

CLASSIFICAZIONE DELLO STILE DI GUIDA: UNO STRUMENTO PER LA PREVENZIONE DEGLI INCIDENTI STRADALI

ABSTRACT

Gli incidenti stradali sono un fenomeno molto frequente negli Stati Uniti. Una delle cause di questo problema è l'assunzione di uno stile di guida aggressivo. Riuscire a identificare comportamenti aggressivi alla guida diventa quindi una sfida importante per la prevenzione degli incidenti.

L'obiettivo del presente lavoro è quello di costruire e testare una rete neurale artificiale in grado di classificare lo stile di guida di un autista sulla base dei dati di accelerazione e rotazione raccolti durante la marcia, grazie ad alcuni sensori del suo smartphone. Inoltre, si è cercato di capire quali sono le principali caratteristiche di un conducente aggressivo in modo da poter prevedere delle strategie che limitino questo tipo di comportamento.

INTRODUZIONE

Negli Stati Uniti, gli incidenti stradali rappresentano un grave problema di sicurezza. Solo nel 2016 ne sono stati registrati circa 6 milioni, per un totale di 37461 vittime (Kalra & Groves, 2017). Uno dei fattori determinanti nel verificarsi degli incidenti stradali è uno stile di guida aggressivo (Paleti et al., 2010). La guida aggressiva viene definita come: "la guida di un veicolo a motore in modo tale da mettere in pericolo o da poter mettere in pericolo persone o cose" (Shinar, 1998).

Data la sua rilevanza, riuscire a classificare lo stile di guida di un autista, diventa una sfida molto importante in ambito di prevenzione. In questo report assumiamo che uno stile di guida aggressivo sia determinato da tre fattori: l'eccesso di velocità, le frenate brusche e le svolte improvvise a destra o a sinistra. Tali comportamenti possono essere misurati sfruttando l'accelerometro e il giroscopio di uno smartphone Android (Cojocar & Popescu, 2022).

Il presente lavoro, quindi, mira a implementare una rete neurale artificiale che sia in grado di apprendere dei pattern presenti nei dati registrati durante la guida tramite accelerometro e giroscopio. In questo modo dovrebbe essere in grado di classificare correttamente dati mai visti con un'accuratezza significativamente maggiore rispetto a quella del modello nullo. Questo strumento potrebbe quindi aiutare un governo, o un qualsiasi ente, a mettere in atto delle misure preventive per contrastare il fenomeno degli incidenti stradali.

METODOLOGIA

In letteratura troviamo diversi lavori che cercano di costruire un dataset per allenare e testare una rete neurale artificiale in grado di classificare il comportamento alla guida.

Il dataset¹ scelto per la realizzazione di questo report contiene 6728 registrazioni dell'accelerazione e della rotazione del veicolo lungo gli assi x, y e z. Tali registrazioni sono state raccolte durante diverse sessioni di guida di una Dacia Sandero lungo due diversi percorsi. Lo smartphone utilizzato per la registrazione è un Samsung Galaxy S10. I dati sono stati divisi in training set (3644 istanze) e test set (3084 istanze). Le colonne del dataset sono otto: accelerazione sull'asse x, accelerazione sull'asse y, accelerazione sull'asse z, rotazione sull'asse x, rotazione sull'asse y, rotazione sull'asse z e timestamp. Quest'ultimo dato indica il momento specifico in cui è stata effettuata la registrazione. Successivamente, gli autori hanno aggiunto un'ottava caratteristica, chiamata classe, che rappresenta le tre

¹ <https://www.kaggle.com/datasets/outofskills/driving-behavior>

tipologie di stile di guida: aggressive, normal e slow (Cojocaru & Popescu, 2022). Essi definiscono le tre categorie in questo modo:

- aggressive – svolte improvvise a destra o a sinistra, accelerazioni e frenate brusche;
- normal – andamento medio, senza comportamenti estremi;
- slow – mantenimento di una velocità inferiore alla media.

Per l'implementazione della rete neurale artificiale è stato realizzato un notebook² di Mathematica, un software di calcolo simbolico e numerico sviluppato dall'azienda Wolfram Research. La versione di Wolfram Cloud³ utilizzata per la realizzazione del report non consente di effettuare computazioni troppo onerose. Per ovviare a questo problema, sulla base dei dati a disposizione, è stato creato un dataset bilanciato composto da 300 righe, 100 per ognuna delle tre classi (aggressive, normal, slow). Inoltre, è stata rimossa la colonna relativa al timestamp in quanto relativa all'esperimento specifico degli autori del dataset e non utile a classificare lo stile di guida. L'istante in cui viene effettuata la registrazione può addirittura risultare forviante ai fini dell'addestramento. Dato che le registrazioni del dataset originale sono state effettuate anche durante la stessa sessione di guida, un autista che ha assunto un determinato comportamento ha dato origine, in istanti ravvicinati, a diverse righe. Ciò può portare la rete a classificare i dati solo in base al momento in cui sono stati registrati e non secondo l'accelerazione e la rotazione del veicolo. Se questo meccanismo può funzionare con il dataset originale è chiaro che non può essere mantenuto nell'ottica di creare un sistema per la prevenzione degli incidenti che, invece, deve basarsi sui dati di accelerazione e rotazione raccolti durante la marcia.

Data la dimensione ridotta del dataset è stata utilizzata una cross-validation a 5 fold (Yadav & Shukla, 2016). Pertanto, il dataset è stato diviso in 5 fold uguali sui quali sono stati effettuati addestramento e test in 5 iterazioni. Ad ogni iterazione, è stato lasciato un fold per il test mentre il modello è stato allenato sui fold rimanenti. Per ogni iterazione, sul test set, sono state calcolate accuracy, precision e recall. Successivamente, è stata calcolata l'accuracy media (\bar{a}) con il relativo errore standard (σ) in modo da poter applicare la regola dei due sigma. Essa ci dice che, se l'accuratezza del modello nullo è inferiore a $\bar{a} - 2 * \sigma$, allora è possibile asserire, con un margine di rischio del 5%, che la rete neurale si comporta meglio del modello nullo ed è dunque in grado di imparare dai dati.

Infine, è stata calcolata l'importanza di ciascuna feature per la classificazione dello stile di guida aggressive. Questi dati possono fornire un'interessante indicazione degli aspetti su cui concentrarsi per prevenire gli incidenti stradali.

RISULTATI

Ad ogni iterazione della cross-validation sono state calcolate accuracy, precision e recall. Di seguito i valori medi di precision (\bar{p}) e recall (\bar{r}) per ognuna delle tre classi:

1. aggressive:
 - a. $\bar{p}_{aggressive} = 0.49 \pm 0.08$;
 - b. $\bar{r}_{aggressive} = 0.43 \pm 0.06$;
2. normal:
 - a. $\bar{p}_{normal} = 0.39 \pm 0.07$;
 - b. $\bar{r}_{normal} = 0.38 \pm 0.09$;

² <https://www.wolframcloud.com/obj/ae901196-4ccd-43ca-8f82-eb1892c9dcec>

³ <https://www.wolframcloud.com/>

3. slow:

- a. $\bar{p}_{slow} = 0.50 \pm 0.05$;
- b. $\bar{r}_{slow} = 0.55 \pm 0.05$.

L'accuracy media (\bar{a}), invece, è risultata essere $\bar{a} = 0.46 \pm 0.05$. Dato che il dataset è bilanciato, prendiamo come modello nullo il classificatore random. La sua precisione si calcola attraverso la formula $a_{random} = \frac{1}{c}$, dove c rappresenta il numero di classi. In questo caso abbiamo tre classi, quindi l'accuratezza del classificatore random sarà pari a $a_{random} = 1/3 = 0.33$.

Applicando la regola dei due sigma ci rendiamo conto che $a_{random} < \bar{a} - 2 * \sigma$ (cioè, $0.33 < 0.36$). Pertanto, è possibile asserire, con un margine di rischio del 5%, che la rete neurale si comporta meglio del modello nullo ed è dunque in grado di imparare dai dati.

Dato che uno degli obiettivi del presente report è quello di fornire uno strumento utile alla prevenzione degli incidenti stradali, diventa interessante capire quali sono le feature più rilevanti nel determinare uno stile di guida aggressivo. In Figura 1 è possibile visualizzare queste informazioni attraverso un grafico a barre.

Notiamo che, per la classe aggressiva, l'accelerazione lungo l'asse Y è una feature particolarmente rilevante ai fini della classificazione. Essa rappresenta le forze laterali che colpiscono il veicolo durante la marcia. Più sono presenti, più il guidatore sta effettuando accelerazioni e svolte improvvise (Cojocar & Popescu, 2022).

Per prevenire questo comportamento si potrebbero, innanzitutto, mettere in atto delle misure ambientali. Nello specifico, sarebbe utile progettare le strade in modo che siano il più diritte possibile, senza troppe curve. Ciò servirebbe ad evitare che il guidatore continui ad accelerare e frenare, effettuando anche delle svolte brusche.

Ovviamente questa soluzione può essere utilizzata solo nel momento in cui si progetta una nuova strada. Per quanto riguarda quelle già esistenti, si potrebbe integrare una nuova funzionalità all'interno di applicazioni per la mobilità come Google Maps. Durante la navigazione si potrebbero raccogliere i dati della marcia; quando il valore dell'accelerazione sull'asse delle y supera una determinata soglia si potrebbero inviare degli avvisi acustici che indichino al conducente che sta assumendo un comportamento pericoloso per sé stesso e per gli altri utenti della strada.

In alternativa, visto che le automobili stanno diventando sempre più tecnologiche, si potrebbero prevedere dei sistemi che correggano lo stile di guida dell'autista nel momento in cui si registrano dei valori di accelerazione elevati lungo l'asse delle y .

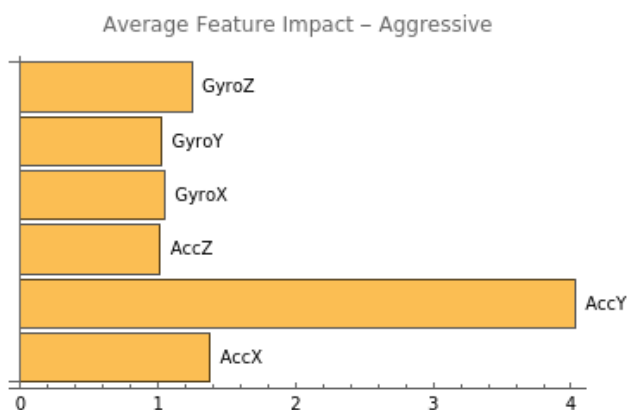


Figura 1: importanza delle feature per la classificazione dello stile di guida aggressivo.

REFERENZE

1. Kalra, N., & Groves, D. G. (2017). *The enemy of good: Estimating the cost of waiting for nearly perfect automated vehicles*. Rand Corporation.
2. Paleti, R., Eluru, N., & Bhat, C. R. (2010). Examining the influence of aggressive driving behavior on driver injury severity in traffic crashes. *Accident Analysis & Prevention*, 42(6), 1839-1854.
3. Shinar, D. (1998). Aggressive driving: the contribution of the drivers and the situation. *Transportation Research Part F: traffic psychology and behaviour*, 1(2), 137-160.
4. Cojocaru, I., & Popescu, P. S. Building a Driving Behaviour Dataset.
5. Yadav, S., & Shukla, S. (2016, February). Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In *2016 IEEE 6th International conference on advanced computing (IACC)* (pp. 78-83). IEEE.