

Generování multivariantních časových řad pro HIL simulace

Michal Křepelka <michal.krepelka@tul.cz>, Jiří Vraný, Pavel Satrapa

Tato práce se zaměřuje na generování multivariantních časových řad pro Hardware-in-the-loop (HIL) simulaci digitálního průjezdu trasy zadané pomocí posloupnosti GPS souřadnic. Pro zadanou trasu je vytvořen syntetický rychlostní profil, ke kterému jsou následně vygenerovány další veličiny (atributy) testovacího vozidla: tlak v brzdách, procento stlačení plynového pedálu, zařazený rychlostní stupeň a odpovídající otáčky motoru. Za účelem generování zmiňovaných atributů byly natrénovány modely strojového učení. V případě rychlosti byl model založen na Long-Short Term Memory (LSTM) neuronové síti. Pro ostatní atributy byl použit Multilayer Perceptron (MLP) a LSTM. Stěžejní je možnost digitálně projet neznámou trasu, tj. trasu, na které nebyly modely natrénovány.

Klíčová slova: MLP, LSTM, syntetická data, HIL

Úvod

Cílem práce bylo vytvoření modelů strojového učení pro generování rychlostního profilu automobilu a k němu odpovídajícího průběhu tlaku v brzdách, procenta stlačení plynového pedálu, zařazeného rychlostního stupně a otáček motoru na trasu zadané pomocí posloupnosti GPS souřadnic.

Motivací byla digitalizace integračního testování, které je důležitou součástí vývoje automobilu. V současné době je jedním ze způsobů testování, které provádí naše partnerská společnost, testování v terénu. Testovaná komponenta se v takovém případě fyzicky připojí do automobilu, se kterým se provádí testovací jízdy. Testování v terénu je časově, personálně a finančně náročné a umožňuje testovat pouze omezené množství scénářů. Vhodným řešením zmíněného problému je využití simulace.

Trendem v automobilovém průmyslu jsou podle [1] koncepty HIL a Digital Twin (DT). Pro simulace využívané v rámci konceptů HIL a DT je společná potřeba generovat syntetická data. Tato práce se zaměřuje na digitalizaci integračního testování komponent jako jsou počítače v přístrojové desce (infotainment, navigace) a řídicí jednotky. Komunikace s těmito komponentami je řešena pomocí Controller Area Network (CAN) sběrnice, a tedy se práce zaměřuje na možnosti generování dat posílaných po CAN sběrnici, tj. problém je definován jako generování multivariantních časových řad vhodných pro HIL nebo DT.

Metodika

Při generování rychlosti je třeba rozlišit, jestli se jedná o rychlost krátkodobou nebo dlouhodobou. Krátkodobou rychlostí rozumíme jako v případě [2] predikci v časovém horizontu 10, 20 nebo 30 sekund. Podle této práce nejlepších výsledků dosahuje LSTM využívající k predikci mapových podkladů z OpenStreetMap (OSM) a sklonu vozovky. Dlouhodobou rychlostí pak může být predikce rychlosti na celé předem známé trase. Jako příklad lze uvést práci [3], která pro predikci dlouhodobé rychlosti používá kombinaci Feed-forward neuronové sítě a LSTM. Práce je omezená na Čínu a srovnání je tak komplikované.

K natrénování rychlostního modelu byl použit dataset obsahující 22179,5km jízd po České republice, které byly vzorkovány každých 0,1 sekundy. S pomocí Open Source Routing Machine (OSRM) byl proveden map-matching a naměřené jízdy byly obohaceny o geografická data z OSM. Získané OSM identifikátory jsou dále použity pro přidání elevace a sklonu vozovky.

Vhodným řešením pro generování rychlostního profilu se z dostupné literatury jeví použití obousměrného LSTM, které odpovídá situaci, kdy řidič zná už ujetou cestu a dopředu vidí, co ho čeká. Navržený model se skládá z 5 vrstev obousměrného LSTM a lineární vrstvy o šířkách 512. Jako základní rychlostní model pak byl zvolen OSRM, které bylo s LSTM srovnáno.

Pro generování atributů závislých na rychlosti nebyla známa žádná publikace, která by se věnovala použití modelů strojového učení pro predikci zmíněných atributů. Jako základní model

tak byl zvolen MLP, který byl srovnán s modelem založeným na obousměrném LSTM. Navržené LSTM modely využívají 2 vrstvy obousměrného LSTM a 2 vrstvy ReLu-Linear, tj. kombinaci ReLu (Rectified Linear Unit) a lineární vrstvy, o šířkách 256 pro tlak v brzdách, stlačení plynového pedálu a otáčky motoru. Model zařazeného rychlostního stupně obsahuje 2 vrstvy obousměrného LSTM a pouze 1 vrstvu ReLu-Linear a je šířky 160. MLP modely využívají shodné architektury 1 lineární vrstvy a 3 vrstev ReLu-Linear se šířkou 256.

Pro trénování modelů atributů závislých na rychlosti bylo zvoleno jedno konkrétní vozidlo Škoda Karoq s jedním řidičem a dataset tak byl omezen na 13337,85 km. Díky omezenému kontextu pak musel být na MLP predikci použit klouzavý průměr a predikce zařazené rychlosti musela také být analogicky vyhlazena.

Výsledky a diskuze

Cílem práce [4] bylo vytvořit model, který by generoval realistický rychlostní profil. Prvním krokem bylo objektivní vyhodnocení modelů s použitím dvou metrik: Wassersteinovy vzdálenosti a Maximum Mean Discrepancy. Tímto srovnáním bylo zjištěno, že rychlostní profil vygenerovaný OSRM není realistický. Dále pak bylo přikročeno k subjektivnímu vyhodnocení uživateli testovací platformy, kteří nedokázali spolehlivě rozlišit, který rychlostní profil je reálný a který je generovaný LSTM modelem. Navržený LSTM model tak lze považovat za realistický.

Cílem práce [5] bylo vygenerování průběhu tlaku v brzdách, procenta stlačení plynového pedálu, zařazeného rychlostního stupně a otáček motoru pro zadaný rychlostní profil. Pro srovnání kvality predikce MLP a LSTM modelů pro jednotlivé atributy byly použity dvě metriky: Mean Absolute Error (MAE) a Root Mean Squared Error (RMSE). Jako vstup modelů byly použity skutečně naměřené hodnoty. V tomto scénáři dosahovaly všechny LSTM modely lepších hodnot pro obě metriky a zároveň subjektivně dobře odpovídali skutečně naměřeným hodnotám. I přes vyšší MAE a RMSE však byly MLP modely ze subjektivního hlediska také přijatelné a dobře zachycovaly trend.

Závěr

V rámci výzkumu se podařilo vytvořit zadané modely strojového učení vhodné pro použití v HIL simulacích, které nahradí testování v terénu. LSTM model rychlostního profilu je dostatečně realistický, aby ho operátor testovací platformy nedokázal

odlišit od rychlostního profilu naměřeného při testovací jízdě. Navržené LSTM modely dobře predikují atributy závislé na rychlosti a dosahují lepších hodnot MAE a RMSE než MLP modely.

Do budoucna by bylo vhodné prozkoumat možnosti generování rychlostního profilu pomocí transformerů, které jsou současný trendem. Navržené řešení pro stejný vstup vždy vygeneruje stejný výstup, tedy další výzkum by se měl zaměřit na Generative adversarial networks, které je možné inicializovat.

Poděkování

Tato práce byla podpořena z projektu Studentské grantové soutěže (SGS) na Technické univerzitě v Liberci v roce 2023 a Technologickou agenturou ČR projektem CK02000136 "Virtual Convoy - komplexní prostředí pro testování komunikačních systémů CAR2X".

Reference

- [1] IBRAHIM, Mahmoud et al. Overview on Digital Twin for Autonomous Electrical Vehicles Propulsion Drive System. Sustainability. 2022, roč. 14, č. 2. issn 2071-1050. Dostupné z doi: [10.3390/su14020601](https://doi.org/10.3390/su14020601).
- [2] DEUFEL, Felix et al. Velocity Prediction Based on Map Data for Optimal Control of Electrified Vehicles Using Recurrent Neural Networks (LSTM). Vehicles. 2022, roč. 4, č. 3, s. 808-824. issn 2624-8921. Dostupné z doi: [10.3390/vehicles4030045](https://doi.org/10.3390/vehicles4030045).
- [3] YUFANG, Li, Chen MINGNUO a Zhao WANZHONG. Investigating long-term vehicle speed prediction based on BP-LSTM algorithms. IET Intelligent Transport Systems. 2019, roč. 13, č. 8, s. 1281-1290. Dostupné z doi: [10.1049/iet-its.2018.5593](https://doi.org/10.1049/iet-its.2018.5593).
- [4] VRANY, Jiri, Michal KREPELKA a Matej CHUMLEN. Generating Synthetic Vehicle Speed Records Using LSTM. In: MAGLOGIANNIS, Ilias et al. (ed.). Artificial Intelligence Applications and Innovations. Cham: Springer Nature Switzerland, 2023, s. 125-136. isbn 978-3-031-34111-3. Dostupné z doi: [10.1007/978-3-031-34111-3_12](https://doi.org/10.1007/978-3-031-34111-3_12).
- [5] KREPELKA, Michal a Jiri VRANY. Synthesizing Vehicle Speed-Related Features with Neural Networks. Vehicles. 2023, roč. 5, č. 3, s. 732-743. issn 2624-8921. Dostupné z doi: [10.3390/vehicles5030040](https://doi.org/10.3390/vehicles5030040).