

UDK: 614.8:519.237.8

## PRIMENA K-MEANS METODE U DUBINSKOJ ANALIZI SAOBRAĆAJNIH NEZGODA

### USING K-MEANS CLUSTERING METHOD FOR IN-DEPTH ANALYSIS OF TRAFFIC ACCIDENT

Dalibor Pešić<sup>1</sup>, Milica Šelmić<sup>2</sup>, Dragana Macura<sup>3</sup> i Nenad Marković<sup>4</sup>

**Rezime:** Preventivno delovanje u bezbednosti saobraćaja podrazumeva kvalitetno prikupljanje podataka o faktorima koji utiču na nastanak i posledice saobraćajnih nezgoda. U praksi najbolje prikupljanje ovih podataka omogućava metod dubinskih analiza saobraćajnih nezgoda, na koji način se analizira uticaj puta i putne okoline, vozila i čoveka na saobraćajnu nezgodu. Kako je ovaj metod izuzetno složen i prevashodno skup za sprovođenje na širem području, to je neophodno razviti model koji bi prilagodio i pojednostavio sprovođenje dubinskih analiza u praksi, a na osnovu već postojećih podataka prikupljenih veštacanjem saobraćajnih nezgoda. U radu je razvijen model za grupisanje uzročnika saobraćajnih nezgoda na osnovu sličnosti karakteristika vozača, vozila i puta. Razvijeni model je zasnovan na metodu klasterovanja. Klasterovanje je proces klasifikacije objekata u različite grupe, skupove, tako da elementi jednog skupa imaju izvestan stepen približnosti i jednakosti meren po unapred definisanim kriterijumima. Sličnost elemenata se utvrđuje na osnovu njihovih rastojanja. Dva elementa su sličnija ukoliko se nalaze na bližem rastojanju. Najviše korišćena metoda klasterovanja je metod K-means, koji je ujedno korišćen kao alat u ovom radu.

**Ključне ријечи:** klaster analiza, veštacanje, saobraćajne nezgode, faktori

**Abstract:** Preventive actions in the field of road traffic safety implies quality collection of data related to factors which are contribute to traffic accident occurrence and its consequences. In practice, the best collection of these data is provided by using in-depth studies of traffic accidents, where influence of road, environment, vehicle and man (driver) is being analysed. Whereas this model is significantly complex and expensive for wide implementation, it is necessary to create a model capable to simplify and adapt in-depth studies process by using data already collected through traffic accident expertises. In this paper is developed model for grouping – clustering of the causes of traffic accidents, based on similarities of driver, vehicle and road. Clustering is process where different objects are classified in groups and sets in way to be equal or similar according to predefined criteria. Similarity of the elements is determined according to the „distance“ between them and two elements are more similar if the „distance“ is shorter. One of the most applied clustering methods is K-means and this method is explained in this paper.

**Keywords:** Cluster analysis, Traffic accident expertise, Traffic accident, Impact factors

#### 1. UVOD

Analizama saobraćajnih nezgoda može se doći do odgovarajućih zaključaka koji stvaraju mogućnost upravljanja stanjem bezbednosti saobraćaja. U zavisnosti od toga koji nivo analiza je neophodan upravljaču, moguće je sprovoditi različite vrste analiza saobraćajnih nezgoda. U naučnoj i stručnoj praksi poznate su analize saobraćajnih nezgoda koje se mogu podeliti u dve grupe: fenomenološke i etiološke. Fenomenološke analize saobraćajnih nezgoda imaju zadatak da utvrde globalne probleme bezbednosti saobraćaja i najčešće se sprovode korišćenjem tzv. zbirnih podataka o saobraćajnim nezgodama. Sa druge

---

<sup>1</sup> dr Dalibor Pešić, dipl. inženjer saobraćaja, docent, Saobraćajni fakultet u Beogradu, Vojvode Stepe 305, 11000 Beograd, Srbija, e-mail: [d.pesic@sf.bg.ac.rs](mailto:d.pesic@sf.bg.ac.rs)

<sup>2</sup> dr Milica Šelmić, dipl. inženjer saobraćaja, docent, Saobraćajni fakultet u Beogradu, Vojvode Stepe 305, 11000 Beograd, Srbija, e-mail: [m.selmic@sf.bg.ac.rs](mailto:m.selmic@sf.bg.ac.rs)

<sup>3</sup> dr Dragana Macura, dipl. inženjer saobraćaja, docent, Saobraćajni fakultet u Beogradu, Vojvode Stepe 305, 11000 Beograd, Srbija, e-mail: [d.macura@sf.bg.ac.rs](mailto:d.macura@sf.bg.ac.rs)

<sup>4</sup> MSc Nenad Marković, dipl. inženjer saobraćaja, asistent, Saobraćajni fakultet u Beogradu, Vojvode Stepe 305, 11000 Beograd, Srbija, e-mail: [n.markovic@sf.bg.ac.rs](mailto:n.markovic@sf.bg.ac.rs)

strane, etiološka analiza otvara tzv. crnu kutiju i omogućava da se utvrde uzroci saobraćajnih nezgoda. Sa preciznim poznavanjem uzroka saobraćajnih nezgoda moguće je definisati odgovarajući set mera za unapređenje stanja bezbednosti saobraćaja. U okviru etioloških analiza saobraćajnih nezgoda prepoznaju se najčešće: ekspertize, odnosno veštačenja saobraćajnih nezgoda i dubinske analize saobraćajnih nezgoda, odnosno nezavisne ocene saobraćajnih nezgoda.

Detaljnom analizom podataka iz etioloških istraživanja saobraćajnih nezgoda mogu se pouzdano utvrditi uzroci i okolnosti koji su doveli do nastanka svake konkretnе saobraćajne nezgode. Analizom ovako prikupljenih podataka moguće je prepoznati najvažnija obeležja saobraćajnih nezgoda koja ih izdvajaju ili poistovjećuju sa drugim nezgodama. Prepoznavanje ovakvih faktora omogućava usmeravanje dalje analize na konkretnu oblast ili konkretni faktor, kako bi se on istražio u svakom sledećem slučaju i utvrdio pouzdan metod za njegovu eliminaciju u budućnosti.

U radu je razvijen model za grupisanje uzročnika saobraćajnih nezgoda na osnovu sličnosti karakteristika vozača, vozila i puta. Razvijeni model je zasnovan na metodu klasterovanja. Klasterovanje je proces klasifikacije objekata u različite grupe, skupove, tako da elementi jednog skupa imaju izvestan stepen približnosti i jednakosti meren po unapred definisanim kriterijumima. Sličnost elemenata se utvrđuje na osnovu njihovih rastojanja. Dva elementa su sličnija ukoliko se nalaze na bližem rastojanju. U dosadašnjoj stručnoj i naučnoj praksi u oblasti bezbednosti saobraćaja klasterovanje je primenjivano u mnogo slučajeva (Fleury and Brenac, 2001; Casaer et al, 2004; Ma and Kockelman, 2006; Habibović et al, 2013; de Ona et al., 2013; Fernandes and Neves, 2013; Bil et al, 2013; Lenard et al, 2014; Huang and Wong, 2015; Amirian et al., 2015). Međutim, najviše korišćena metoda klasterovanja je metod *K-means* (Teodorović et al., 2010 i Šelmić et al., 2012), koji je u ovom radu predstavljen kao jedan od modela klasterovanja sa mogućnošću primene na analize saobraćajnih nezgoda, posebno kao pomoć pri preliminarnim analizama u procesu dubinskih analiza saobraćajnih nezgoda.

## 2. KLASTEROVANJE – K-MEANS ALGORITAM

Klasterovanje je metod klasifikacije objekata u različite grupe, skupove, tako da elementi jednog skupa imaju izvestan stepen približnosti i jednakosti meren po unapred definisanim kriterijumima. Sličnost elemenata se utvrđuje na osnovu rastojanja. Dva elementa su sličnija ukoliko se nalaze na bližem rastojanju. Postoje mnogobrojne metode za računanje rastojanja, kao što su: Euklidsko, Menhetn, Maksimum rastojanje, itd. Najviše korišćena metoda klasterovanja je metod *K-means* koju je razvio Hartigan 1975. godine. Četiri godine kasnije metod je dopunjeno doprinosom autora Hartigana i Vonga.

*K-means* algoritam dodeljuje element grupi, čiji je centar najbliži posmatranom elementu. Rastojanje, odnosno udaljenost, elementa od drugih elemenata može da se računa različitim metodama, kao što je već spomenuto. U ovom radu korišćeno je Euklidsko rastojanje. Konačno rešenje se prikazuje binarnom matricom  $U$ . Element  $u_{ij}$  matrice  $U$  je jednak 1 ukoliko je  $j$ -ti element dodeljen  $i$ -toj grupi. Vrednost elementa je jednaka 0 u suprotnom slučaju, tj.:

$$u_{ij} = \begin{cases} 1, & \text{ako je } \|x_j - c_i\|^2 \leq \|x_j - c_k\|^2, \text{ za } \forall k \neq i \\ 0, & \text{у осталим случајевима} \end{cases} \quad (1)$$

gde je:

$x_j$  – koordinate (karakteristike)  $j$ -tog elementa

$c_i$  – centar posmatrane  $i$ -te grupe;

Funkcija cilja (2) koju treba minimizirati predstavlja zbir rastojanja svih elemenata od centara grupe kojoj su dodeljeni. Matematička formulacija problema klasterovanja glasi:

Minimizirati

$$F = \sum_{i=1}^c F_i = \sum_{i=1}^c \left( \sum_{k, x_k \in G_i} \|x_k - c_i\|^2 \right) \quad (2)$$

pri ograničenjima:

$$\sum_{i=1}^c u_{ij} = 1, \text{ за } \forall j = 1, 2, \dots, n \quad (3)$$

$$\sum_{i=1}^c \sum_{j=1}^n u_{ij} = n \quad (4)$$

gde je:

$F_i$  - vrednost kriterijumske funkcije u okviru  $i$ -te grupe;

$x_k$  – koordinate (karakteristike)  $k$ -tog elementa;

$c_i$  – centar posmatrane  $i$ -te grupe;

$c$  – broj grupa ( $i=1,2,\dots,c$ );

$G_i$  –  $i$ -ta grupa.

Ograničenje predstavljeno relacijom (3) pokazuje da jedan element može da pripada samo jednoj grupi, dok se ograničenjem (4) proverava da li su svi elementi raspoređeni po grupama. Početni centar svake grupe bira se na slučajan način. Nakon svake završene iteracije algoritma bira se novi centar klastera i vrši se ponovno pridruživanje elemenata. Novi centar,  $c_i$ , za svaku grupu se definiše tako što se vrednosti prethodno definisanih elemenata, kao članova  $i$ -te grupe, sumiraju i dele sa brojem članova same grupe, tj.:

$$c_i = \frac{1}{|G_i|} \sum_{k, x_k \in G_i} x_k \quad (5)$$

pri ograničenju:

$$|G_i| = \sum_{j=1}^n u_{ij} \quad (6)$$

gde je:

$|G_i|$  - ukupan broj elemenata  $i$ -te grupe

$n$  – broj elemenata koje treba grupisati

Ograničenje (6) obezbeđuje da se ne prekorači maksimalni dozvoljeni broj elemenata u svakoj grupi. Neophodni koraci prilikom rešavanja posmatranog modela su (Šelmić et al, 2012):

- Definisati elemente koje treba grupisati,  $n$ ;
- Izabratи broj grupa,  $c$ ;
- Izabratи broj elemenata svake grupe,  $G$  (ovaj korak može da se izostavi, ukoliko je broj članova grupa neograničen);
- Odreditи  $c$  centara grupa;
- Odreditи najbliži centar za svaku grupu;
- Odreditи nove centre;

Ponavljati prethodne korake, dok se ne postigne neki unapred definisan kriterijum. Kriterijumi zaustavljanja mogu biti: unapred zadati broj iteracija, nova vrednost funkcije cilja je veća od prethodne; nova vrednost funkcije cilja je promenjena u odnosu na prethodnu za manje od 20%.

Osnovna prednost ovog modela jeste njegova jednostavnost i brzina obrade velikog broja podataka. Neki od nedostataka su: zavisnost kvaliteta izlaznog rešenja od slučajnog izbora početnih, ulaznih, vrednosti centara čvorova; atributi su isključivo numeričke vrednosti; izračunati lokalni optimum može da bude veoma različit od globalnog optimuma; i dr. Primena ovog modela ne garantuje iznalaženje optimalnog rešenja (Teodorovic et al, 2010).

### **3. PRIMENA METODE K-MEANS ZA GRUPISANJE UZROČNIKA SAOBRAĆAJNIH NEZGODA NA OSNOVU SLIČNOSTI KARAKTERISTIKA VOZAČA, VOZILA I PUTOA**

U primeru koji je razvijen u ovom radu, posmatran je slučaj kada su učestvovala dva vozila u saobraćajnoj nezgodi. Svaki učesnik saobraćajne nezgode je okarakterisan sa sledećih osam karakteristika:

- vreme i dan kada se nezgoda dogodila;
- stanje puta;

- poravnanje puta;
- pol i godine vozača;
- brzina;
- vidljivost;
- površina kolovoza;
- kategorija puta.

Algoritam za grupisanje uzročnika saobraćajnih nezgoda se sastoji iz sledećih koraka:

**Korak 1.** Za zadati broj iteracija, broj uzoraka nezgoda i veličine grupa generisati ulazne podatke (koordinate) za sve nezgode koje se analiziraju.

**Korak 2.** Na slučajan način generisati centre grupa. Ukupan broj klastera (grupa) je 15 i to u skladu sa uzrocima nezgode. Pod uzrocima se podrazumevaju faktori (propusti) koji su uticali na nastanak saobraćajne nezgode, odnosno koji su je prouzrokovali, dok su pod doprinosom smatrani faktori (propusti) koji nisu direktno prouzrokovali nastanak saobraćajne nezgode, ali su doprineli posledicama nastale nezgode. Naime, doprinosi se ogledaju u povećanim posledicama saobraćajne nezgode u odnosu na posledice koje bi bile da nije bilo ovih okolnosti.

Mogućnost izbegavanja saobraćajnih nezgoda predstavlja propust nekog od navedenih faktora (najčešće vezana za faktor čovek) gde je načinjen propust ne preduzimanjem određenih radnji u cilju izbegavanja saobraćajne nezgode. Propusti vezani za težinu posledica su oni propusti koji nemaju vezu sa nastankom ili mogućnošću izbegavanja nastanka saobraćajne nezgode, ali su doprineli većim posledicama nezgode (veća oštećenja i/ili teže povrede).

**Korak 3.** Izračunati Euklidska rastojanja svih nezgoda od svih generisanih centara. Formirati matricu rastojanja u kojoj vrste predstavljaju nezgode, a kolone centre klastera.

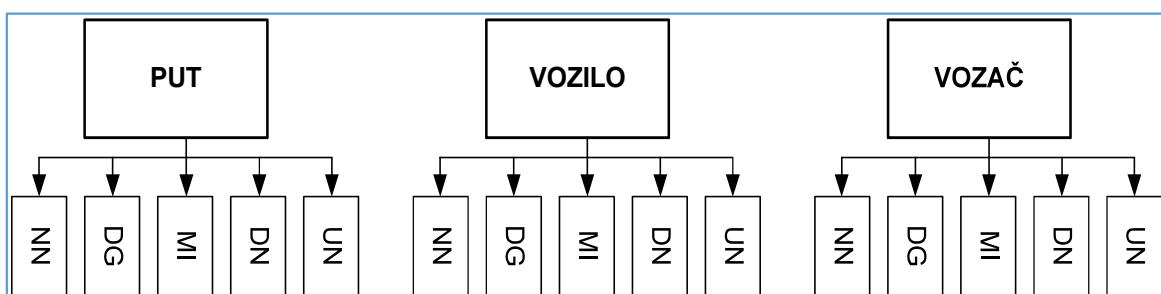
**Korak 4.** Pronaći najmanji element u matrici rastojanja. Određena nezgoda kojoj odgovara vrednost najmanjeg rastojanja dodeljuje se odgovarajućem klasteru i isključuje se iz daljeg razmatranja. Ažurirati matricu rastojanja i ponavljati postupak sve dok se sve nezgode ne dodelje klasterima (svrstaju po uzročnicima saobraćajnih nezgoda). S obzirom da ne postoji ograničenje kapaciteta klastera svaka nezgoda se može svrstati u klaster kome pripada.

**Korak 5.** Po dodeljivanju svih nezgoda klasterima izračunati vrednost kriterijumske funkcije.

**Korak 6.** Odrediti nove centre grupa koristeći relacije (5) i (6). Vratiti se na korak 2.

**Korak 7.** Ponavljati algoritamske korake dok se ne dostigne unapred zadati broj iteracija.

Primenom izloženog algoritma različiti uticaji puta, vozila i vozača u pojedinačnoj saobraćajnoj nezgodi se mogu klasifikovati, a sa ciljem obavljanja dubinske analize. Svaki od ovih faktora može učestvovati u nezgodi kao: uzrok nezgode (UN), doprinos pojavi nezgode (DN), mogućnost izbegavanja (MI), doprinos nastanku gubitaka (DG) i nijedan od navedenih (NN).



*Slika 1. 1- 15 mogućih klastera*

Validacija ostvarenih rezultata se vrši primenom Silhouette tehnike (Rousseeuw 1987). Silhouette je metoda koja se koristi za interpretaciju klasterovanih podataka i omogućava grafički prikaz kako se svaki element (nezgoda) uklapa u klaster (uzrok nezgode) kome je dodeljen. Na y osi bi bili predstavljeni klasteri, a na x osi vrednost Silhouette metode. Ova vrednost može da bude u rasponu od -1 do +1. Ukoliko je vrednost bliža +1 to znači da je nezgoda dobro klasifikovana, dok suprotno ukoliko je Silhouette vrednost bliža -1 to znači da klasterovanje nije precizno urađeno.

#### 4. ZAKLJUČAK

Uzimajući u obzir negativne posledice saobraćaja, a posebno nedopustivo veliko stradanje ljudi u saobraćajnim nezgodama, jasno je da je uspešno upravljanje stanjem bezbednosti saobraćaja izuzetno značajan društveni proces. Brojna su istraživanja koja su dokumentovala značaj strateškog upravljanja bezbednošću saobraćaja, kao i primenu sofisticiranih naučnih metoda u rešavanju ključnih problema bezbednosti saobraćaja. Posebno je važno izdvojiti alate koji se sa jedne strane bave otkrivanjem i analizom uzroka nastanka saobraćajnih nezgoda, jer se neutralisanjem uzroka na najjednostavniji i najekonomičniji način sprečavaju najteže posledice saobraćajnih nezgoda, ali i alate koji služe za rešavanje već uočenih uzroka – problema.

Jedan od međunarodno priznatih i u većini zemalja zakonom propisanih alata za unapređenje bezbednosti saobraćaja jesu i dubinske analize saobraćajnih nezgoda (metod nezavisne ocene) koje su bile predmet ovog rada. S obzirom na to da je postupak realizacije dubinskih analiza saobraćajnih nezgoda dugotrajan i veoma složen, jer zahteva prikupljanje i analizu velikog broja podataka, u ovom radu su predstavljene mogućnosti izdvajanja i grupisanja podataka iz ekspertiza saobraćajnih nezgoda, primenom K-means algoritma. Ekspertize saobraćajnih nezgoda predstavljaju riznicu podataka vezanih za nastanak konkretne saobraćajne nezgode, pa se korišćenjem tih, već prikupljenih, podataka za potrebe dubinskih analiza saobraćajnih nezgoda ostvaruje niz koristi i postupak pojednostavljuje. Pored toga, najvažnija prednost primene K-means algoritma je što se na jednostavan i brz način može obraditi velika količina podataka čime se trajanje postupka dubinske analize i utvrđivanja uzroka nastanka nezgode bitno skraćuje.

Prethodno iznete prednosti i dati zaključci ukazuju na značaj opisanog metoda za unapređenje bezbednosti saobraćaja u lokalnim zajednicama. Posebno je važno istaći da samouprave, a posebno donosici odluka u subjektima značajanim za upravljanje stanjem bezbednosti saobraćaja, primenom ovog metoda imaju značajnu podršku u odlučivanju. Naime, rezultati se dobijaju brzo, pa se u slučaju uočenog problema u bezbednosti saobraćaja relativno brzo mogu otkriti uzroci tog problema, a potom i realizovati one mere koje na najbolji način neutrališu uočene uzroke. Pored toga, primenom opisanog metoda je moguće po hijerarhiji kreirati listu uzroka, odnosno listu problema i na taj način alocirati sredstva predviđena za unapređenje bezbednosti saobraćaja u lokalnoj zajednici.

Uzimajući u obzir prednosti dubinskih analiza saobraćajnih nezgoda, kao i sposobnosti K-means algoritma, u budućnosti bi podaci iz ekspertiza saobraćajnih nezgoda mogli biti dopunjeni i podacima iz osiguravajućih kompanija, zdravstvenih ustanova, servisnih ustanova i drugih subjekata koji raspolažu podacima od značaja za utvrđivanje uzroka (i okolnosti) saobraćajnih nezgoda, čime bi se još više unapredio proces upravljanja bezbednošću saobraćaja na konkretnom području, jer bi doneti zaključci bili potkrepljeni analizom većeg broja podataka.

#### 5. LITERATURA

- [1]. Amirian, E., Leung, J.Y., Zanon, S., Dzurman, P. 2015. Integrated cluster analysis and artificial neural network modeling for
- [2]. steam-assisted gravity drainage performance prediction in heterogeneous reservoirs, Expert Systems with Applications 42, 723–740
- [3]. Bíl, M., András, R., Ček Janoška, Z. 2013. Identification of hazardous road locations of traffic accidents by means of kernel density estimation and cluster significance evaluation, Accident Analysis and Prevention 55, 265–273
- [4]. Casaer, F., Geert, W., Isabelle, T. 2004. Road Traffic Accident Clustering With Categorical Attributes, TRB 2004 Annual Meeting
- [5]. de Ona, J., López, G., Mujalli, R., Calvo, F.J. 2013. Analysis of traffic accidents on rural highways using Latent Class Clustering and Bayesian Networks, Accident Analysis and Prevention 51, 1– 10
- [6]. Fernandes, A., Neves, J. 2013. An approach to accidents modeling based on compounds road environments, Accident Analysis and Prevention 53, 39– 45
- [7]. Fleury, D., Brenac, T. 2001. Accident prototypical scenarios, a tool for road safety research and diagnostic studies, Accident Analysis and Prevention 33, 267 – 276
- [8]. Habibovica, A., Tivesten, E., Uchidab, N., Bärgman, J., Ljung Aust, M. 2013. Driver behavior in car-to-pedestrian incidents: An application of the Driving Reliability and Error Analysis Method (DREAM), Accident Analysis and Prevention 50, 554– 565

- [9]. Hartigan, J. A., *Clustering Algorithms*. Wiley, 1975.
- [10]. Hartigan, J. A., Wong, M. A., Algorithm AS 136: A K-means Clustering Algorithm. *Journal of the Royal Statistical Society, Series C (Applied Statistics)* 28 (1), 100-108, 1979.
- [11]. Huang, S.H., Wong, J.T. 2015. A multinomial choice model approach for dynamic driver vision transitions, *Accident Analysis and Prevention* 74, 107–117
- [12]. Lenard, J., Badea-Romero, A., Danton, R. 2014. Typical pedestrian accident scenarios for the development of autonomous emergency braking test protocols, *Accident Analysis and Prevention* 73, 73–80
- [13]. Ma, J., Kockelman, K. 2006. Crash Frequency and Severity Modeling Using Clustered Data from Washington State, *IEEE Intelligent Transportation Systems Conference*, Toronto, Canada, September 17-20
- [14]. Rousseeuw, P., "Silhouettes: a Graphical Aid to the Interpretation and Validation of Cluster Analysis". *Computational and Applied Mathematics*, Vol. 20, 53–65, 1987.
- [15]. Teodorović D., Macura D., Šelmić M. 2010 Povezivanje zajedničkih vožnji primenom metode k-means, Simpozijum o operacionim istraživanjima SYM-OP-IS.
- [16]. Šelmić, M., Macura, D., and Teodorović, D. (2012). "Ride Matching Using K -means Method: Case Study of Gazela Bridge in Belgrade, Serbia." *J. Transp. Eng.*, 138(1), 132–140.