دلیل در این کار از این روش برای پیش‌بینی سرعت استفاده شده است. در این پژوهش سه روش شبکه عصبی مصنوعی عمیق، حافظه کوتاه طولانی مدت و واحد دروازه‌ای بازگشتی برای پیش‌بینی سرعت خودرو به کار گرفته شده است. این سه روش در ادامه شرح داده می‌شوند.

۳-۲-۱- شبکه عصبی عمیق

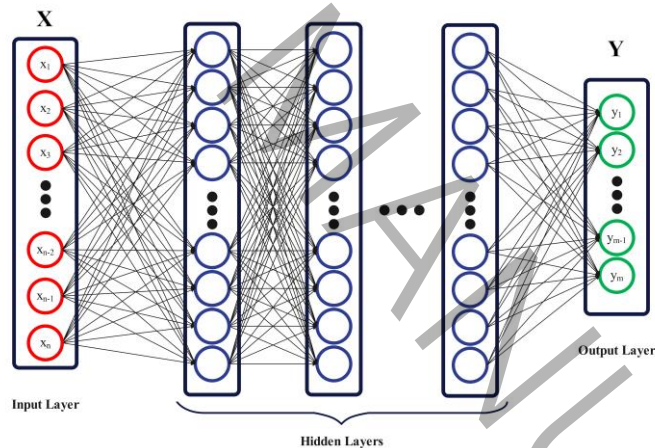
شبکه عصبی مصنوعی توانایی خوبی برای یافتن روابط غیرخطی و پیچیده بین داده‌های ورودی و خروجی دارد. شبکه عصبی عمیق یک نوع شبکه عصبی است که از یک لایه ورودی، چندین لایه پنهان و یک لایه خروجی تشکیل شده است. در این شبکه تمام نودهای^۱ هر لایه به تمام نودهای لایه قبلی متصل هستند. شماییک شبکه عصبی عمیق در شکل ۲ نشان داده شده است. در این نوع شبکه رابطه بازگشتی وجود ندارد و جریان داده رو به جلو است. محاسبه خروجی هر لایه به این صورت است مقدار هر نود از حاصل ضرب تمام نود های لایه قبلی در وزن مربوطه محاسبه شده و با یک مقدار بایاس جمع می‌شوند، سپس روی مقادیر محاسبه شده تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی، غیرخطی بودن را به مدل اضافه می‌کند.

$$\mathbf{h} = f(\mathbf{WX} + \mathbf{b}) \quad (۳)$$

که در آن \mathbf{h} بردار خروجی هر لایه، f یک تابع فعال‌سازی، \mathbf{W} تابع وزن، \mathbf{X} بردار ورودی و \mathbf{b} بایاس است. برای رگرسیون، لایه آخر به صورت زیر محاسبه می‌شود.

$$\mathbf{Y} = \mathbf{WX} + \mathbf{b} \quad (۴)$$

که در آن \mathbf{Y} بردار خروجی لایه آخر شبکه عصبی عمیق است. بردار خروجی آخرین لایه در شبکه عصبی در واقع مقادیر پیش‌بینی شده توسط شبکه عصبی هستند. مقادیر \mathbf{W} و \mathbf{b} در زمان آموزش شبکه تعیین می‌شوند و رابطه بین ورودی و خروجی را تعیین می‌کنند.



شکل ۲: ساختار یک شبکه عصبی عمیق

Fig. 2. Architecture of the deep neural network.

۳-۲-۲- حافظه کوتاه طولانی مدت

حافظه کوتاه طولانی مدت یک شبکه عصبی بازگشتی است. شبکه‌های بازگشتی برای داده دارای توالی مانند سری‌های زمانی یا زبان طبیعی استفاده می‌شوند. در این شبکه‌ها لایه پنهان مرحله قبل همراه با داده جدید به عنوان ورودی شبکه استفاده می‌شوند. شبکه عصبی بازگشتی برای سری‌های طولانی، که در آن خروجی به داده‌های ورودی اولیه وابسته است، مناسب نبودند. برای حل این مشکل حافظه کوتاه طولانی مدت ایجاد شد. در حافظه کوتاه طولانی مدت از یک سلول حافظه استفاده می‌شود تا اطلاعات مهم در این سلول ذخیره شود. این سلول به عنوان حافظه شبکه در نظر گرفته می‌شود و می‌تواند در مدت طولانی حفظ شود یا با توجه به اطلاعات جدید

¹ Node

تغییر کند. محاسبات داخلی این شبکه به این صورت است که از دروازه‌هایی برای محاسبه خروجی نهایی استفاده شده است. در این شبکه از سه دروازه فراموشی، ورودی و خروجی و یک گره ورودی استفاده می‌شود. تابع فعال‌سازی دروازه‌ها و گره ورودی به ترتیب تابع سیگموئید^۱ و تانژانت هایپربولیک است. این شبکه علاوه بر حالت پنهان، دارای حالت داخلی سلول است. حالت داخلی سلول به عنوان حافظه برای حفظ طولانی مدت اطلاعات استفاده می‌شود. در این شبکه دروازه ورودی برای تعیین میزان اضافه شدن مقدار گره ورودی به حالت داخلی سلول در گام زمانی فعلی، گیت فراموشی برای تعیین حفظ یا پاک شدن مقدار فعلی حافظه و گیت خروجی برای تعیین تاثیر حالت سلول داخلی در گام زمانی فعلی است. در این سلول خروجی دروازه‌ها و گره خروجی توسط لایه‌های کاملاً متصل محاسبه می‌شود. جریان محاسبات داخلی حافظه کوتاه طولانی مدت در شکل ۳ نشان داده شده است. روابط محاسبه خروجی سلول حافظه کوتاه طولانی مدت در معادله (۵) آورده شده است [۲۶].

$$\mathbf{I}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xi} + \mathbf{H}_{t-1} \mathbf{W}_{hi} + \mathbf{b}_i) \quad (الف-۵)$$

$$\mathbf{F}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xf} + \mathbf{H}_{t-1} \mathbf{W}_{hf} + \mathbf{b}_f) \quad (ب-۵)$$

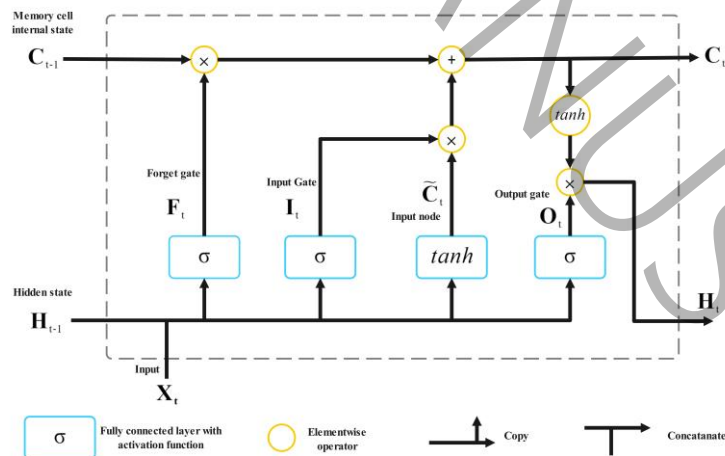
$$\mathbf{O}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xo} + \mathbf{H}_{t-1} \mathbf{W}_{ho} + \mathbf{b}_o) \quad (ج-۵)$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{X}_t \mathbf{W}_{xc} + \mathbf{H}_{t-1} \mathbf{W}_{hc} + \mathbf{b}_c) \quad (د-۵)$$

$$\mathbf{C}_t = \mathbf{F}_t \odot \mathbf{C}_{t-1} + \mathbf{I}_t \odot \tilde{\mathbf{C}}_t \quad (ه-۵)$$

$$\mathbf{H}_t = \mathbf{O}_t \odot \tanh(\mathbf{C}_t) \quad (ی-۵)$$

در این روابط \mathbf{I}_t بردار دروازه ورودی، \mathbf{F}_t بردار دروازه فراموشی، \mathbf{O}_t بردار دروازه خروجی، $\tilde{\mathbf{C}}_t$ بردار گره ورودی، \mathbf{C}_t بردار حالت داخلی سلول، \mathbf{H}_t بردار حالت پنهان و \mathbf{X}_t بردار داده ورودی در گام t و \mathbf{H}_{t-1} و \mathbf{C}_{t-1} به ترتیب بردار حالت پنهان و بردار حالت داخلی شبکه در گام قبلی است. نماد \odot نشان دهنده عملگر ضرب درایه‌ای است. \mathbf{W}_{\square} پارامتر وزن و \mathbf{b}_{\square} پارامتر بایاس شبکه مربوط به هر لایه کاملاً متصل است. برای مثال \mathbf{W}_{xi} وزن بردار ورودی \mathbf{X} در دروازه فراموشی است.



شکل ۳: ساختار یک سلول حافظه کوتاه طولانی مدت

Fig. 3. Structure of the Long Short-Term Memory (LSTM) unit.

¹ Sigmoid

۳-۲-۳- واحد بازگشتی دروازه‌ای

یکی دیگر از انواع شبکه عصبی بازگشتی، واحد بازگشتی دروازه‌ای است. این شبکه عصبی نیز با هدف رفع مشکلات شبکه‌های بازگشتی و ایجاد نوعی حافظه در ساختار آن ایجاد شد. مکانیزم کار این شبکه نیز شبیه حافظه طولانی کوتاه مدت است. در این شبکه فقط دو دروازه بازنشانی و به‌روزرسانی در نظر گرفته شده است. دروازه بازنشانی برای تعیین میزان نگهداری حافظه پنهان قبلی و دروازه به‌روزرسانی برای تعیین میزان اضافه کردن اطلاعات فعلی یا در نظر گرفتن حالت پنهان قبلی در حالت پنهان فعلی شبکه است. خروجی دروازه‌ها توسط دو لایه کاملاً متصل محاسبه می‌شود. این شبکه تعداد پارامتر کمتری دارد و آموزش و پاسخ آن معمولاً سریع‌تر از حافظه کوتاه طولانی مدت است و نیاز به منابع پردازشی کمتری دارد. جریان محاسبات این شبکه در شکل ۴ نشان داده شده است. روابط مربوط به محاسبه سلول واحد بازگشتی دروازه‌ای در معادله (۶) آورده شده است [۲۶].

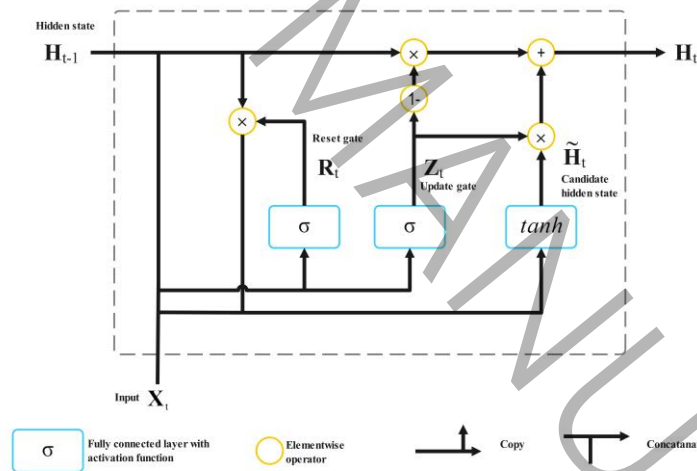
$$\mathbf{R}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xr} + \mathbf{H}_{t-1} \mathbf{W}_{hr} + \mathbf{b}_r) \quad (۶-الف)$$

$$\mathbf{Z}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xz} + \mathbf{H}_{t-1} \mathbf{W}_{hz} + \mathbf{b}_z) \quad (۶-ب)$$

$$\tilde{\mathbf{H}}_t = \tanh(\mathbf{X}_t \mathbf{W}_{xh} + (\mathbf{R}_t \odot \mathbf{H}_{t-1}) \mathbf{W}_{hh} + \mathbf{b}_h) \quad (۶-ج)$$

$$\mathbf{H}_t = \mathbf{Z}_t \odot \mathbf{H}_{t-1} + (1 - \mathbf{Z}_t) \odot \tilde{\mathbf{H}}_t \quad (۶-د)$$

در این معادلات \mathbf{R}_t بردار دروازه بازنشانی، \mathbf{Z}_t بردار دروازه به‌روزرسانی، \mathbf{H}_t بردار حالت پنهان، $\tilde{\mathbf{H}}_t$ بردار کاندیدای حالت پنهان است. \mathbf{W}_\square پارامتر وزن و \mathbf{b}_\square پارامتر بایاس است.



شکل ۴: ساختار یک سلول واحد بازگشتی دروازه‌ای

Fig. 4. Structure of the Gated Recurrent Unit (GRU).

۳-۲-۴- مدل‌های پیش‌بین سرعت تحلیلی

دو مدل تحلیلی رایج در پیش‌بینی سرعت خودرو مدل سرعت ثابت و شتاب ثابت هستند. در مدل سرعت ثابت فرض می‌شود که خودرو با سرعت ثابت به حرکت خود ادامه خواهد داد. سرعت ثابت خودرو در این روش با استفاده از معادله (۷) محاسبه می‌شود.

$$v_{k+i} = v_{const}, (i = 0, 1, \dots, n) \quad (۷-الف)$$

(۷-ب)

$$v_{const} = \frac{v_k + v_{k-1}}{2}$$

که در آن v_{k+i} سرعت در زمان $k+i$ ، v_{const} سرعت ثابت خودرو، v_k سرعت خودرو در زمان فعلی و v_{k-1} سرعت خودرو در گام زمانی قبلی است.

در روش شتاب ثابت فرض می‌شود که خودرو با شتاب ثابت به حرکت خود ادامه خواهد داد. شتاب ثابت و سرعت آینده خودرو به ترتیب با معادله (۸-الف) و (۸-ب) محاسبه می‌شود.

$$v_{k+i} = v_k + i \Delta T a_{const}, (i = 0, 1, \dots, n) \quad (۸-الف)$$

$$a_{const} = \frac{v_k - v_{k-1}}{\Delta T} \quad (۸-ب)$$

که در آن a_{const} شتاب ثابت خودرو و ΔT گام زمانی است.

علاوه بر این دو روش، روش شتاب متغیر نیز برای پیش‌بینی سرعت خودرو استفاده می‌شود. در این روش شتاب با کاهش نمایی^۱ در نظر گرفته می‌شود و در سیکل‌های رانندگی پیش‌بینی خوبی دارد [۲۷]. روش محاسبه شتاب در این روش بر اساس معادله (۹) است.

$$a(t + \tau) = a(t) e^{-\lambda \tau} \quad (۹)$$

که در آن $a(t)$ شتاب فعلی خودرو، $a(t + \tau)$ شتاب خودرو در لحظه $t + \tau$ و λ پارامتر کنترل میزان کاهش است.

۳-۲-۵- ارزیابی خطا

برای ارزیابی روش‌های پیش‌بینی سرعت از معیار میانگین خطای مطلق^۲ استفاده شده است. این معیار آماری برای مشخص کردن مقدار خطای داده پیش‌بینی شده است. میزان زیان در آموزش مدل‌ها نیز با معیار میانگین مربعات خطا^۳ محاسبه می‌شود. میانگین خطای مطلق، میانگین بزرگی خطا در پیش‌بینی بدون در نظر گرفتن جهت آن، با استفاده از قدر مطلق اختلاف با مقدار واقعی اندازه‌گیری می‌کند. میانگین خطای مطلق طبق معادله (۹) و میانگین مربعات خطا طبق معادله (۱۰) محاسبه می‌شود.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (۱۰)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (۱۱)$$

که در آن y_i ها مقادیر واقعی، \hat{y}_i مقادیر پیش‌بینی شد و n تعداد مشاهدات است.

۴- نتایج و بحث

در این پژوهش هر سه مدل روی دو مجموعه داده آموزش داده شده است. داده اول، داده نرمال شده با روش نرمال سازی ویژه است. داده دوم، داده سرعت بدون نرمال سازی یا همان داده خام است که در آن سرعت‌ها به صورت مقادیر واقعی بدون هیچگونه تغییر استفاده می‌شوند. مدل‌هایی که با داده سرعت خام و نرمال نشده آموزش داده شده‌اند با پسوند Raw مشخص شده‌اند. روش‌های نرمال سازی رایج دیگر نیز بررسی شد و نتیجه مشابه آموزش با داده‌های خام داشتند. به همین دلیل مدل‌ها روی داده‌های خام آموزش داده شدند و به عنوان روش پایه مورد قیاس قرار گرفتند. همچنین سه روش تحلیلی سرعت ثابت، شتاب ثابت و شتاب متغیر با شتاب کاهشی به صورت نمایی برای مقایسه استفاده شدند و در نمودارها و جداول به ترتیب با سه نماد CA، CV، EDA نشان داده شدند. مجموعه داده به سه بخش داده آموزش، داده اعتبارسنجی و داده آزمایش تقسیم می‌شود. داده آموزش، داده اعتبارسنجی و داده آزمایش به ترتیب ۶۰، ۱۰ و ۲۰ درصد از داده‌های مجموعه داده است. داده‌ها به صورتی تقسیم شده‌اند حداقل همپوشانی را دارند. این یعنی برای مثال داده‌هایی که در داده آزمایش هستند مربوط به خودروهایی هستند که هیچ داده‌ای از آنها در مجموعه‌های دیگر نیست.

¹ Exponential decay acceleration

² Mean absolute error (MAE)

³ Mean squared error (MSE)

اولین گام برای ایجاد مدل‌های پیش‌بین سرعت، مشخص کردن هایپرپارامترهای مدل‌ها است. هایپرپارامترها شامل تعداد لایه‌های پنهان، اندازه لایه‌های پنهان، تعداد لایه‌های بازگشتی، نرخ یادگیری، تعداد دوره آموزش و اندازه دسته داده است. همه مدل‌ها با هایپرپارامترهای متفاوت آموزش داده شده و بهترین ترکیب هایپرپارامترهای هر مدل در بین موارد بررسی شده انتخاب شد. بهترین ترکیب هایپرپارامترها بر اساس میزان زیان شبکه روی داده صحت‌سنجی بوده است. ابتدا هایپرپارامترهای مربوط به ساختار مدل بر اساس کمترین میزان انتخاب می‌شود. سپس مجموعه هایپرپارامتری که کمترین میزان زیان روی برای هر مجموعه داده دارند انتخاب می‌شود. سپس هر مدل با این هایپرپارامترهای انتخابی مربوط به آن آموزش می‌شود. تعداد دوره آموزش هر شبکه نیز طوری انتخاب شده است که از بیش‌یادگیری شبکه‌های عصبی جلوگیری شود. در جدول ۱ هایپر پارامترهای انتخاب شده برای هر شبکه آورده شده است.

Table 1. Training hyperparameters of the models.

جدول ۱: هایپر پارامترهای استفاده شده برای آموزش مدل‌ها

مدل	تعداد لایه/لایه پنهان	اندازه لایه/لایه‌های پنهان	تعداد دوره آموزش
LSTM	۳	۶۴	۳۰۰
LSTM-Raw	۴	۳۲	۲۰۰
GRU	۴	۳۲	۲۰۰
GRU-Raw	۳	۶۴	۱۷۵
DNN	۴	۱۰۲۴، ۸۵۰، ۲۵۶، ۶۰۰، ۸۵۰، ۱۰۲۴	۲۰۰
DNN-Raw	۵	۱۰۲۴، ۱۵۰۰، ۱۵۰۰، ۱۵۰۰، ۲۰۰۰	۲۰۰

در آموزش همه مدل‌های پیش‌بین سرعت از نرخ یادگیری ۰/۰۰۱، ضریب کاهش نرخ یادگیری ۰/۹ در هر ۲۵ دوره آموزش استفاده شد. به روزرسانی وزن‌های شبکه‌ها با الگوریتم AdamW انجام شد. ابعاد ورودی مدل‌های حافظه کوتاه طولانی مدت و واحد بازگشتی دروازه‌ای برابر با (۵×۲۵۰) و خروجی آن (۱×۱۵۰) است. ابعاد ورودی مدل‌های شبکه عصبی عمیق برابر با (۱×۱۲۵۰) و خروجی آن نیز (۱×۱۵۰) می‌باشد. اندازه دسته در آموزش همه مدل‌ها ۸ در نظر گرفته شد. نمودار میزان زیان روی داده آموزش و اعتبارسنجی بر حسب دوره آموزش در شکل ۵ نشان داده شده است. بر اساس این شکل مشخص است که مدل‌ها به اندازه کافی آموزش دیده‌اند و میزان زیان آنها به مقدار کمینه خود رسیده است. همچنین از روند تغییرات زیان روی داده اعتبارسنجی مشخص است که مدل‌ها دچار بیش‌یادگیری نشده‌اند و روند کاهش میزان زیان روی داده آموزش و اعتبارسنجی یکی است. میزان هزینه مدل‌های آموزش داده شده بر حسب میانگین مربعات خطا^۱ روی داده آموزش و اعتبارسنجی در آخرین مرحله آموزش در جدول ۲ آورده شده است.

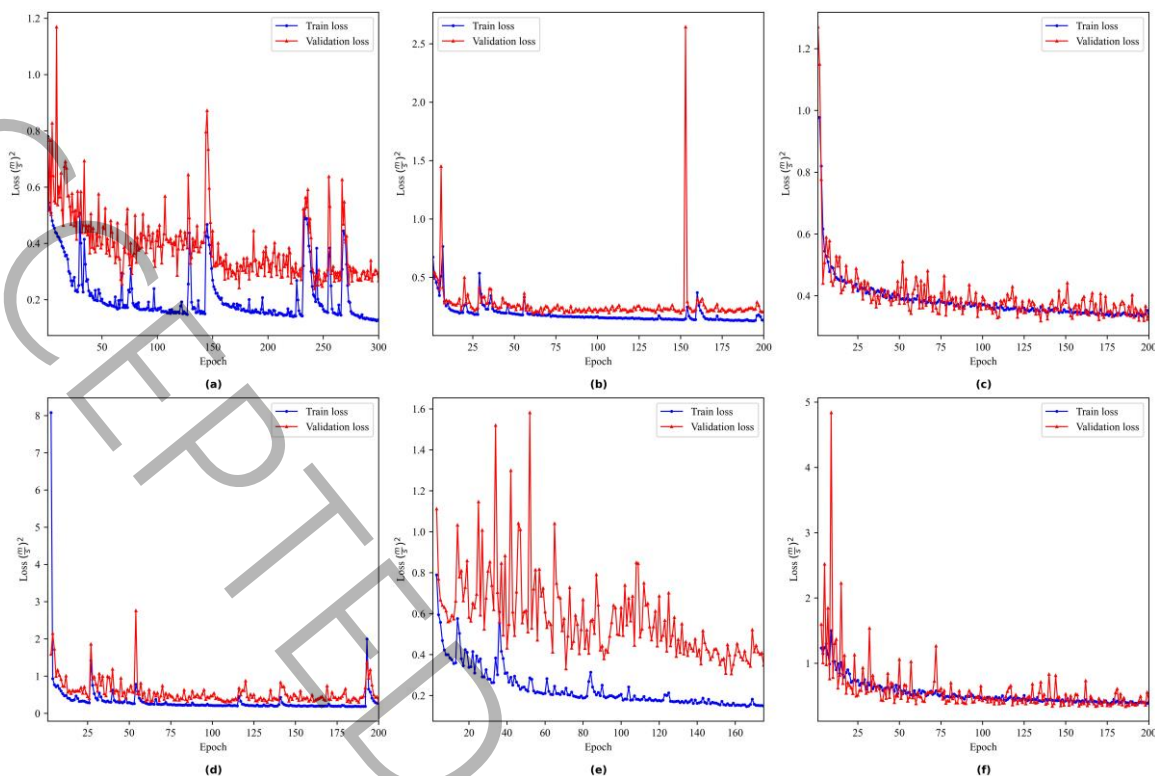
Table 2. Final Root Mean Squared Error (RMSE) of the trained models.

جدول ۲: مقدار نهایی زیان در آموزش مدل‌ها بر حسب میانگین مربعات خطا

مدل	LSTM	LSTM-Raw	GRU	GRU-Raw	DNN	DNN-Raw
میزان زیان روی داده آموزش در آخرین دور	۰/۱۲۹۷	۰/۲۶۷۶	۰/۱۳۱۸	۰/۱۴۸۹	۰/۳۳۳۶	۰/۳۹۹۳
میزان زیان روی داده اعتبارسنجی در آخرین دور	۰/۲۶۷۳	۰/۳۲۱۶	۰/۲۰۶۵	۰/۳۴۸۸	۰/۳۳۶۹	۰/۴۳۲۷

پس از آموزش مدل‌ها باید عملکرد آن روی داده‌های آزمایش بررسی شود. مجموعه داده آزمایش شامل داده سرعت خودروهایی است که اصلاً در زمان آموزش استفاده نشده است. برای بررسی مدل‌ها، میزان خطای پیش‌بینی با معیار میانگین خطای مطلق در شش ثانیه روی کل مجموعه داده آزمایش و برای تمام مدل‌های هوشمند و سه مدل تحلیلی محاسبه می‌شود.

¹ Mean squared error (MSE)



شکل ۵: نمودار تغییرات تابع هزینه بر روی داده‌های آموزش و اعتبارسنجی برای مدل‌های (a) LSTM، (b) LSTM-Raw، (c) GRU، (d) GRU-Raw، (e) DNN، و (f) DNN-Raw.

Fig. 5. Training and validation loss curves for different neural network models: (a) LSTM, (b) LSTM-Raw, (c) GRU, (d) GRU-Raw, (e) DNN, and (f) DNN-Raw.

همانطور که در جدول ۳ مشخص است مدل پیش‌بین سرعت بر اساس واحد بازگشتی دروازه‌ای روی داده نرمال شده کمترین مقدار خطای پیش‌بینی را دارد. میانگین خطای مطلق پیش‌بینی این مدل در افق شش ثانیه‌ای ۰/۲۴۱۰ و در افق دو ثانیه‌ای ۰/۰۵۷۸ متر بر ثانیه است. مدل حافظه کوتاه طولانی مدت روی داده نرمال شده نیز مقدار خطای پیش‌بینی بسیار کم و نزدیک به مدل واحد بازگشتی دروازه‌ای دارد. خطای پیش‌بینی با مدل واحد بازگشتی دروازه‌ای در افق شش ثانیه‌ای نسبت به مدل‌های سرعت ثابت، شتاب ثابت و شتاب متغیر به ترتیب ۵۸/۱۲، ۳۳/۸۱ و ۲۴/۳۰ درصد کمتر است. بهترین مدل آموزش داده شده روی داده نرمال نشده مدل حافظه کوتاه طولانی مدت با خطای ۰/۲۷۷۶ است و مدل واحد بازگشتی دروازه‌ای با نرمال‌سازی ویژه ۱۳/۱۸ درصد خطای پیش‌بینی کمتری نسبت به آن دارد. هرچند میزان خطای مدل‌ها آموزش داده شده روی داده خام نیز مقدار کم و نزدیک به مدل‌های آموزش داده شده روی داده‌های نرمال شده دارند، خطای پیش‌بینی آنها در گام‌های زمانی اولیه زیاد است. چون پیش‌بینی سرعت در زمان‌های آینده نزدیک بسیار مهم‌تر از زمان‌های دورتر است، میزان خطای پیش‌بینی در دو ثانیه اول پیش‌بینی نیز محاسبه شد. همانطور که در جدول ۳ نشان داده شده است کمترین میزان خطای پیش‌بینی در دو ثانیه آینده مربوط به شبکه واحد بازگشتی دروازه‌ای با نرمال‌سازی ویژه است. همچنین مشخص است که پیش‌بینی مدل‌های آموزش داده شده روی داده خام بسیار زیادی دارد و خطای پیش‌بینی آنها حتی از مدل‌های تحلیلی هم بیشتر است. دلیل آن وجود آفست در سرعت پیش‌بینی شده است. این مدل‌ها هر چند مسیر سرعت را بهتر از مدل‌های تحلیلی پیش‌بینی می‌کنند ولی پیش‌بینی گام‌های اولیه در آنها دقیق نیست. برای بررسی آفست، میزان میانگین خطای مطلق و حداکثر خطا در پیش‌بینی گام اول روی کل مجموعه داده آزمایش در جدول ۳ نشان داده شد. همانطور که در جدول ۳ مشخص است، خطای پیش‌بینی در گام اول مدل‌هایی که در آموزش آنها از نرمال‌سازی ویژه استفاده شد بسیار کم و نزدیک به روش‌های تحلیلی است. مدل‌هایی که روی داده خام آموزش داده شده‌اند به میانگین خطای بسیار زیادی دارند و این خطا در گام زمانی

۰/۰۴ ثانیه غیر قابل قبول است. همچنین حداکثر خطای این مدل‌ها نشان می‌دهد که این خطا می‌تواند بسیار زیاد و غیر قابل قبول و مغایر با فیزیک مسئله، باشد.

Table 3. Mean absolute error (MAE) of velocity forecasting at 2 s and 6 s prediction horizons, and maximum one-step-ahead prediction error on the test dataset.

جدول ۳: مقدار میانگین خطای مطلق پیش‌بینی سرعت در شش و دو ثانیه و حداکثر خطای پیش‌بینی در گام اول روی کل مجموعه داده آزمایش


مدل	پیش‌بینی شش ثانیه (متر بر ثانیه)	پیش‌بینی دو ثانیه (متر بر ثانیه)	حداکثر خطا در گام اول	میانگین مطلق خطا در گام اول
LSTM	۰/۲۴۹۹	۰/۰۶۱۳	۰/۰۴۳۴	۰/۰۰۴۳
LSTM-Raw	۰/۲۷۷۶	۰/۱۳۰۹	۱/۵۷۹۴	۰/۱۲۱۲
GRU	۰/۲۴۱۰	۰/۰۵۷۸	۰/۰۳۳۶	۰/۰۰۴۴
GRU-Raw	۰/۲۹۷۰	۰/۱۶۲۴	۱/۵۱۲۷	۰/۱۸۱۷
DNN	۰/۳۲۴۰	۰/۱۳۱۱	۰/۰۶۴۲	۰/۰۰۷۳
DNN-Raw	۰/۳۶۸۶	۰/۱۷۹۳	۱/۴۳۳۲	۰/۱۴۲۰
CV	۰/۵۷۶۱	۰/۱۹۳۱	۰/۰۹۰۰	۰/۰۰۸۰
CA	۰/۳۶۴۱	۰/۰۶۰۳	۰/۰۱۲۰	۰/۰۰۳۶
EDA	۰/۳۴۰۹	۰/۰۵۹۱	۰/۰۱۲۰	۰/۰۰۳۶

برای ارزیابی روش‌های پیش‌بینی سرعت، پیش‌بینی مدل‌های متفاوت در دو سناریو متفاوت روی داده آزمایش در شکل ۶ آورده شده است. همچنین میزان خطای پیش‌بینی همه روش‌ها محاسبه و در جدول ۴ آورده شده است. این دو حرکت با سرعت پایین با وجود خودرو جلویی (شکل ۲-الف) و سناریو حرکت با سرعت بالا با وجود خودرو جلویی (شکل ۲-ب) است. در شکل ۶-الف مشخص است که همه مدل‌ها و روش شتاب ثابت و شتاب متغیر در این دو نمونه انتخاب شده به خوبی روند افزایش سرعت را پیش‌بینی کردند. در این شکل به خوبی آفست در پیش‌بینی سرعت توسط مدل‌های آموزش داده شده با داده خام مشخص است. این آفست در صورت آموزش با دیگر روش‌های نرمال‌سازی رایج نیز وجود خواهد داشت. همه مدل‌های آموزش داده شده روی داده نرمال شده خطای بسیار کم و تقریباً صفر در گام اولیه دارد. این آفست یا همان میزان خطا در گام اول در جدول ۴ گزارش شده است. دلیل نداشتن آفست این است که در داده‌های نرمال شده با روش نرمال‌سازی ویژه در گام‌های اولیه مقدار بسیار کم و نزدیک به صفر دارند و در گام‌های بعدی سرعت به تدریج و به صورت نسبی تغییر می‌کند. این نرمال‌سازی ویژه که در این مقاله ارائه شده برای مسئله پیش‌بینی سرعت مناسب است و مدل‌هایی که روی این داده‌ها آموزش داده شدند به خوبی سرعت را پیش‌بینی می‌کنند. روش ارائه شده همزمان دقت مناسب در کوتاه مدت و هم بلند مدت دارد. در جدول ۴ مقدار خطای پیش‌بینی در ۲ و ۶ ثانیه در این سناریو آورده شده است.

در جدول ۴ مشاهده می‌شود که در پیش‌بینی سرعت در شش ثانیه کمترین مقدار خطا مربوط به حافظه کوتاه طولانی مدت و بعد از آن مدل شتاب متغیر است. دلیل دقت خوب مدل شتاب متغیر و شتاب ثابت، همخوانی رفتار راننده با فرض استفاده شده برای توسعه این مدل است. همانطور که در شکل ۶ مشخص است سرعت ابتدا به صورت تقریباً شتاب ثابت و در انتها با کاهش همراه است. هر چند در شش ثانیه، خطای مدل واحد بازگشتی دروازه‌ای خطای نسبتاً بیشتری دارد ولی در پیش‌بینی در دو ثانیه کمترین میزان خطا در بین روش‌های داده محور را دارد.

در نمونه آورده شده در شکل ۲-ب تغییرات سرعت به صورت غیر خطی و نسبتاً زیاد است. همانطور که در این شکل مشاهده می‌شود مدل واحد بازگشتی دروازه‌ای بهترین پیش‌بینی و کمترین میزان خطا را دارد. در دو ثانیه اول خطای مدل شتاب متغیر کمتر از مدل‌های دیگر است ولی این مدل وقتی شتاب تغییر کند خطای زیادی خواهد داشت. در این نمونه مدل‌هایی که روی داده خام آموزش داده شده اند نیز در ابتدا پیش‌بینی دقیقی داشته و تقریباً آفست ندارند. در واقع در اندکی از نمونه‌ها آفست پیش‌بینی این مدل‌ها کم است ولی

هیچوقت صفر نمی‌شود و حتی در بهترین حالت هم در پیش‌بینی اولین سرعت آینده خطا وجود دارد. میزان آفست پیش‌بینی همه روش‌ها در جدول ۴ گزارش شده است.



شکل ۶: نمودار پیش‌بینی سرعت توسط هر شش مدل آموزش داده شده و مدل سرعت ثابت، شتاب ثابت و شتاب متغییر در: (a) سناریو سرعت کم (b) سناریو سرعت زیاد.

Fig. 6. Velocity forecasting plots of six trained models and constant velocity, constant acceleration, and exponentially decaying acceleration models in (a) low-speed and (b) high-speed scenarios.


Table 4. Forecasting error of velocity prediction models in the two scenarios presented in Fig. 6.

جدول ۴: مقدار خطای پیش‌بینی مدل‌های پیش‌بین سرعت در دو سناریو نشان داده شده در شکل ۶

سناریو سرعت زیاد شکل ۶-ب			سناریو سرعت کم شکل ۶-الف			مدل
گام اول	دو ثانیه	شش ثانیه	گام اول	دو ثانیه	شش ثانیه	
۰/۰۰۵۱	۰/۱۱۷۶	۰/۱۴۵۰	۰/۰۰۵۲	۰/۰۵۹۳	۰/۰۷۹۲	LSTM
۰/۰۳۰۶	۰/۲۲۱۱	۰/۲۸۷۶	۰/۲۸۶۳	۰/۴۱۹۰	۰/۵۲۱۹	LSTM-Raw
۰/۰۱۰۶	۰/۰۹۱۲	۰/۰۸۰۲	۰/۰۰۰۱	۰/۰۲۹۵	۰/۳۳۱۷	GRU
۰/۰۰۵۳	۰/۰۶۳۷	۰/۲۲۵۸	۰/۵۶۶۶	۰/۴۴۰۰	۰/۷۷۸۳	GRU-Raw
۰/۰۲۷۸	۰/۴۶۹۹	۰/۷۹۰۴	۰/۰۲۱۰	۰/۴۱۵۷	۰/۷۲۵۷	DNN
۰/۱۱۵۲	۰/۳۵۲۵	۰/۵۳۸۰	۰/۲۸۰۶	۰/۲۵۸۸	۰/۸۵۵۵	DNN-Raw
۰/۰۴۰۰	۰/۷۵۹۸	۱/۶۰۸۹	۰/۰۳۰۰	۰/۵۹۴۰	۱/۶۱۷۱	CV
۰/۰۰۵۲	۰/۰۹۲۳	۰/۹۸۱۵	۰/۰۰۳۹	۰/۰۴۶۷	۰/۳۳۰۵	CA
۰/۰۰۵۲	۰/۰۶۵۷	۰/۷۴۳۸	۰/۰۰۳۹	۰/۰۲۶۷	۰/۱۵۱۷	EDA

برای بررسی وجود آفست، پیش‌بینی سرعت روی یک نمونه داده دیگر از مجموعه داده آزمایش در شکل ۷ آورده شده است. در این شکل نمای بزرگنمایی شده در ۰/۲ ثانیه اول نشان داده شده است. همانطور که در شکل ۱ مشخص است مدل‌های آموزش داده شده روی داده خام در بهترین حالت هم آفست نسبتاً زیادی در پیش‌بینی گام اول دارند؛ هر چند از لحاظ فیزیکی این مورد قابل قبول نیست و یک خودرو در شرایط عادی هیچوقت پرفش شدید در سرعت در گام زمانی بسیار کوتاه ندارد. در عوض تمامی مدل‌های آموزش داده شده با داده نرمال شده، در زمان‌های اولیه، سرعت را به خوبی و با دقت بالا پیش‌بینی می‌کنند. در این مدل‌ها خطای سرعت پیش‌بینی شده

در گام اولیه تقریباً صفر است. روش نرمال سازی ارائه شده باعث می شود که مدل ها به صورت منطبق با فیزیک سرعت خودرو را پیش بینی کنند.




شکل ۷: نمودار با نمای بزرگنمایی شده پیش بینی سرعت خودرو در ۰/۲ ثانیه در: (a) مدل های آموزش داده شده با روش پیشنهادی و (b) مدل های آموزش داده شده با داده خام.

Fig. 7. Zoomed-in velocity forecasting results over a 0.2 s interval: (a) models trained using the proposed approach, (b) models trained using raw data.

در پیش بینی سرعت خودرو ممکن است همیشه تعداد خودروهای جلویی خودرو هدف برابر با چهار نباشد یا تاریخچه سرعت همه آنها برای ده ثانیه گذشته در دسترس نباشد. یعنی تعداد خودرو و میزان تاریخچه سرعت در دسترس آنها متغیر باشد. در آموزش مدل های هوشمند توسعه داده شده، عدم قطعیت در تعداد خودروهای جلویی و تاریخچه آنها در نظر گرفته شده است. در واقع مدل ها حتی در صورت عدم وجود خودرو در جلو خودرو هدف نیز قابلیت پیش بینی سرعت را دارند و پیش بینی فقط محدود به یک سناریو خاص نیست. در شکل ۸ پیش بینی سرعت خودرو جلویی در دو سناریو افزایش سرعت به صورت پیوسته (شکل ۸-الف) و افزایش و سپس کاهش سرعت (شکل ۸-ب) بدون وجود خودرو در جلو خودرو هدف نشان داده شده است. در شکل ۸-الف مشاهده می شود که همه مدل های توسعه داده شده به خوبی رفتار و سرعت آینده خودرو را پیش بینی کرده اند و پیش بینی آنها از روش های تحلیلی سرعت ثابت، شتاب ثابت و شتاب متغیر بهتر است. در سناریو بعدی که در شکل ۸-ب آورده شده است مدل ها هوشمند توسعه داده شده تا جایی که سرعت افزایشی است رفتار و سرعت آینده را به خوبی پیش بینی کرده اند ولی هیچکدام نتوانستند تغییر در شتاب و مسیر سرعت را پیش بینی کنند. این رفتار می تواند نشان دهنده این باشد که در این حالت هیچ خودرو جلویی وجود ندارد و سرعت فقط باید بر اساس سابقه سرعت خودرو هدف باشد. در این حالت سرعت آینده به تصمیمات راننده بستگی دارد و امکان پیش بینی تغییرات در شتاب و سرعت خودرو وجود ندارد. در صورت وجود خودرو جلویی می توان این تغییرات را بر اساس تغییرات سرعت خودرو جلویی پیش بینی کرد.

برای بررسی امکان پیاده سازی روش برای اجرای در لحظه، روش ارائه شده روی یک سیستم کامپوتری با پردازنده Intel Core i7-8550U، ۸ گیگابایت رم و کارت گرافیک Nvidia MX150 اجرا شد. زمان استنتاج شبکه واحد بازگشتی پیشنهادی روی این سیستم برابر با 0.751 ± 0.008 میلی ثانیه است و امکان اجرای در لحظه را دارد.



شکل ۸ : نمودار پیش‌بینی سرعت خودرو بدون وجود خودرو جلویی در: (a) افزایش سرعت پیوسته و (b) افزایش و سپس کاهش سرعت.

Fig. 8. Vehicle velocity forecasting in the absence of preceding vehicles under (a) continuously increasing speed and (b) increasing then decreasing speed.

۵- نتیجه گیری

پیش‌بینی سرعت خودرو یکی از بخش‌های مهم در توسعه خودروهای هوشمند و پیشگیری از تصادفات است. در این پژوهش از الگوریتم‌های مختلف یادگیری عمیق و دو مجموعه داده‌ی نرمال شده و خام برای پیش‌بینی سرعت خودرو در بزرگراه استفاده شده است. در این مطالعه، یک روش دقیق برای پیش‌بینی سرعت خودروی هدف بر اساس تاریخچه‌ی سرعت خودروی هدف و خودروهای جلویی آن توسعه داده شده است.

در ابتدا داده‌های سرعت با استفاده از یک روش نرمال‌سازی ابتکاری که در این پژوهش معرفی شده است، نرمال‌سازی شدند. سپس مدل‌های حافظه کوتاه طولانی مدت، واحد بازگشتی دروازه‌ای و شبکه عصبی عمیق با استفاده بر روی این داده‌ها آموزش داده شدند. هرچند گام زمانی کوتاه می‌تواند موجب افزایش دقت پیش‌بینی شود، اما به دلیل تعداد بالای داده‌های پیش‌بینی حتی در بازه‌های زمانی کوتاه و نیاز به پیش‌بینی دقیق هر گام، کاربرد آن چالش‌برانگیز است. در این کار پیش‌بینی سرعت با گام زمانی بسیار کوتاه ۰/۴ ثانیه انجام شده است. پیش‌بینی دقیق در این گام زمانی نشان‌دهنده‌ی دقت و کارآمدی روش توسعه‌یافته است، زیرا با کاهش گام زمانی، اهمیت دقت پیش‌بینی در هر گام و مخصوصاً گام‌های ابتدایی افزایش می‌یابد.

روش نرمال‌سازی ویژه پیشنهادی، به همراه انتخاب شبکه‌ی عصبی مناسب و استفاده از داده خودروهای دیگر موجب افزایش دقت پیش‌بینی سرعت شده است. بر اساس مقایسه‌ی انجام‌شده بین مدل‌های آموزش‌دیده بر روی داده‌های نرمال‌شده با روش نرمال‌سازی ویژه و داده‌های خام، مشاهده می‌شود که مدل‌های آموزش‌دیده بر روی داده‌های خام، هرچند روند تغییرات سرعت را پیش‌بینی می‌کنند، اما دارای خطای بالا بوده و پیش‌بینی آن‌ها در گام‌های زمانی اولیه دارای آفست قابل توجه است. در مقابل، تمامی مدل‌های آموزش‌دیده بر روی داده‌های نرمال‌شده عملکرد بهتری داشته و برخلاف پژوهش‌های موجود، هیچ‌کدام در اولین گام پیش‌بینی دچار آفست نیستند و خطای پیش‌بینی در تمامی بازه‌ها کم است. علاوه بر این، خطای پیش‌بینی مدل‌های توسعه‌یافته در گام‌های اولیه کمتر است که از نظر کاربردی بسیار مطلوب است.

در روش توسعه‌یافته، امکان پیش‌بینی سرعت حتی در صورت عدم وجود برخی از خودروهای جلویی نیز وجود دارد. نتایج نشان می‌دهد که در حالتی که هیچ خودروی جلویی وجود نداشته باشد، پیش‌بینی با روش پیشنهادی رفتاری مشابه مدل شتاب ثابت یا شتاب متغیر، اما با دقت بالاتر، دارد. در واقع، به دلیل نبود تاریخچه‌ی سرعت خودروی جلویی، تغییرات روند سرعت به‌طور کامل قابل پیش‌بینی نیست؛ با این حال، مدل‌های توسعه‌یافته در این شرایط نیز عملکرد قابل قبولی نشان داده‌اند.

در بین مدل‌های بررسی‌شده، مدل واحد بازگشتی دروازه‌ای بهترین عملکرد و کمترین میزان خطای پیش‌بینی را دارد. میانگین خطای مطلق پیش‌بینی این مدل در افق شش ثانیه‌ای برابر با $0/2410$ و در افق دو ثانیه‌ای برابر با $0/0578$ متر بر ثانیه است. همچنین خطای پیش‌بینی روش پیشنهادی در افق شش ثانیه‌ای نسبت به مدل‌های سرعت ثابت، شتاب ثابت و شتاب متغیر به ترتیب $58/12$ ، $33/81$ و $24/30$ درصد کمتر است. همچنین نسب به حالت بدون استفاده نرمال‌سازی ویژه، خطای پیش‌بینی $13/18$ درصد کمتر است. در آینده این کار به چند صورت می‌تواند بسط داده شود. در این کار اثر استفاده از ویژگی‌های دیگر مانند فاصله بین خودورها یا شتاب آنها بررسی نشد. در آینده می‌تواند برای بسط این کار اثر عوامل مختلط بر پیش‌بینی سرعت بررسی شود. همچنین می‌توان اثر ترکیب این روش با روش‌های کنترل‌پیش‌بین را مورد بررسی قرار داد. روش ارائه شده روی بهترین داده در دسترس بررسی شد. برای بررسی بیشتر می‌توان این روش ارائه شده را روی مجموعه داده دیگر آزمایش کرد.

۶- فهرست علائم

علائم انگلیسی

a	شتاب
b	بایاس یک لایه کاملاً متصل
C	حالت داخلی یک سلول حافظه کوتاه طولانی مدت
\tilde{C}	مقدار گره ورودی حافظه کوتاه طولانی مدت
f	تابع فعالسازی یک لایه کاملاً متصل در شبکه عصبی عمیق
F	مقدار خروجی دروازه فراموشی حافظه کوتاه طولانی مدت
h	بردار مقدار لایه پنهان یک لایه کاملاً متصل در شبکه عصبی عمیق
H	بردار حالت پنهان در حافظه کوتاه طولانی مدت و واحد بازگشتی دروازه‌ای
\hat{H}	کاندیدای حالت پنهان در واحد بازگشتی دروازه‌ای
I	مقدار دروازه ورودی در حافظه کوتاه طولانی مدت
O	مقدار دروازه خروجی در حافظه کوتاه طولانی مدت
R	مقدار دروازه بازنشانی
v	سرعت خودرو
\bar{v}	سرعت نرمال شده خودرو
W	ماتریس وزن یک لایه کاملاً متصل
X	داده ورودی به مدل‌های پیش‌بینی کننده سرعت
y	مقدار واقعی یک رویداد پیش‌بینی شده
\hat{y}	مقدار پیش‌بینی شده یک رویداد
Y	مقدار خروجی مدل‌های پیش‌بینی کننده سرعت
Z	بردار دروازه به روزرسانی در واحد بازگشتی دروازه‌ای

علائم یونانی

σ	تابع سیگموئید
ΔT	گام زمانی

زیرنویس

C	مربوط به حالت داخلی سلول حافظه کوتاه طولانی مدت
$const$	یک مقدار ثابت در گام زمانی فعلی
f	مربوط به دوازه فراموشی سلول حافظه کوتاه طولانی مدت
h	مربوط به کاندیدای حالت پنهان واحد بازگشتی دروازه‌ای
i	مربوط به دروازه ورودی حافظه کوتاه طولانی مدت
k	گام زمانی k ام در داده یا مقادیر پیش‌بینی شده
O	مربوط به دروازه خروجی حافظه کوتاه طولانی مدت
r	مربوط به دروازه بازنشانی واحد بازگشتی دروازه‌ای

مربوط به دروازه به روزرسانی واحد بازگشتی دروازه‌ای	<i>z</i>
وزن حالت پنهان قبلی در حالت داخلی سلول حافظه کوتاه طولانی مدت	<i>hc</i>
وزن حالت پنهان قبلی در دروازه فراموشی حافظه کوتاه طولانی مدت	<i>hf</i>
وزن حالت پنهان قبلی در کاندیدای حالت پنهان واحد بازگشتی دروازه‌ای	<i>hh</i>
وزن حالت پنهان قبلی در دروازه ورودی حافظه کوتاه طولانی مدت	<i>hi</i>
وزن حالت پنهان قبلی در دروازه خروجی حافظه کوتاه طولانی مدت	<i>ho</i>
وزن حالت پنهان قبلی در دروازه بازنشانی واحد بازگشتی دروازه‌ای	<i>hr</i>
وزن حالت پنهان قبلی در دروازه به روزرسانی واحد بازگشتی دروازه‌ای	<i>hz</i>
گام زمانی t ام در پردازش دنباله‌ای از داده‌ها در شبکه‌های عصبی بازگشتی	<i>t</i>
خودرو هدف	<i>T</i>
وزن داده ورودی در حالت داخلی سلول حافظه کوتاه طولانی مدت	<i>x_c</i>
وزن داده ورودی در دروازه فراموشی حافظه کوتاه طولانی مدت	<i>x_f</i>
وزن داده ورودی در کاندیدای حالت پنهان واحد بازگشتی دروازه‌ای	<i>x_h</i>
وزن داده ورودی در حالت داخلی سلول حافظه کوتاه طولانی مدت	<i>x_i</i>
وزن داده ورودی در حالت داخلی سلول حافظه کوتاه طولانی مدت	<i>x_o</i>
وزن داده ورودی در دروازه بازنشانی واحد بازگشتی دروازه‌ای	<i>x_r</i>
وزن داده ورودی در دروازه به روزرسانی واحد بازگشتی دروازه‌ای	<i>x_z</i>

Intelligent vehicle velocity forecasting based on the real highway data

Mostafa Khanalipour, Mohsen Mohammadi¹, Hossein Mohammadi

School of Mechanical Engineering, Shiraz University, Shiraz, Iran

ABSTRACT

Accurate vehicle velocity forecasting reduces energy consumption and improves the safety of intelligent vehicles. Considering the available data in intelligent transportation systems and the capability of deep neural networks to exploit these data, an intelligent velocity forecasting method based on deep neural networks is proposed. Velocity forecasting is performed using the velocity history of the target vehicle and its preceding vehicles. To enhance forecasting accuracy, a novel normalization method for vehicle velocity data is introduced, which leads to a reduction in prediction error. Furthermore, to address practical driving challenges, uncertainty in the available length of velocity history and the number of preceding vehicles is incorporated into the proposed method. In this study, velocity forecasting is conducted with a very short time step, which is more challenging and has not been reported in previous studies. The velocity forecasting models are trained using real-world highway data. The results demonstrate that the proposed method achieves higher accuracy, particularly in the initial time steps, and is free of offset. Moreover, unlike existing studies, velocity forecasting remains feasible even in the absence of a preceding vehicle, and the prediction accuracy under this condition exceeds that of conventional analytical methods. The mean absolute prediction error over a six-second horizon using the proposed method is 0.2410 m/s, representing the prediction error reduction of at least a 29.30% compared to analytical models and at least 13.18% compared to cases without the proposed normalization.

KEYWORDS

Vehicle velocity forecasting, Machine learning, Data normalization, Connected automated vehicles, Deep learning

۷-مراجع

[1] X. Li, W. Lin, Y. Jin, D. Chen, T. chen, Dynamic Energy Management Strategy of Hybrid Electric Vehicles based on Velocity Prediction, IFAC-PapersOnLine, 54(10) (2021) 363-369.

¹ Corresponding Author: Email: mohsen_mohammadi@shirazu.ac.ir

- [2] C. Sun, X. Hu, S.J. Moura, F. Sun, Velocity Predictors for Predictive Energy Management in Hybrid Electric Vehicles, *IEEE Transactions on Control Systems Technology*, 23(3) (2015) 1197-1204.
- [3] Y. Jia, C. Cai, D. Görge, An LSTM-Based Speed Predictor Based on Traffic Simulation Data for Improving the Performance of Energy-Optimal Adaptive Cruise Control, in: 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), 2020, pp. 1-7.
- [4] B. Li, W. Zhuang, B. Chen, H. Zhang, S. Yu, J. Zhang, G. Yin, Predictive Ecological Cooperative Control of Electric Vehicles Platoon on Hilly Roads, *Chin. J. Mech. Eng.*, 38(1) (2025) 37.
- [5] T. Eرسال, I. Kolmanovsky, N. Masoud, N. Ozay, J. Scruggs, R. Vasudevan, G. Orosz, Connected and automated road vehicles: state of the art and future challenges, *Vehicle System Dynamics*, 58(5) (2020) 672-704.
- [6] E. Hyeon, Y. Kim, N. Prakash, A.G. Stefanopoulou, Influence of Speed Forecasting on the Performance of Ecological Adaptive Cruise Control, in: ASME 2019 Dynamic Systems and Control Conference, American Society of Mechanical Engineers Digital Collection, 2019.
- [7] J.J.Q. Yu, Online Traffic Speed Estimation for Urban Road Networks with Few Data: A Transfer Learning Approach, 2019 IEEE Intelligent Transportation Systems Conference (ITSC), (2019).
- [8] J.B. Kenney, Dedicated Short-Range Communications (DSRC) Standards in the United States, *Proceedings of the IEEE*, 99(7) (2011) 1162-1182.
- [9] S. Lefèvre, C. Sun, R. Bajcsy, C. Laugier, Comparison of parametric and non-parametric approaches for vehicle speed prediction, in: 2014 American Control Conference, 2014, pp. 3494-3499.
- [10] Z. Zhou, Z. Yang, Y. Zhang, Y. Huang, H. Chen, Z. Yu, A comprehensive study of speed prediction in transportation system: From vehicle to traffic, *iScience*, 25(3) (2022) 103909.
- [11] K. Liu, Z. Asher, X. Gong, M. Huang, I. Kolmanovsky, Vehicle velocity prediction and energy management strategy part 1: Deterministic and stochastic vehicle velocity prediction using machine learning, SAE Technical Paper, 2019.
- [12] S.D. Cairano, D. Bernardini, A. Bemporad, I.V. Kolmanovsky, Stochastic MPC With Learning for Driver-Predictive Vehicle Control and its Application to HEV Energy Management, *IEEE Transactions on Control Systems Technology*, 22(3) (2014) 1018-1031.
- [13] M. Wegener, F. Herrmann, L. Koch, R. Savelsberg, J. Andert, Longitudinal Vehicle Motion Prediction in Urban Settings With Traffic Light Interaction, *IEEE Transactions on Intelligent Vehicles*, 8(1) (2023) 204-215.
- [14] E. Hyeon, D. Shen, D. Karbowski, A. Rousseau, Forecasting Short to Mid-Length Speed Trajectories of Preceding Vehicle Using V2X Connectivity for Eco-Driving of Electric Vehicles, *SAE Int. J. Adv. & Curr. Prac. in Mobility*, 3(4) (2021) 1801-1809.
- [15] E. Hyeon, Y. Kim, T. Eرسال, A. Stefanopoulou, Data-Driven Forgetting and Discount Factors for Vehicle Speed Forecasting in Ecological Adaptive Cruise Control, *J. Dyn. Sys., Meas., Control*, 144(1) (2022).
- [16] E. Hyeon, D. Karbowski, A. Rousseau, Potential Energy Saving by Different Cooperative Driving Automation Classes in Car-Following Scenarios *, in: 2023 American Control Conference (ACC), 2023, pp. 1313-1318.
- [17] J. Guo, H. He, C. Sun, ARIMA-Based Road Gradient and Vehicle Velocity Prediction for Hybrid Electric Vehicle Energy Management, *IEEE Transactions on Vehicular Technology*, 68(6) (2019) 5309-5320.
- [18] C. Pan, A. Huang, J. Wang, L. Chen, J. Liang, W. Zhou, L. Wang, J. Yang, Energy-optimal adaptive cruise control strategy for electric vehicles based on model predictive control, *Energy*, 241 (2022) 122793.

- [19] C. Pan, Y. Li, J. Wang, J. Liang, H. Jinyama, Research on multi-lane energy-saving driving strategy of connected electric vehicle based on vehicle speed prediction, *Green Energy and Intelligent Transportation*, 2(6) (2023) 100127.
- [20] J. Wang, Z. Li, C. Pan, Energy-efficient trajectory planning with curve splicing based on PSO-LSTM prediction, *Control Engineering Practice*, 150 (2024) 106009.
- [21] S.K. Chada, D. Görges, A. Ebert, R. Teutsch, Deep Learning-Based Vehicle Speed Prediction for Ecological Adaptive Cruise Control in Urban and Highway Scenarios, *IFAC-PapersOnLine*, 56(2) (2023) 1107-1114.
- [22] M.F. Ozkan, Y. Ma, Eco-Driving of Connected and Automated Vehicle With Preceding Driver Behavior Prediction, *J. Dyn. Sys., Meas., Control*, 143(1) (2021) 011002.
- [23] F. Zhang, J. Xi, R. Langari, Real-Time Energy Management Strategy Based on Velocity Forecasts Using V2V and V2I Communications, *IEEE Transactions on Intelligent Transportation Systems*, 18(2) (2017) 416-430.
- [24] E. Hyeon, Speed Forecasting Strategies for the Energy-Optimal Car-Following of Connected and Automated Vehicles, Thesis, 2022.
- [25] R. Krajewski, J. Bock, L. Kloeker, L. Eckstein, The highD Dataset: A Drone Dataset of Naturalistic Vehicle Trajectories on German Highways for Validation of Highly Automated Driving Systems, in: 2018 21st International Conference on Intelligent Transportation Systems (ITSC), 2018, pp. 2118-2125.
- [26] A. Zhang, Z.C. Lipton, M. Li, A.J. Smola, Dive into deep learning, Cambridge University Press, 2023.
- [27] M. Vajedi, N.L. Azad, Ecological Adaptive Cruise Controller for Plug-In Hybrid Electric Vehicles Using Nonlinear Model Predictive Control, *IEEE Transactions on Intelligent Transportation Systems*, (2016).