

Zaznavanje manevrov pri voznikih

Miloš Antić, Goran Andonovski

Univerza v Ljubljani, fakulteta za elektrotehniko, Tržaška cesta 25

E-pošta: ma4852@student.uni-lj.si, goran.andonovski@fe.uni-lj.si

Detection of driver maneuvers

Abstract. The main objective of the paper is to evaluate the performance of certain maneuvers of drivers and to compare them with known or correct maneuvers. In this way, we can create an expert system that can assess how well a driver performs a certain maneuver, such as a three-point turn, U-turn, etc. When creating the system, we will focus on methods for selecting the most influential components such as PCA and manually selecting components and comparing them. The quality of maneuvers will be evaluated using the KNN method, which means sorting with the k -nearest neighbors. The second step of the task is based on the learned/known models to detect which maneuver was performed. We will evaluate drivers' drive on the data we have collected on the simulator in Madrid.

1 Uvod

U-obrat in trikoračni obrat sta ena izmed mnogih manevrov, ki se jih vozniki poslužujemo v določenih okoliščinah. Trikoračni obrat je metoda obračanja vozila v nasprotno smer v omejenem, ozkem prostoru z manevriranjem naprej in nazaj. Sam proces trikoračnega obrata se začne z vožnjo čez cesto, kjer smo obrnjeni proti robu ceste nasprotnega pasu, nato zapeljemo vzvratno in obračamo zadek avtomobila proti izhodiščnemu zunanjemu robu ceste, nadaljujemo z vožnjo naprej v željeno smer, tj. smer nasprotna izhodiščni smeri. Drug princip obračanja vozila, tj. maneuver U-obrat, najpogosteje uporabljamo v križiščih, kjer imamo dovolj prostora za izvedbo manevra. Gre za obračanje vozila za 180 stopinj v smer, ki je nasprotna izhodiščni smeri potovanja. Tak maneuver se izvaja v obliki črke U, zato tudi takšno poimenovanje.


V tem članku bomo predstavili ekspertni sistem, ki bo voznikom pomagal pri učenju, in sicer tako, da bo ocenjeval njihovo vožnjo. Model bomo uporabili za napovedovanje manevrov oz. določanje, kateri maneuver se izvaja oz. se je izvedel. Da bi z modelom čim bolj pravilno napovedovali oz. ocenjevali manevre, je potrebno podatke o vožnji predhodno analizirati. V ta namen bomo vpeljali metodo PCA (angl. principal component analysis) oz. analizo glavnih komponent, da se znebimo redundantnosti podatkov in izločimo tiste podatke, ki ne vsebujejo veliko informacij o zadanem problemu. To pomeni, da imamo določene kolinearne komponente, kar pomeni, da za opis celotne informacije ne potrebujemo vseh komponent oz. spremenljivk [2].

Z izbranimi komponentami bomo z metodo k najbližjih sosedov vrednotili manevre voznikov [1].


Uspešnost razvrščevalnika bomo prikazali tudi grafično v obliki stolpčnih diagramov, s posebno vrsto ko-tigenčne matrike (angl. confusion matrix).

2 Podatki


Na razpolago imamo podatke o vožnji za pet voznikov, ki smo jih pridobili na simulatorju vožnje [3]. Vsak voznik je opravil trikoračni in U-obrat. Merili smo 16 atributov oz. signalov, npr. kot volana, število obratov na minuto, hitrost, prestava, pojemek, pospešek, itn. Pri uporabi PCA analize je priporočljivo da so podatki normirani in osredinjeni. Na sliki 1 je prikazan graf zaviranja (pri izvajanju trikoračnega manevra), ki vsebuje normirane vrednosti, medtem ko na sliki 2 in 3 vidimo, da hitrost avtomobila in število obratov na minuto, v setu podatkov, niso normirani.



Slika 1. Graf zaviranja




Slika 2. Graf hitrosti



Slika 3. Graf obratov na minuto

Število zajetih vzorcev merjenih atributov je od 5000 pa do 12000. Večje število vzorcev so naredili vozniki s trikoračnim obratom.

V setu podatkov imamo tudi dve vrednosti markerja, nič in ena. Marker ponazarja izvajanje določenega manevra, npr. U-obrat, trikoračni obrat itn. Marker z vrednostjo ena predstavlja trenutek, ko se manever izvaja, medtem ko marker z vrednostjo nič pa ko vozimo naravnost. Na sliki 3 je prikazan potek markerja za prvega in druga voznika, ko sta opravila U obrat. Z modro je označen potek za prvega voznika, z rdečo pa za drugega.



Slika 4. Graf markerja

Najboljšega izmed voznikov, tj. prvi voznik po dogovoru, bomo izbrali za učno množico pri učenju razvrščevalnika, ki temelji na metodi k-najbližjih sosedov. S podatki preostalih voznikov pa bomo vršili validacijo izvajanja manevrov.

3 Analiza in rezultati

Preizkušali smo tri načine določitve najvplivnejših komponent, in sicer z ročno izbiro vhodnih signalov oz.

komponent, s fiksnim številom izbranih komponent (PCA) in z izbiro komponent z varianco večjo, kot je določena meja. Analizirali smo tudi vpliv parametra k na delovanje razvrščevalnika.

3.1 Ročna izbira komponent

Pri ročni izbiri smo smiselno izbrali komponente, ki imajo normirane vrednosti in ki vsebujejo velik delež informacij o manevru. Uporaba metode ročne izbire je smiselna zato, ker nam je problem vožnje dobro znan in znamo iz izkušenj oceniti pomembne aspekte vožnje avtomobila. V tabeli 1 so prikazane uspešnosti izvajanja manevrov voznikov, ki smo jih vrednotili z učnim modelom voznika ena.

Tabela 1. Uspešnost voznikov-ročna izbira

	Število komponent		
	1	2	3
U-obrat	Uspešnost voznika v %		
Voznik 2	62,16	74,64	41,60
Voznik 3	60,89	69,56	41,58
Voznik 4	66,63	70,44	50,13
Voznik 5	66,77	75,11	40,22
3-koračen obrat			
Voznik 2	82,68	81,39	61,00
Voznik 3	79,42	78,13	64,85
Voznik 4	83,72	82,07	63,24
Voznik 5	88,20	87,94	62,10
	Število komponent		
	4	5	7
U-obrat	Uspešnost voznika v %		
Voznik 2	46,71	67,62	91,55
Voznik 3	51,93	66,01	89,66
Voznik 4	49,65	70,77	78,69
Voznik 5	39,85	77,09	78,84
3-koračen obrat			
Voznik 2	50,74	75,07	88,88
Voznik 3	53,35	71,05	87,89
Voznik 4	55,56	76,68	86,70
Voznik 5	53,24	74,60	93,90

Opazimo, da v nekaterih primerih z večanjem števila komponent upada uspešnost voznikov (vsi vozniki pri U in 3-koračnem obratu). S tem želimo pokazati, da pri napačni oz. nesmiselni izbiri komponent izgubimo veliko pomembnih informacij. V vseh šestih primerih smo za parameter k vzeli vrednost pet pri razvrščanju s KNN.

3.2 Fiksno število izbranih komponent

Izbiri najvplivnejših komponent smo v tem primeru prepustili metodi PCA in smo ji kot parameter vnesli željeno število vplivnih komponent, ki jih želimo poiskati. V tabeli 2 vidimo, da se z večanjem števila

komponent uspešnost voznikov povečuje. Opazimo, da se pri sedmih komponentah odstotek uspešnosti ustali in da z večanjem št. komponent ne vnašamo novih informacij. Za razvrščanje smo zopet uporabili pet najbližjih sosedov.

Tabela 2. Uspešnost voznikov-fiksno število

	Število komponent		
	1	2	3
U-obrat	Uspešnost voznika v %		
Voznik 2	78,62	77,15	86,96
Voznik 3	80,66	80,19	86,42
Voznik 4	74,70	77,57	81,90
Voznik 5	70,70	75,97	81,82
3-koračen obrat			
Voznik 2	81,23	85,05	88,61
Voznik 3	82,10	84,96	87,02
Voznik 4	80,22	81,67	82,05
Voznik 5	84,49	89,80	93,96
	Število komponent		
	4	5	7
U-obrat	Uspešnost voznika v %		
Voznik 2	90,13	90,53	91,55
Voznik 3	87,64	88,53	89,66
Voznik 4	77,22	79,13	78,69
Voznik 5	74,52	77,86	78,84
3-koračen obrat			
Voznik 2	88,09	89,05	88,88
Voznik 3	86,83	87,90	87,89
Voznik 4	82,71	85,82	86,70
Voznik 5	93,50	94,34	93,90

3.3 Izbira glede na delež informacij

Delež informacij je meja, ki določa število komponent, ki imajo varianco večjo od meje. Vrednosti meje smo izbirali v intervalu od 0,80 do 0,99. Zopet smo pri razvrščanju uporabili za parameter k vrednost pet. V tabeli 3 so podani rezultati vrednotenja. Rezultati vrednotenja se bistveno ne spreminjajo glede na delež informacij.


3.4 Analiza vpliva parametra k

V tabeli 4 vidimo, da se rezultati z večanjem k -ja bistveno ne spreminjajo. Najprej smo z metodo PCA izbrali sedem najvplivnejših komponent, nato pa analizirali KNN razvrševalnik oz. parameter k . Za potrebe razvrščanja je za dane podatke zadosti, če uporabimo uporabimo $k=1$. Za mero podobnosti pri razvrščanju uporabljamo evklidsko razdaljo. Na sliki 4 je prikazana matrika zamenjav, ki prikazuje rezultate za vrednotenje manevriranja drugega voznika glede na prvega voznika, pri izvedbi U-obrata (sedem komponent, $k=1$). Target Class predstavlja vrednosti markerja dejanskega poteka manevrov prvega voznika, Output Class pa predikcije oz. razvrščene vzorce voznika 2. Marker 0 smo napovedali pravilno v 2776-ih primerih, tj. 50,5 %, marker 1 pa v 2259-ih oz. 41,1 %.

Marker 0 je napovedan napačno v 155-ih (oz. 2,8%) primerih, marker 1 pa v 310-ih (oz. 5,6%).

Tabela 3. Uspešnost voznikov-delež informacij

	Delež informacij		
	0,80	0,85	0,89
U-obrat	Uspešnost voznika v %		
Voznik 2	73,76	73,76	73,76
Voznik 3	73,72	73,72	73,72
Voznik 4	68,17	68,17	68,17
Voznik 5	58,96	58,96	58,96
3-koračen obrat			
Voznik 2	61,05	61,05	61,05
Voznik 3	63,40	63,40	63,40
Voznik 4	61,83	61,83	61,83
Voznik 5	64,68	64,68	64,68
	Delež informacij		
	0,92	0,95	0,97
U-obrat	Uspešnost voznika v %		
Voznik 2	73,76	73,76	73,76
Voznik 3	73,72	73,72	73,72
Voznik 4	68,17	68,17	68,17
Voznik 5	58,96	58,96	58,96
3-koračen obrat			
Voznik 2	61,05	61,05	61,05
Voznik 3	63,40	63,40	63,40
Voznik 4	61,83	61,83	61,83
Voznik 5	64,68	64,68	64,68



Slika 5. Matrika zamenjav

3.5 Metoda in parametri

Glede na analizo in rezultate smo izbrali metodo ročne izbire vplivnih komponent. Izbrano število komponent je sedem. Do ugotovitve smo hitro prišli tudi zato, ker smo dobro seznanjeni s problemom vožnje. Izbrane komponente od šestnajstih so:

- kot volana,

- pospeševanje,
- zaviranje,
- pritisk sklopke,
- hitrost,
- število obratov na minuto,
- prestava.

Za parameter k pri metodi razvrščanja s k -najbližjimi sosedi smo izbrali vrednost ena. Izbrano metodo in parametre bomo upoštevali pri tvorbi modela za trikoračni in U-obrat.

Tabela 4. Analiza vpliva parametra k

	Parameter k			
	1	3	5	7
U-obrat	Uspešnost voznika v %			
Voznik 2	91,60	91,76	91,55	91,60
Voznik 3	89,24	89,31	89,66	89,75
Voznik 4	78,84	78,89	78,69	78,41
Voznik 5	78,36	78,59	78,84	78,93
3-koračen obrat				
Voznik 2	89,45	88,99	88,88	89,09
Voznik 3	87,65	87,63	87,89	87,59
Voznik 4	86,62	86,69	86,70	86,77
Voznik 5	93,89	94,05	93,90	93,96

4 Model trikoračnega in U-obrata

Z modeloma obeh obratov želimo razpoznavati, kateri od njiju se izvaja ali se je izvedel v določenem trenutku. Modela smo naredili tako, da smo ju učili na podatkih prvega voznika. Z modeloma napovedujemo potek markerja na podatkih ostalih voznikov in tako lahko preverjamo uspešnost napovedovanja obeh modelov glede na dejanske poteke markerjev preostalih voznikov. Za razvrščevalni algoritem smo zopet izbrali metodo KNN, kjer je parameter $k=1$ in mera podobnosti evklidska razdalja. Pri razvrščanju smo ponovno upoštevali sedem najvplivnejših komponent, omenjene v podpoglavju 4.5. V tabeli 5 imamo podane uspešnosti napovedovanja z modelom U-obrata.

Tabela 5. Napovedovanje z modelom U-obrata

	Uspešnost napovedovanja v %
U-obrat	
Voznik 2	0,9189
Voznik 3	0,8966
Voznik 4	0,8011
Voznik 5	0,7928
3- koračen obrat	
Voznik 1	0,6066
Voznik 2	0,6341
Voznik 3	0,6574
Voznik 4	0,6074
Voznik 5	0,6045

Vidimo, da lahko, glede na odstotek uspešnosti, brez problema razlikujemo med obratoma. Glede na odstotek uspešnosti napovedovanja (glej tabelo 6) z modelom za trikoračni obrat vidimo, da bi lahko prav tako razpoznavali kateri obrat se je izvedel, ker imamo v vseh primerih za izvedeni trikoračni obrat višji odstotek napovedi.

Tabela 6. Napovedovanje z modelom trikoračnega obrata

	Uspešnost napovedovanja v %
U-obrat	
Voznik 1	0,8782
Voznik 2	0,8653
Voznik 3	0,8466
Voznik 4	0,8737
Voznik 5	0,9041
3- koračen obrat	
Voznik 2	0,8942
Voznik 3	0,8766
Voznik 4	0,8895
Voznik 5	0,9504

5 Zaključek

Tekom analize komponent smo ugotovili, da lahko z metodo ročne izbire hitro določimo najvplivnejše komponente, kar nam omogoča predvsem dobro poznavanje problema vožnje avtomobila. Na drugi strani imamo metodo PCA, ki nam omogoča podrobnejšo analizo komponent. Rezultat obeh analiz je izbranih sedem komponent in vrednost parametra k za metodo k -najbližjih sosedov. Za izboljšanje rezultatov in razpoznavanje določenih manevrov z modeli bi morali analizirati dogajanje znotraj posameznega intervala manevriranja, ki ga določa marker. To je pomembno zaradi tega, ker so lahko zaporedja manevrov znotraj intervala različna.

Literatura

- [1] "k-nearest neighbors algorithm", Dostopno na: https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm, 30.1.2019 [Citirano: 14.2.2019]
- [2] I. Škrjanc: Inteligentni sistemi za podporo odločanju, Založba FE in FRI, Univerza v Ljubljani, Fakulteta za elektrotehniko, 2016.
- [3] Systems Technology. (2016). Car driving simulator & simulation software. Retrieved September 14, 2016, from <http://www.stisimdrive.com/products/simulation-systems/m100-series>