Odnos menadžmenta i vođenja

Bubaš, Marija

Undergraduate thesis / Završni rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Polytechnic Nikola Tesla in Gospić / Veleučilište Nikola Tesla u Gospiću**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:107:687916

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Polytechnic Nikola Tesla in Gospić - Undergraduate thesis repository

zir.nsk.hr

Image not found or type unknown

VELEUČILIŠTE „NIKOLA TESLA“ U GOSPIĆU

Marina Bubaš

DESKRIPTIVNA SVOJSTVA PROMETNIH NESREĆA U REPUBLICI HRVATSKOJ

DESCRIPTIVE STATISTICS OF TRAFFIC ACCIDENTS IN THE REPUBLIC OF CROATIA

Završni rad

Gospić, 2017.

VELEUČILIŠTE „NIKOLA TESLA“ U GOSPIĆU

Prometni odjel

Stručni studij cestovnog prometa

DESKRIPTIVNA SVOJSTVA PROMETNIH NESREĆA U REPUBLICI HRVATSKOJ

DESCRIPTIVE STATISTICS OF TRAFFIC ACCIDENTS IN THE REPUBLIC OF CROATIA

Završni rad

MENTOR:
Kristina Devčić, univ.spec.oec,
viši predavač

STUDENT:
Marina Bubaš
MBS: 2961000288/10

Gospić, studeni 2017.

Veleučilište „Nikola Tesla“ u Gospiću

Prometni odjel

Gospić, 12. travnja 2017.

Z A D A T A K

za završni rad

Pristupniku Marini Bubaš MBS: 2961000288/10.

Studentu stručnog studija Cestovni promet izdaje se tema završnog rada pod nazivom

Deskriptivna svojstva prometnih nesreća u Republici Hrvatskoj

Sadržaj zadatka :

Opisati glavne pokazatelje deskriptivne statistike: grafički prikazi, relativne frekvencije, srednje vrijednosti, mjere disperzije, mjere asimetrije i mjeru zaobljenosti. Na temelju dostupnih podataka o broju prometnih nesreća izračunati vrijednosti navedenih pokazatelja za Republiku Hrvatsku i posebno za Ličko-senjsku županiju. Analizirati, interpretirati i usporediti dobivene rezultate. Donijeti zaključak.

Završni rad izraditi sukladno odredbama Pravilnika o završnom radu Veleučilišta „Nikola Tesla“ u Gospiću.

Mentor: Kristina Devčić, v.pred. zadano: 12. travnja 2017., _____
(ime i prezime) (nadnevak) potpis

Pročelnik odjela: Slađana Čuljat, pred. predati do: 05. rujna 2018., _____
(ime i prezime) (nadnevak) potpis

Student: Marina Bubaš primila zadatak: 12. travnja 2017., Marina Bubaš
(ime i prezime) (nadnevak) potpis

I Z J A V A

Izjavljujem da sam završni rad pod nazivom ***Deskriptivna svojstva prometnih nesreća u Republici Hrvatskoj*** izradila samostalno pod nadzorom i uz pomoć mentora Kristine Devčić, univ.spec.oec, višeg predavača.

Marina Bubaš

Marina Bubaš

(potpis studenta)

SAŽETAK

U posljednjih nekoliko godina u Republici Hrvatskoj je sve izraženiji problem nesigurnosti na cestama i velikog broja prometnih nesreća. Svakodnevno smo okruženi lošim vijestima s prometnica, te nažalost velikim brojem smrtno stradalih u prometu. Statistika je skup ideja i metoda koje se upotrebljavaju za prikupljanje i interpretaciju podataka u nekom području istraživanja te za izvođenje zaključaka u situacijama gdje su prisutne nesigurnosti i varijacije. U radu su detaljno pojašnjeni pojmovi deskriptivne statistike te na temelju toga prikazan je izračun broja prometnih nesreća po županijama u Republici Hrvatskoj. Dobiveni rezultati detaljno su analizirani i uspoređeni.

Ključne riječi: cesta, prometna nesreća, statistika, uzorak.

SUMMARY

Over the past few years, the problem of road safety and a large number of traffic accidents has been increasingly pronounced in Republic of Croatia. Every day we are surrounded by bad news from the road, and unfortunately, a large number of fatalities in traffic. Statistics are a set of ideas and methods used to collect and interpret data in some area of research and to draw conclusions in situations where uncertainties and variations are present. The paper describes the concepts of descriptive statistics and the calculation of the number of traffic accidents for counties in the Republic of Croatia is shown. The results were analyzed and compared in detail.

Keywords: Road, Traffic Accident, Statistics, Sample.

SADRŽAJ

1. UVOD 1
1.1. Predmet istraživanja 1
1.2. Svrha i cilj istraživanja 1
1.3. Metode istraživanja 1
1.4. Struktura rada 2
2. DESKRIPTIVNA STATISTIKA 2
2.1. Grafički prikazi 3
2.1.1. Površinski grafikoni 3
2.1.2. Linijski grafikoni 4
2.2. Kumulativni niz 4
2.3. Relativne frekvencije 5
2.4. Srednje vrijednosti 5
2.4.1. Aritmetička sredina 6
2.4.2. Harmonijska sredina 7
2.4.3. Geometrijska sredina 8
2.4.4. Medijan 9
2.4.5. Kvartili, decili i percentili 10
2.4.6. Mod 12
2.5. Mjere disperzije 12
2.5.1. Raspon varijacije 13
2.5.2. Varijanca 13
2.5.3. Standardna devijacija 14
2.5.4. Interkvartil 15
2.5.5. Koeficijent varijacije 15
2.5.6. Koeficijent kvartilne devijacije 16
2.6. Mjere asimetrije 16
2.6.1. Koeficijent asimetrije 17
2.6.2. Pearsonova mjera asimetrije 17
2.6.3. Bowleyjeva mjera asimetrije 18
2.7. Mjera zaobljenosti 18
3. ANALIZA BROJA PROMETNIH NESREĆA U REPUBLICI HRVATSKOJ 19
4. ZAKLJUČAK 39
LITERATURA 40
POPIS TABLICA 41
POPIS GRAFIKONA 41

1. UVOD

Motorizirani cestovni promet jedno je od bitnih obilježja suvremene civilizacije. Svakodnevno na cestama dolazi do prometnih nesreća u kojima sudionici u prometu trpe više ili manje štetne posljedice. Na žalost, sigurnosti prometa na cestama pažnja se poklanja tek nakon prometnih nesreća. Prometna nesreća je događaj na cesti u kojem je sudjelovalo najmanje jedno vozilo u pokretu i u kojem je najmanje jedna osoba ozlijeđena ili poginula ili u roku od 30 dana preminula od posljedica te prometne nesreće ili je izazvana materijalna šteta.Neprimjerena brzina, nekorištenje sigurnosnog pojasa, nepoštivanje prometnih znakova, nepropisno zaustavljanje te vožnja pod utjecajem alkohola glavni su uzroci prometnih nesreća. Od tri bitna čimbenika za sigurnost prometa, prometna kultura svih sudionika – osobito vozača najbrže može smanjiti tragične posljedice. Potrebno je svakodnevno pratiti i analizirati stanje i promjene na cestovnim prometnicama kako bi se dobila što potpunija slika o stanju sigurnosti cestovnog prometa u Republici Hrvatskoj i svim čimbenicima koji ga ugrožavaju.

1.1. Predmet istraživanja

U radu su detaljno pojašnjeni osnovni pojmovi deskriptivne statistike. Primjenom navedenih pokazatelja statistički je analiziran broj prometnih nesreća po županijama Republike Hrvatske. Na temelju dobivenih rezultata analizirano je i uspoređeno kretanje sigurnosti prometa na hrvatskim prometnicama u proteklih nekoliko godina.

1.2. Svrha i cilj istraživanja

U ovom radu analizirani su deskriptivni pokazatelji prometnih nesreća u Republici Hrvatskoj u razdoblju od 2008. do 2016. godine te je dana njihova usporedba. Svrha ovog završnog rada je statistički prikazati osnovne podatke prometnih nesreća i njihovih posljedica kako bi se dobio uvid u složenost problema sigurnosti prometa na cestama.

1.3. Metode istraživanja

Završni rad je rezultat sustavnog proučavanja dostupne i znanstvene literature, internetskih izvora te predstavlja sistematizaciju odgovarajuće građe. U ovom završnom radu, za opisivanje i definiranje pojmova korištene su u odgovarajućim kombinacijama, slijedeće

znanstvene metode: analiza i sinteza, deskriptivna i deduktivna metoda, grafička metoda te metoda generalizacije i konkretizacije.

1.4. Struktura rada

Sveukupna struktura ovog završnog rada koncipirana je u nekoliko međusobno interakcijski povezanih dijelova.

U prvom dijelu, Uvodu, naveden je predmet istraživanja, svrha i ciljevi koji su istraživanjem ostvareni, metode istraživanja te struktura završnog rada. U drugom dijelu pod naslovom Deskriptivna statistika detaljno su pojašnjeni pojmovi deskriptivne statistike, grafičkih prikaza, relativnih frekvencija, kumulativnog niza, srednjih vrijednosti, mjera disperzije, mjera asimetrije te mjere zaobljenosti. U trećem dijelu pod naslovom Analiza broja prometnih nesreća u Republici Hrvatskoj dan je izračun srednjih vrijednosti na primjeru prometnih nesreća u Republici Hrvatskoj. U četvrtom i posljednjem dijelu pod naslovom Zaključak, dana je sinteza činjenica i spoznaja do kojih se došlo u ovom istraživačkom procesu.

2. DESKRIPTIVNA STATISTIKA

Uporaba riječi statistika u svakodnevnom životu najčešće je povezana s brojčanim vrijednostima kojima se pokušava opisati bitne karakteristike nekog skupa podataka.

Statistika[1] je znanstvena disciplina koja se bavi prikupljanjem, analizom i tumačenjem podataka o masovnim pojavama. Statistika na organizirani način pristupa prikupljanju, selekciji, grupiranju, prezentaciji i analizi informacija ili podataka, te interpretiranju rezultata provedene analize, a u svrhu realizacije postavljenih istraživačkih ciljeva. (Marković, Raspor, 2008.)

Deskriptivna statistika se sastoji od primjene postupaka kojima se podaci uređuju te tablično i grafički prikazuju. U sklopu deskriptivne statistike provodi se i raznovrsna brojčana obrada. Rezultati statističke analize dobiveni primjenom metoda deskriptivne statistike služe

[1] Riječ **statistika** potječe od latinskih riječi *statisticum collegium* koje znače „državno stanje“ i talijanske riječi *statista* koja znači „državni čovjek, političar“. Nijemac Gottfried Achenwall prvi put koristi riječ Statistik za analizu državnih podataka (“science of state“) 1749. godine. Značenje riječi statistika za skupljanje i klasifikaciju podataka usvojeno je početkom 19.stoljeća.

za donošenje zaključaka o pojavi koju oni predočuju te se ne poopćavaju, nego se odnose isključivo na analizirane podatke. (Šošić, 2004.)

Deskriptivna statistika se bavi:

- mjerama centralne tendencije: mod i medijan te aritmetička sredina, geometrijska i harmonijska sredina;
- mjerama disperzije: raspon, standardna devijacija, varijanca, interkvartil i semiinterkvartil, koeficijent varijacije, koeficijent kvartilne devijacije;
- grafičkim i tabelarnim prikazivanjem osnovnih statističkih vrijednosti. (https://bs.wikipedia.org/wiki/Statistika, 19. srpnja 2017.)

2.1. Grafički prikazi

Grafičkim se prikazom populariziraju razni statistički rezultati. Pri objašnjavanju poslovnih i gospodarskih događaja grafički prikazi vrlo su važni jer je njihovo tumačenje jednostavno i ne zahtjeva mnogo vremena. Postoji više vrsta grafikona, a odabir konkretne vrste grafikona ovisi o vrsti pojave koja se tim grafikonom želi prikazati.

Vrste grafikona su:

1. površinski grafikoni,
2. linijski grafikoni.

2.1.1. Površinski grafikoni

Površinskim grafikonima se podaci prikazuju pomoću geometrijskih likova. Površine tih geometrijskih likova proporcionalne su veličinama brojčanih podataka koji se tim grafikonom prikazuju. Najjednostavniji površinski grafikon je grafikon s jednostavnim stupcima. Najčešće se površinski grafikoni crtaju pomoću pravokutnika jednakih baza.

Posebna vrsta površinskih grafikona je histogram. Histogram je grafički prikaz koji se sastoji od pravokutnika. Osnovice pravokutnika predočuju vrijednosti numeričke varijable, a visina pravokutnika ovisi o frekvencijama. Ako su razredi nejednakih veličina, visina pravokutnika ovisi o korigiranoj frekvenciji. Da bi se istaknuo kontinuitet numeričkog obilježja, pravokutnici se crtaju jedan uz drugoga (bez razmaka). Najčešći oblik distribucije frekvencija je oblik zvona koje može biti više ili manje asimetrično. Ukoliko u grafikonu postoji samo desna strana „zvona“ govori se o L-distribuciji, u suprotnom riječ je o J-

distribuciji. Posebna vrsta histograma je stablo-list dijagram. Ovaj dijagram konstruira se tako da se vodeće znamenke (koje predstavljaju stablo) pišu u prvi stupac, a ostale znamenke (koje predstavljaju listove) u retke pored odgovarajućih vodećih znamenaka. (Štambuk, Devčić, 2010.)

Skupini površinskih grafikona pripadaju i kružni grafikoni. Strukturni krug ili kružni grafikon se definira kao način prikazivanja djelomičnih vrijednosti neke cjeline kao dijela kruga. U pravilu je grafikon podijeljen na kružne isječke i svaki od njih predstavlja neku djelomičnu vrijednost, a cijeli krug predstavlja zbroj svih tih vrijednosti. Naziva ga se još i tortnim grafikonom. (https://hr.wikipedia.org/wiki/Strukturni_krug, 19. srpnja. 2017.)

2.1.2. Linijski grafikoni

Linijski grafikoni se koriste za prikazivanje međuodnosa dviju promjenljivih varijabli tijekom vremena. Kod linijskog grafikona pojave se prikazuju linijama. Također, linijskim grafikonima se prikazuje kumulanta kontinuiranog numeričkog obilježja grupiranog u razrede.

2.2. Kumulativni niz

Kumulativni niz je niz koji nastaje postupnim zbrajanjem originalnih frekvencija (apsolutnih ili relativnih) numeričkog niza. Zbrajaju li se relativne frekvencije, onda se takav niz još naziva i empirijskom funkcijom distribucije. Kumulativni niz može biti kumulativni niz „manje od“ i „više od“.

Svaki član kumulativnog niza „manje od“ pokazuje ukupan broj jedinica koje imaju vrijednost numeričkog obilježja jednaku ili manju od vrijednosti modaliteta čija je frekvencija posljednja ušla u zbroj, a ako se radi o distribuciji s razredima, tada svaki član kumulativnog niza „manje od“ pokazuje ukupan broj jedinica čija je vrijednost manja od vrijednosti gornje granice onog razreda čija je frekvencija posljednja ušla u zbroj. Posljednji član kumulativnog niza jednak je zbroju svih frekvencija.

Svaki član kumulativnog niza „više od“ pokazuje ukupan broj jedinica koje imaju vrijednost numeričkog obilježja jednaku ili veću od vrijednosti modaliteta čija je frekvencija posljednja ušla u zbroj, a ako se radi o distribuciji s razredima, tada svaki član kumulativnog niza „više od“ pokazuje ukupan broj jedinica čija je vrijednost veća ili jednaka od vrijednosti

koju pokazuje donja granica onog razreda čija je frekvencija posljednja ušla u zbroj. (Štambuk, Devčić 2010.)

2.3. Relativne frekvencije

Ako podatke grupiramo u razrede, onda slično definiramo frekvencije razreda. Relativna frekvencija p_i , i =1,…,k, po definiciji je omjer apsolutne frekvencije razreda i zbroja frekvencija svih razreda. Zato je zbroj relativnih frekvencija jednak 1. Postotna relativna frekvencija je omjer frekvencije i zbroja frekvencija pomnožen sa sto.

$$p_i = \frac{f_i}{\sum_{i=1}^{k} f_i}, \; i = 1,\ldots,k. \tag{1}$$

pri čemu je f_i frekvencija razreda a $\sum_{i=1}^{k} f_i$ je zbroj frekvencija svih razreda.

Ukoliko se grafički prikazuju podaci grupirani u razrede različitih veličina potrebno je korigirati frekvencije. Frekvencije se korigiraju tako da se originalne frekvencije podijele pripadajućim veličinama razreda ili njima proporcionalnim veličinama.

$$F_{ci} = \frac{f_i}{j_i}, \; i = 1,\ldots k. \tag{2}$$

gdje je *fi* originalna frekvencija i – tog razreda, a j_i veličina i – tog razreda.

2.4. Srednje vrijednosti

Srednja ili prosječna vrijednost je broj kojim se opisuje niz varijabilnih podataka i koji ima smisla računati samo za veći broj podataka. Srednjim vrijednostima se podaci uopćavaju i one zamjenjuju svaku individualnu vrijednost obilježja elemenata. Nazivamo ih još i mjerama centralne tendencije. (Štambuk, Devčić, 2010.)

Srednje vrijednosti dijelimo u dvije skupine:

1. potpune,
2. položajne.

Potpune srednje vrijednosti su one koje se računaju na temelju svih podataka. Potpune srednje vrijednosti su:

1. aritmetička sredina,
2. harmonijska sredina,
3. geometrijska sredina.

Položajna srednja vrijednost po pravilu je jedan modalitet statističke varijable, koji se identificira sukladno definiciji srednje vrijednosti ili se aproksimira pomoću manjeg broja podataka. (Šošić, 2006.)

Položajne srednje vrijednosti su:

1. mod,
2. medijan.

Izbor tipa srednje vrijednosti ovisi o vrsti statističke varijable, odnosno ovisi o nizu podataka za koji se određuje. Pri analizi numeričkog niza u pravilu se rabe sve spomenute potpune i položajne vrijednosti.

2.4.1. Aritmetička sredina

Aritmetička sredina je najvažnija i najčešće korištena potpuna srednja vrijednost. Popularno se naziva još i prosjek. Aritmetička sredina se dobiva tako što se zbroj vrijednosti promatranog obilježja podijeli s njihovim brojem, a računa se po formuli

$$\overline{x} = \frac{x_1 + x_2 + \ldots + x_n}{n}, \tag{3}$$

pri čemu je $x_1 + x_2 + \ldots x_n$ zbroj svih vrijednosti nekog obilježja, a n je ukupan broj elemenata u nizu.

Aritmetička sredina za grupirane podatke računa se u obliku vagane (ponderirane) aritmetiče sredine po formuli

$$\overline{x} = \frac{f_1 x_1 + \ldots + f_k\ x_k}{f_1 + \ldots + f_k}, \tag{4}$$

pri čemu su $x_1,\ldots x_k$ modaliteti obilježja po kojem je provedeno grupiranje, $f_1,\ldots f_k$ su frekvencije tih modaliteta, a k je broj razreda.

Svojstva aritmetičke sredine:

1. Nalazi se između najmanje i najveće vrijednosti obilježja,
2. Zbroj odstupanja vrijednosti aritmetičkog obilježja od aritmetičke sredine je nula,
3. Zbroj kvadrata odstupanja vrijednosti obilježja od njihove aritmetičke sredine manji je od zbroja kvadrata odstupanja vrijednosti obilježja od bilo kojeg drugog broja,
4. Ako su vrijednosti numeričke varijable jednake konstanti c, onda je aritmetička sredina te varijable jednaka konstanti c. (Štambuk, Devčić, 2010.)

2.4.2. Harmonijska sredina

Harmonijska sredina koristi se u izračunavanju produktivnosti rada mjerene utroškom vremena po jedinici. Jednaka je recipročnoj vrijednosti aritmetičke sredine recipročnih vrijednosti podataka. Harmonijska sredina je uvijek manja ili jednaka od aritmetičke sredine. (Štambuk, Devčić, 2010.)

Harmonijska sredina za negrupirane podatke računa se po formuli

$$H = \frac{n}{\frac{1}{x_1}+\frac{1}{x_2}+\ldots+\frac{1}{x_n}},\ x_i \neq 0,\ i = 1,\ldots,n, \tag{5}$$

pri čemu je n broj elemenata skupa a $x_1, x_2,\ldots x_n$ je i-ti element skupa.

Harmonijska sredina za grupirane podatke računa se po formuli

$$H = \frac{\sum_{i=1}^{k} f_i}{\sum_{i=1}^{k} \frac{f_i}{x_i}},\ x_i \neq 0,\ \forall i = 1,\ldots,k., \tag{6}$$

pri čemu su f_i frekvencije i-tog razreda, a x_i je i-ti element skupa.

2.4.3. Geometrijska sredina

Geometrijska sredina se koristi u poslovnoj statistici pri računanju prosjeka pokazatelja relativnih promjena, primjerice za izračunavanje prosječne stope promjene pojave u vremenu. Kao i svaka srednja vrijednost, tako se i geometrijska sredina nalazi između najmanje i najveće vrijednosti niza za koji se izračunava. (Štambuk, Devčić, 2010.)
Određivanje geometrijske sredine za negrupirane podatke izvodi se prema formuli

$$G = \sqrt[n]{x_1 . x_2 . \ldots . x_n} \text{ , } x_i > 0, i = 1, \ldots, n \text{ .,} \quad (7)$$

pri čemu je *n* ukupan broj elemenata u nizu, a $x_1, x_2, \ldots, x_n$ je vrijednost numeričkog obilježja. Prema tome, geometrijska sredina je broj koji se izračunava kao n-ti korijen iz njihova umnoška.

Određivanje geometrijske sredine za grupirane podatke izvodi se prema formuli

$$G = \sqrt[n]{x_1^{f1} . \ldots . x_k^{fk}}, \quad (8)$$

pri čemu je *n* ukupan broj elemenata u nizu, $x_1, \ldots x_n$ je vrijednost numeričkog obilježja a $f_1, \ldots f_k$ je frekvencija.

U poslovnoj i gospodarskoj analizi umjesto pojedinačnih stopa promjene često se upotrebljava prosječna stopa promjene razine pojave u uzastopnim razdobljima. (Šošić, 2004.)
Prosječna stopa promjene je broj koji se izračunava primjenom formule

$$G = \left[\sqrt[(N-1)]{\frac{Y_N}{Y_1}} - 1 \right] 100. \quad (9)$$

pri čemu je *N* broj članova u nizu, y_N je posljednji član niza, a y_1 je prvi član niza.

2.4.4. Medijan

Medijan je srednja vrijednost numeričkog obilježja koja uređene elemente osnovnog skupa dijeli na dva jednakobrojna dijela tako da se u jednom dijelu nalaze elementi koji imaju vrijednost obilježja manju ili jednaku od medijana, a u drugom dijelu se nalaze elementi koji imaju vrijednost veću ili jednaku od medijana. Da bi se odredio, potrebno je vrijednosti urediti po veličini od najmanje do najveće. (Štambuk, Devčić, 2010.)

Kod određivanja medijana za negrupirane podatke razlikujemo dva slučaja:

- statistički niz se sastoji od neparnog broja elemenata,
- statistički niz se sastoji od parnog broja elemenata.

Ako je broj elemenata u nizu neparan broj n, tada se medijan računa pomoću formule

$$M_e = x_{\frac{n+1}{2}}, \tag{10}$$

uz pretpostavku da su elementi niza uređeni po veličini.

Ako je broj elemenata u nizu paran broj n, tada se medijan računa pomoću formule

$$M_e = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2}, \tag{11}$$

Kod određivanja medijana za grupirane podatke razlikujemo dva slučaja:

- numerički niz je grupiran prema diskontinuiranom obilježju gdje su modaliteti predstavljeni brojevima (ne razredima),
- numerički niz je grupiran po razredima (bez obzira na to radi li se o diskontinuiranom ili kontinuiranom obilježju).

U prvom slučaju medijan se određuje pomoću kumulativnog niza „manje od“. Za medijan se uzima vrijednost modaliteta obilježja koja pripada elementu na poziciji $\frac{n+1}{2}$,ako je ukupan broj podataka neparan. Ako je broj podataka paran, medijan je vrijednost modaliteta obilježja koja pripada elementima koji se nalaze na pozicijama $\frac{n}{2}$ i $\frac{n}{2}+1$.

U drugom slučaju s razredima medijan se aproksimira prema formuli

$$M_e = L_1 + \frac{\frac{n}{2} - \sum_{m=1}^{s} f_m}{f_{med}} \cdot i\,. \tag{12}$$

pri čemu je L_1 donja granica medijalnog razreda, n zbroj frekvencija, f_{med} je frekvencija medijalnog razreda a i je veličina razreda. (Šošić, 2004.)

2.4.5. Kvartili, decili i percentili

Medijan, kvartili, decili i percentili ubrajaju se u kvantile. Broj kvantila za jedan je manji od njegovog reda. Stoga su tri kvartila, devet decila i devedeset devet percentila. (Štambuk, Devčić, 2010.)

Kod određivanja kvartila za negrupirane podatke razlikujemo dva slučaja:

- i·n je djeljivo s 4,
- i·n nije djeljivo s 4.

Ako je i·n djeljivo s 4, onda je

$$Q_i = \frac{x_r + x_{r+1}}{2}, \tag{13}$$

gdje je $r = \frac{i \cdot n}{4}$.

Ako i·n nije djeljivo s 4, onda je

$$Q_i = x_{r,} \tag{14}$$

gdje je $r = \mathrm{INT}\left(\frac{i \cdot n}{4}\right) + 1$.

Ako je distribucija dana po razredima, vrijednost kvartila aproksimira se prema formuli

$$Q_i = L_1 + \frac{\frac{i \cdot n}{4} - \sum_{m=1}^{s} f_m}{f_{kv}} \cdot j\ ,i = 1,2,3.\ , \tag{15}$$

Prilikom određivanja decila za negrupirane podatke razlikujemo dva slučaja:

- i·n je djeljivo s 10,
- i·n nije djeljivo s 10.

Ako je i·n djeljivo s 10, onda je

$$D_i = \frac{x_r + x_{r+1}}{2}, \tag{16}$$

gdje je $r = \frac{i \cdot n}{10}$.

Ako i·n nije djeljivo s 10, onda je

$$D_i = x_r, \tag{17}$$

gdje je $r = \left(\frac{i \cdot n}{10}\right) + 1$.

Ako je distribucija dana po razredima, vrijednost decila se aproksimira po formuli

$$D_i = L_1 + \frac{\frac{i \cdot n}{10} - \sum_{m=1}^{s} f_m}{f_{dec}} \cdot j, \; i = 1,\ldots,9. \tag{18}$$

Percentili dijele osnovni skup na sto jednakobrojnih dijelova. Kod određivanja percentila za negrupirane podatke razlikujemo dva slučaja:

- i·n je djeljiv sa 100,
- i·n nije djeljiv sa 100.

Ako je i·n djeljiv sa 100, onda je

$$P_i = \frac{x_r + x_{r+1}}{2}, \tag{19}$$

gdje je $r = \frac{i \cdot n}{100}$.

Ako i·n nije djeljiv sa 100, onda je

$$P_i = x_r, \tag{20}$$

gdje je r = INT $\left(\frac{i \cdot n}{100}\right) + 1$.

Ako je distribucija dana po razredima, vrijednost percentila aproksimira se prema formuli

$$P_i = L_1 + \frac{\frac{i \cdot n}{100} - \sum_{m=1}^{s} f_m}{f_{perc}} \cdot j,\ i = 1,\ldots,99. \quad (21)$$

2.4.6. Mod

Mod je položajna srednja vrijednost. To je vrijednost ili modalitet varijable koji se najčešće pojavljuje u nizu. Prema tome, mod je modalitet nominalne varijable ili numeričke varijable s najvećom frekvencijom. Mod postoji ako su u nizu barem dva jednaka podatka. (Šošić, 2006.)

Kod numeričkog obilježja čije su vrijednosti grupirane u razrede mod se aproksimira po formuli

$$M_o = L_1 + \frac{(b-a)}{(b-a)+(b-c)} \cdot i, \quad (22)$$

pri čemu je *b* najveća (korigirana) frekvencija, *a* je frekvencija ispred nje, a *c* frekvencija iza najveće korigirane frekvencije. Kada su razredi jednakih veličina, umjesto korigiranih koristit će se originalne frekvencije. Modalni razred je razred s najvećom frekvencijom. Ako razredi nisu jednakih veličina potrebno je korigirati frekvencije.L_1 je donja granica modalnog razreda, a i njegova veličina.

2.5. Mjere disperzije

Srednje vrijednosti nisu dovoljne za opisivanje rasporeda podataka unutar jednog ili više nizova. Više različitih statističkih nizova može imati jednake srednje vrijednsti i zbog toga se uvode mjere disperzije (raspršenosti). Mjerama disperzije dobiva se uvid u u raspršenost pojave oko srednje vrijednosti (najčešće aritmetičke sredine). Dijele se na apsolutne i relativne. (Štambuk, Devčić, 2010.)

Apsolutne mjere disperzije su:

1. raspon varijacije,
2. varijanca,
3. standardna devijacija,
4. interkvartil.

Relativne mjere disperzije su:

1. koeficijent varijacije,
2. koeficijent kvartilne devijacije.

2.5.1. Raspon varijacije

Raspon varijacije R je najjednostavnija mjera disperzije. Ona govori u kojem se rasponu kreću vrijednosti numeričke varijable.

Za negrupirane podatke raspon varijacije jednak je razlici najveće i najmanje vrijednosti numeričkog obilježja.

$$R = x_{max} - x_{min}, \tag{23}$$

Kod grupiranih podataka raspon varijacije R računa se ili kao razlika gornje granice posljednjeg razreda i donje granice prvog razreda ili kao razlika razrednih sredina posljednjeg i prvog razreda. (Štambuk, Devčić, 2010.)

2.5.2. Varijanca

Varijanca σ^2 je aritmetička sredina kvadrata odstupanja vrijednosti numeričkog obilježja od njihove aritmetičke sredine.

Varijanca uzorka za negrupirane podatke se računa prema formuli

$$\sigma^2 = \frac{\sum_{i=1}^{n}(x_{i-}\bar{x})}{n-1}, \tag{24}$$

pri čemu je *n* broj elemenata, x_i je statistički niz, a $\overline{x}$ je aritmetička sredina danog statističkog niza.

Varijancu uzorka za grupirane podatke računamo prema formuli

$$\sigma^2 = \frac{\sum_{i=1}^{k} f_i x_i^2}{n-1} - \overline{x}^2, \tag{25}$$

pri čemu je x_i statistički niz, f_i pripadajuće frekvencije a $\overline{x}$ je aritmetička sredina distribucije.

Kod računanja varijance veća odstupanja kvadriranjem dolaze više do izražaja, te se na taj način „kažnjava“ postojanje ekstremnih rezultata u mjerenju. Općenito, varijanca se kao samostalna vrijednost ne koristi često, iako je ona vrlo korisna prilikom provođenja složenijih statističkih analiza.

2.5.3. Standardna devijacija

Standardna devijacija σ je pozitivni kvadratni korijen iz varijance. Ona izražava prosječno odstupanje vrijednosti numeričke varijable od njezine aritmetičke sredine. (Štambuk, Devčić, 2010.)

Uzoračka standardna devijacija za negrupirane podatke se računa prema formuli

$$\sigma = \sqrt{\frac{\sum_{i=1}^{n} (x_i^2 - \overline{x})^2}{n-1}}, \tag{26}$$

pri čemu je *n* broj elemenata statističkog niza, $\overline{x}$ je aritmetička sredina a x_i je i-ti član danog niza.

Uzoračka standardna devijacija za grupirane podatke računa se prema formuli

$$\sigma = \sqrt{\frac{\sum_{i=1}^{k} f_i \ (x_i - \overline{x})^2}{n-1}}, \tag{27}$$

pri čemu je pri čemu je *xi* statistički niz, f_i pripadajuće frekvencije a $\overline{x}$ je aritmetička sredina distribucije.

Standardna devijacija je mjera raspršenosti iskazana u mjernim jedinicama obilježja. Disperzija u različitim nizovima ne može se izravno usporediti sa standardnom devijacijom jer je ona ovisna o mjernim jedinicama i stupnju varijacije obilježja. (Šošić, 2004.)

Standardna devijacija je statistički pojam koji označava mjeru raspršenosti podataka u skupu. Interpretira se kao prosječno odstupanje od prosjeka i to u apsolutnom iznosu. (https://hr.wikipedia.org/wiki/Standardna_devijacija, 26. srpnja 2017.)

2.5.4. Interkvartil

Interkvartil je razlika između gornjeg i donjeg kvartila.

$$I_q = Q_3 - Q_1, \tag{28}$$

pri čemu je Q_3 treći (gornji) kvartil a Q_1 je prvi (gornji) kvartil.

Interkvartil I_q govori u kojem se rasponu oko medijana gomila 50% središnjih vrijednosti. Što je vrijednost interkvartila manja, to je 50% središnjih vrijednosti više nagomilano oko medijana i raspršenost je manja, a što je vrijednost interkvartila veća to je 50% središnjih vrijednosti raspoređeno na širem području i raspršenost je veća. (Štambuk, Devčić, 2010.)

2.5.5. Koeficijent varijacije

Koeficijent varijacije V je omjer standardne devijacije i aritmetičke sredine pomnožen sa 100%, tj:

$$V = \frac{\sigma}{\bar{x}} \cdot 100\% , \tag{29}$$

pri čemu je σ standardna devijacija a $\overline{x}$ je aritmetička sredina.

Koeficijent varijacije V je relativna mjera disperzije koja pokazuje koliki dio aritmetičke sredine u postotku iznosi standardna devijacija. Koeficijentom varijacije mjeri se koliko vjerno aritmetička sredina predstavlja neki numerički niz. (Štambuk, Devčić, 2010.)

2.5.6. Koeficijent kvartilne devijacije

Koeficijent kvartilne devijacije V_q je omjer razlike i zbroja gornjeg i donjeg kvartila.

$$V_q = \frac{Q_3 - Q_1}{Q_3 + Q_1}, \tag{30}$$

pri čemu je $Q_3 - Q_1$ razlika trećeg (gornjeg) i prvog (donjeg) kvartila, a $Q_3 + Q_1$ zbroj trećeg (gornjeg) i prvog (donjeg) kvartila.

Koeficijent kvartilne devijacije V_Q poprima vrijednosti iz intervala [0,1>. Što je V_Q bliži nuli to je disperzija relativno manja, a što je bliži jedinici to je disperzija relativno veća.

V_Q se približava nuli kada se razlika $Q_3 - Q_1$ približava nuli, a to je kada je razlika između Q_1 i Q_3 mala što znači da je 50% središnjih vrijednosti u malom segmentu $[Q_1, Q_3]$ pa je raspršenost mala.

V_Q se približava jedinici kada je razlika između Q_1 i Q_3 velika što znači da se 50% središnjih vrijednosti nalazi u relativno velikom segmentu $[Q_1, Q_3]$ pa je raspršenost velika. (Štambuk, Devčić, 2010.)

2.6. Mjere asimetrije

Mjerama simetrije mjeri se način rasporeda podataka u odnosu na aritmetičku sredinu. S obzirom na aritmetičku sredinu svaka distribucija može biti simetrična ili asimetrična. Kod simetričnih distribucija odstupanja od aritmetičke sredine međusobno se poništavaju, tj. zbog simetričnog rasporeda vrijednosti u odnosu na aritmetičku sredinu ukupan zbroj odstupanja od aritmetičke sredine jednak je nuli. Asimetrične distribucije ne zadovoljavaju to svojstvo. One mogu biti lijevo (negativno) ili desno (pozitivno) asimetrične. Lijevo asimetrična distribucija ima više negativnih odstupanja od aritmetičke sredine, dok desno asimetrična distribucija ima više pozitivnih odstupanja od aritmetičke sredine. Da bismo odredili kojoj vrsti pripada distribucija, koristimo koeficijente asimetričnosti. (Štambuk, Devčić, 2010.)

Koeficijenti asimetričnosti su:

1. Koeficijent simetrije,
2. Pearsonova mjera asimetrije,
3. Bowleyjeva mjera asimetrije.

2.6.1. Koeficijent asimetrije

Koeficijent asimetrije α_3 je treći moment oko sredine izražen u jedinicama standardne devijacije na treću potenciju, odnosno

$$\alpha_3 = \frac{\mu_3}{\sigma^3}, \tag{31}$$

Ako je distribucija podataka simetrična, zbroj pozitivnih i negativnih odstupanja bit će jednak nuli pa će i koeficijent asimetrije α_3 biti jednak nuli.

Ako je distribucija pozitivno asimetrična, biti će više odstupanja od aritmetičke sredine s pozitivnim predznakom od onih s negativnim pa će zbroj svih odstupanja podignutih na treću potenciju biti pozitivan.

Ako je distribucija negativno asimetrična, više je odstupanja s negativnim predznakom od onih s pozitivnim pa će i zbroj svih odstupanja podignutih na treću potenciju biti negativan. Tada je negativan i treći moment oko sredine, a odatle slijedi i da će koeficijent asimetrije α_3 biti negativan.

Iz toga zaključujemo da će za simetričnu distribuciju vrijediti da je $\alpha_3 = 0$. Za jaku pozitivnu asimetriju α_3 će se približavati vrijednosti 2. Za jaku negativnu asimetriju α_3 će se približavati vrijednosti -2. Za ekstremno asimetrične distribucije α_3 može poprimiti vrijednost veću od 2, odnosno manju od -2. Ti slučajevi su u praksi vrlo rijetki. (Štambuk, Devčić, 2010.)

Treći moment lakše se može izračunati pomoću momenata oko nule formulom

$$\alpha_3 = m_3 - 3m_1m_2 + 2m_1^3. \tag{32}$$

2.6.2. Pearsonova[2] mjera asimetrije

U simetričnoj distribuciji aritmetička sredina, medijan i mod imaju jednaku vrijednost. Ako je distribucija pozitivno asimetrična, aritmetička sredina je udaljena od moda prema većim vrijednostima, a ako je distribucija negativno asimetrična, aritmetička sredina je udaljena od moda prema najmanjim vrijednostima. (Štambuk, Devčić 2010.)

[2] Karl Pearson (1857. - 1936.), engleski statističar.

Pearson je tako uveo mjeru asimetrije sa

$$S_k = \frac{\bar{x} - M_o}{\sigma}, \tag{33}$$

Za simetrične distribucije vrijedi $S_k = 0$.
Za jaku pozitivnu asimetriju S_k će se približavati vrijednosti 3.
Za jaku negativnu asimetriju S_k će se približavati vrijednosti -3.

Pearsonova mjera asimetrije može se izračunati i pomoću medijana na slijedeći način

$$S_k = \frac{3(\bar{x} - M_e)}{\sigma}. \tag{34}$$

2.6.3. Bowleyjeva[3] mjera asimetrije

Bowley temelji svoju mjeru asimetrije na činjenici da je u simetričnoj distribuciji gornji kvartil jednako udaljen od medijana koliko je medijan od donjeg kvartila.

Bowleyjeva mjera asimetrije glasi

$$S_{kQ} = \frac{(Q_3 - M_e) - (M_e - Q_1)}{Q_3 - Q_1} = \frac{Q_1 + Q_3 - 2M_e}{Q_3 - Q_1}. \tag{35}$$

Za simetrične distribucije vrijedi $S_{kQ} = 0$.
Za jaku pozitivnu asimetriju S_{kQ} će se približavati vrijednosti 1.
Za negativnu asimetriju S_{kQ} će se približavati vrijednosti -1.

2.7. Mjera zaobljenosti

Mjerom zaobljenosti α_4 upotpunjuje se predodžba o izgledu distribucije. Njom se brojčano opisuje zaobljenost u okolini modalnog vrha distribucije. Za mjeru zaobljenosti koristi se četvrti moment oko sredine izražen u jedinicama standardne devijacije na četvrtu potenciju.

[3] Arthur Bowley (1869. - 1957.), engleski statističar i ekonomist.

Koeficijent je dan formulom

$$\alpha_4 = \frac{\mu_4}{\sigma^4}\,. \tag{36}$$

Zaobljenost se mjeri i uspoređuje sa zaobljenosti modalnog vrha normalne ili Gaussove[4] distribucije.

Za normalnu distribuciju je $\alpha_4 = 3$.

Ako je $\alpha_4 > 3$ distribucija je šiljastija (uža i viša) od normalne.

Ako je $\alpha_4 < 3$ distribucija je plosnatija (niža i šira) od normalne.

(Štambuk, Devčić, 2010.)

Izraz za četvrti moment oko sredine pojednostavljuje se upotrebom momenta oko nule i postaje

$$\mu_4 = m_4 - 4m_1m_3 + 6m_1^2m_2 - 3m_1^4. \tag{37}$$

3. ANALIZA BROJA PROMETNIH NESREĆA U REPUBLICI HRVATSKOJ

Osim Zakona o sigurnosti prometa na cestama, kao temeljnog normativnog instrumenta, Vlade Republike Hrvatske od 1994. godine, periodično (1994., 1996., 2001., 2006., 2011.) donose Nacionalni program sigurnosti cestovnog prometa kojim se teži smanjenju stradavanja na cestama u uvjetima povećanja i ubrzanja cestovnog prometa.Podaci o broju prometnih nesreća u Republici Hrvatskoj od 2008. do 2016. godine prikazani su u tablici 1. Svi podaci preuzeti su iz Biltena o sigurnosti cestovnog prometa, Ministarstva unutarnjih poslova.

S obzirom na rijetku primjenu geometrijska i harmonijska sredina su izostavljene iz proračuna, a budući da su sve vrijednosti statističkog niza različite mod je nemoguće odrediti.

Tablica 1: Broj prometnih nesreća u Republici Hrvatskoj od 2008. do 2016. godine

Policijska uprava	***Prometne nesreće***								
	2008.	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**

[4]Gaussova distribucija je najvažnija statistička distribucija i predstavlja model mnogih empiriskih pojava. Prvi ju je matematički opisao Carl Friedrich Gauss (1777. – 1855.), njemački matematičar.

požeško-slavonska	746	751	613	603	534	505	483	452	472
virovitičko-podr.	757	775	662	625	556	512	429	553	610
koprivničko-križe.	1.105	959	772	793	708	661	593	619	619
krapinsko-zagors.	1.008	1.081	907	818	761	707	677	675	727
bjelovarsko-bilog.	1.154	1.063	862	838	699	705	674	714	724
međimurska	1.065	897	719	685	686	743	712	809	747
dubrovačko-neretv	1.251	1.190	1.096	1.164	884	845	719	939	907
primorsko-goran.	4.478	4.135	3.790	3.674	3.359	3.289	3.184	2.881	2.988
varaždinska	1.586	1.528	1.202	1.153	1.065	1.174	1.083	1.186	1.212
ličko-senjska	**1.140**	**1.116**	**986**	**977**	**908**	**896**	**883**	**1.015**	**983**
splitsko-dalmatin.	5.067	5.037	4.677	4.465	3.670	3.204	2.659	2.907	2.964
brodsko-posavska	1.650	1.511	1.246	1.185	1.037	1.050	1.054	1.051	1.044
šibensko-kninska	1.273	1.210	1.071	1.004	801	691	1.011	1.095	1.187
zadarska	2.768	2.723	2.302	2.057	1.866	1.972	1.866	2.080	2.107
vukovarsko-srijem.	1.596	1.494	1.303	1.237	1.016	1.054	1.045	1.102	1.116
karlovačka	2.372	2.113	1.705	1.517	1.171	1.111	1.037	1.087	1.125
istarska	3.527	3.307	2.974	2.890	2.483	1.945	1.858	1.990	1.918
zagrebačka	16.314	15.157	13.735	13.031	11.681	9.698	8.559	8.365	7.877

sisačko-moslavač.	1.940	1.892	1.671	1.564	1.335	1.312	1.146	1.201	1.381
osječko-baranjska	2.685	2.530	2.101	2.163	1.895	1.947	1.716	1.850	1.949
UKUPNO	53.482	50.469	44.394	42.443	37.115	34.021	31.388	32.571	32.657

Izvor:http://stari.mup.hr/main.aspx?id=180991(5. rujna 2017.)

Iz tablice je vidljivo da nakon Zakona o sigurnosti prometa na cestama koji je Vlada donijela 2011. godine broj prometnih nesreća po županijama se uvelike smanjio. Najviše prometnih nesreća događa se u većim županijama kao što su zagrebačka, splitsko-dalmatinska, primorsko-goranska i istarska dok se najmanje prometnih nesreća događa u županijama sa manjim brojem stanovništva kao što su požeško-slavonska, virovitičko podravska, koprivničko-križevačka i međimurska.

Tablica 2. Relativne frekvencije broja prometnih nesreća u Republici Hrvatskoj prema županijama

Policijska uprava	***Relativne frekvencije (u %)***								
	2008.	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
požeško-slavonska	1,39	1,48	1,38	1,42	1,43	1,48	1,53	1,38	1,44
virovitičko-podr.	1,41	1,53	1,49	1,47	1,49	1,50	1,36	1,69	1,86
koprivničko-križe.	2,06	1,90	1,73	1,86	1,90	1,94	1,88	1,89	1,89
krapinsko-zagors.	1,88	2,14	2,04	1,92	2,05	2,07	2,15	2,07	2,22
bjelovarsko-bilog.	2,15	2,10	1,94	1,97	1,88	2,07	2,15	2,19	2,21
međimurska	1,99	1,77	1,61	1,61	1,84	2,18	2,26	2,48	2,28
dubrovačko-neretv.	2,33	2,35	2,46	2,74	2,38	2,48	2,29	2,88	2,77

primorsko-goran.	8,37	8,19	8,53	8,65	9,05	9,66	10,14	8,83	9,14
varaždinska	2,96	3,02	2,70	2,71	2,86	3,45	3,45	3,63	3,71
ličko-senjska	**2,13**	**2,21**	**2,22**	**2,30**	**2,44**	**2,63**	**2,81**	**3,11**	**3,01**
splitsko-dalmatin.	9,47	9,98	10,5	10,51	9,88	9,41	8,47	8,91	9,07
brodsko-posavska	3,08	2,99	2,80	2,79	2,79	3,08	3,35	3,22	3,19
šibensko-kninska	2,38	2,39	2,41	2,36	2,15	2,03	3,22	3,35	3,63
zadarska	5,17	5,39	5,18	4,84	5,02	5,79	5,94	6,38	6,45
vukovarsko-srijem.	2,98	2,96	2,93	2,91	2,73	3,09	3,32	3,38	3,41
karlovačka	4,43	4,18	3,84	3,57	3,15	3,26	3,30	3,33	3,44
istarska	6,59	6,55	6,69	6,80	6,69	5,71	5,91	6,10	5,87
zagrebačka	30,50	30,03	30,93	30,70	31,47	28,50	27,26	25,65	24,12
sisačko-moslavač.	3,62	3,74	3,76	3,68	3,59	3,85	3,65	3,68	4,22
osječko-baranjska	5,02	5,01	4,73	5,09	5,10	5,72	5,46	5,67	5,96
UKUPNO	100	100	100	100	100	100	100	100	100

Izvor: Izračun autorice

Na temelju podataka iz tablice 1 i tablice 2 može se zaključiti da se 2008. godine od ukupnog broja prometnih nesreća u Republici Hrvatskoj u ličko-senjskoj županiji dogodilo 2,13% nesreća, te je to najmanji postotak u toj županiji, dok se 2015. godine od ukupnog broja prometnih nesreća u Republici Hrvatskoj u ličko-senjskoj županiji dogodilo 3,11% nesreća te je to najveći postotak u istoj toj županiji u promatranom razdoblju. Od ukupnog broja prometnih nesreća u razdoblju od 2008. do 2016. godine najveći postotak ima zagrebačka

županija, 31,47%, 2012. godine, dok najmanji postotak ima požeško-slavonska županija sa 1,38%, i to 2010. i 2015. godine.

Na temelju podataka iz tablice 1 napravljen je izračun aritmetičkih sredina za razdoblje od 2008. do 2016.godine. Aritmetička sredina izračunata je primjenom formule (3) pa tako primjerice za 2008. godinu prosječan broj prometnih nesreća iznosi:

$$\overline{x} = \frac{746+757+1105+1008+1154+1.065+1251+4478+1586+1140+5067+1650+1273+2768+}{20}$$

$$\frac{1596+2372+3527+16314+1940+2685}{20} = 2674{,}1.$$

Analogno je izračunat prosječan broj prometnih nesreća za svaku promatranu godinu pojedinačno. Dobivene vrijednosti prikazane su u tablici 3.

Tablica 3: Prosječan broj prometnih nesreća

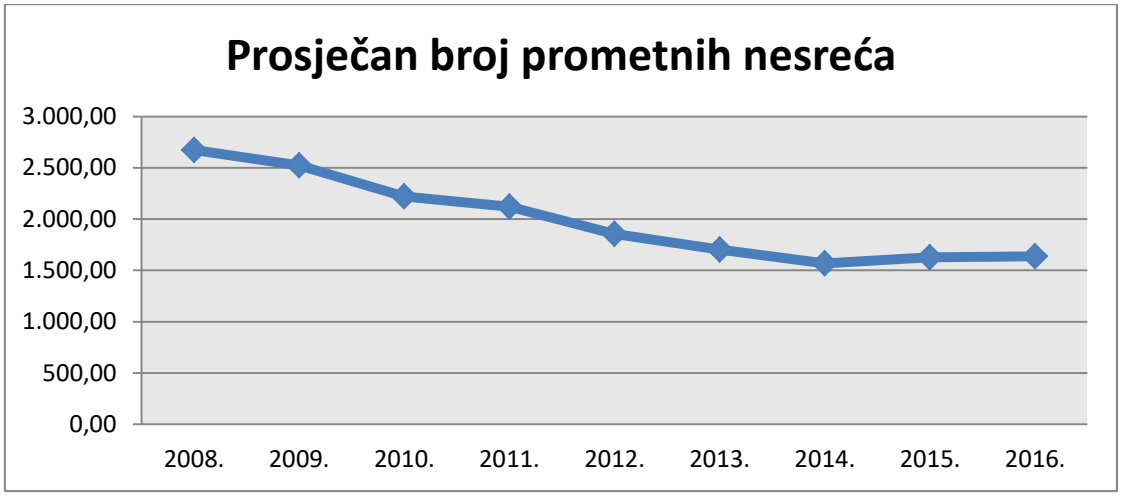
Godina	Prosječan broj prometnih nesreća
2008.	2674,1
2009.	2523,5
2010.	2219,7
2011.	2122,2
2012.	1855,7
2013.	1701,1
2014.	1569,4
2015.	1628,5
2016.	1632,9

Izvor: Izračun autorice

Na temelju dobivenih podataka koji su prikazani u tablici 3 može se zaključiti da se Ličko-senjska županija nalazi ispod prosjeka po broju prometnih nesreća u proteklih devet godina.

Radi lakše preglednosti dobiveni pokazatelji prikazani su na grafikonu 1.

Grafikon 1: Prosječan broj prometnih nesreća



Izvor: Izrada autorice

Na temelju podataka iz tablice 1, primjenom formule (10) napravljen je izračun medijana za razdoblje od 2008. do 2016. godine. Medijan za 2008. godinu iznosi:

$$\text{Me} = \frac{1596+1650}{2} = 1591.$$

Analogno je izračunat medijan za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 4.

Tablica 4: Vrijednost medijana za razdoblje od 2008. do 2016. godine

Godina	Vrijednost medijana
2008.	1591
2009.	1503
2010.	1224
2011.	1174
2012.	1027
2013.	1052
2014.	1041
2015.	1091
2016.	1121

Izvor: Izračun autorice

50% prometnih nesreća u Republici Hrvatskoj ima vrijednost manju ili jednaku od dobivenog medijana, a 50% prometnih nesreća ima vrijednost veću ili jednaku od dobivenog medijana u razdoblju od 2008. do 2016. godine. Napravljena je usporedba podataka iz tablice 1 i tablice 4 na temelju koje se može se zaključiti da se broj prometnih nesreća u ličko-senjskoj županiji tijekom navedenog razdoblja nalazi ispod vrijednosti dobivenog medijana, odnosno ličko-senjska županija ima vrijednost manju od medijana.

Koristeći podatke iz tablice 1, dan je izračun kvartila za promatrano razdoblje primjenom formule (13), pa tako kvartili za 2008. godinu iznose:

$$Q_1 = \frac{1105+1140}{2} = 1131.$$

$$Q_3 = \frac{2768+3372}{2} = 2727.$$

Vrijednosti kvartila za svaku promatranu godinu pojedinačno prikazani su u tablici 5.

Tablica 5: Vrijednosti kvartila za razdoblje od 2008. do 2016.godine

Godina	Vrijednost donjeg kvartila Q_1	Vrijednost gornjeg kvartila Q_3
2008.	1131	2727
2009.	1072	2627
2010.	885	2202
2011.	828	2110
2012.	735	1881
2013.	706	1946
2014.	695	1787
2015.	762	1920
2016.	737	1934

Izvor: Izračun autorice

25% prometnih nesreća u Republici Hrvatskoj u razdoblju od 2008. do 2016. godine ima vrijednost manju ili jednaku od donjeg kvartila Q_1, a 75% prometnih nesreća ima vrijednost

veću ili jednaku od kvartila Q_1. Na temelju uspoređenih podataka iz tablica 1 i 5 vidljivo je da je broj prometnih nesreća u ličko-senjskoj županiji manji od dobivenih vrijednosti donjeg kvartila, odnosno ličko-senjska županija se nalazi u 25% prometnih nesreća koje imaju vrijednost manju od donjeg kvartila.

75% prometnih nesreća ima vrijednost manju ili jednaku od gornjeg kvartila Q_3, a 25% prometnih nesreća ima vrijednost veću ili jednaku od kvartila Q_3. Na temelju podataka iz tablica 1 i 4 može se zaključiti da je broj prometnih nesreća u ličko-senjskoj županiji ispod dobivenih vrijednosti gornjeg kvartila, pa ličko-senjska županija spada u 75% prometnih nesreća koje imaju vrijednost manju od gornjeg kvartila.

Na temelju podataka iz tablice 1 primjenom formule (16) izračunat je prvi decil za razdoblje od 2008. do 2016. godine, pa tako prvi decil za 2008. godinu iznosi:

$$D_1 = \frac{757+1008}{2} = 883.$$

Vrijednosti prvog decila za svaku promatranu godinu pojedinačno prikazani su u tablici 6.

Tablica 6: Vrijednosti prvog decila za razdoblje od 2008. do 2016. godine

Godina	Vrijednost prvog decila
2008.	883
2009.	836
2010.	691
2011.	655
2012.	621
2013.	587
2014.	538
2015.	586
2016.	615

Izvor: Izračun autorice

10% prometnih nesreća u Republici Hrvatskoj u razdoblju od 2008. do 2016. godine ima vrijednost manju od prvog decila D_1, dok 90'% prometnih nesreća ima vrijednost veću od prvog decila D_1. Na temelju podataka iz tablice 1 i tablice 6 vidljivo je da je broj prometnih

nesreća u ličko-senjskoj županiji u navedenom razdoblju veći od dobivenih vrijednosti prvog decila, odnosno ličko-senjska županija se nalazi u 90% prometnih nesreća koje imaju vrijednost veću od prvog decila.

Na temelju podataka iz tablice 1, primjenom formule (23) izračunat je raspon varijacije, pa tako raspon varijacije za 2008. godinu iznosi:

$$R = 16\,314 - 746 = 15\,568.$$

Analogno je izračunat raspon varijacije za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 7.

Tablica 7: Vrijednosti raspona varijacije za razdoblje od 2008. do 2016. godine

Godina	Vrijednosti raspona varijacije
2008.	15 568
2009.	14 406
2010.	13 122
2011.	12 428
2012.	11 147
2013.	9193
2014.	8130
2015.	7913
2016.	7405

Izvor: Izračun autorice

Na temelju dobivenih podataka koji su prikazani u tablici 7 vidljivo je da je broj prometnih nesreća 2008. bio najveći, odnosno 15 568, a 2016. godine je bio najmanji, 7405, prema tome može se zaljučiti da se broj prometnih nesreća svake naredne godine smanjivao.

Na temelju podataka iz tablice 1 i tablice 3, primjenom formule (24) izračunata je varijanca koja za 2008. godinu iznosi

$$\sigma^2$$

$$= \frac{(746-2674{,}1)^2+(757-2674{,}1)^2+(1\,105-2674{,}1)^2+(1008-2674{,}1)^2+(1154-2674{,}1)^2+}{20-1}$$

$$\frac{1065-2674{,}1)^2+(1\,251-2674{,}1)^2+(4478-2674.1)^2+(1586-2674{,}1)^2+(1140-2674{,}1)^2+}{20-1}$$

$$\frac{(5067-2674{,}1)^2+(1650-2674{,}1)^2+(1273-2674{,}1)^2+(2768-2674{,}1)^2+(\,1596-2674{,}1)^2+}{20-1}$$

$$\frac{2372-2674{,}1)^2+(3527-2674{,}1)^2+(16314-2674{,}1)^2+(1940-2674{,}1)^2+(2685-2674{,}1)^2}{20-1} =$$

$$\sigma^2 = \frac{223.660.951{,}4}{19} = 11\,771\,629.$$

Analogno je izračunata varijanca za svaku godinu pojedinačno a dobivene vrijednosti prikazane su u tablici 8.

Tablica 8: Vrijednosti varijance za razdoblje od 2008. do 2016. godine

Godina	Vrijednosti varijance
2008.	11 771 629
2009.	10 200 400
2010.	8 532 256
2011.	7 683 435
2012.	6 149 282
2013.	4 198 433
2014.	3 229 204
2015.	3 019 118
2016.	2 690 376

Izvor: Izračun autorice

Na temelju podataka iz tablice 8 i primjenom formule (26) izračunata je standardna devijacija koja za 2008. godinu iznosi

$$\sigma = \sqrt{11\,771\,629} = 3\,430{,}98$$

Vrijednosti standardne devijacije za svaku godinu pojedinačno prikazane su u tablici 9.

Tablica 9: Vrijednosti standardne devijacije za razdoblje od 2008. do 2016. godine

Godina	Vrijednosti standardne devijacije
2008.	3 430,98
2009.	3 193,80
2010.	2 921,00
2011.	2 771,90
2012.	2 479,77
2013.	2 049,00
2014.	1 796,99
2015.	1 737,56
2016.	1 640,23

Izvor: Izračun autorice

Uspoređivanjem podataka iz tablice 3 i tablice 9 može se zaključiti da su dobivene vrijednosti standardne devijacije veće od vrijednosti aritmetičke sredine.

Na temelju podataka iz tablice 5 i primjenom formule (28) izračunat je interkvartil za 2008. godinu koji iznosi:

$$I_q = 2727 - 1131 = 1595.$$

Dobivene vrijednosti interkvartila za svaku promatranu godinu prikazane su su tablici 10.

Tablica 10: Vrijednosti interkvartila za razdoblje od 2008. do 2016. godine

Godina	Vrijednosti interkvartila
2008.	1595
2009.	1550
2010.	1306
2011.	1277
2012.	1133
2013.	1240
2014.	1084
2015.	1135

2016.	1192

Izvor: Izračun autorice

Uspoređivanjem podataka iz tablica 1 i 10 vidljivo je da u razdoblju od 2008. do 2016. godine broj prometnih nesreća u ličko-senjskoj županiji se nalazi ispod dobivenih vrijednosti interkvartila.

Na temelju podataka iz tablice 3 i tablice 9 i primjenom formule (29) izračunat je koeficijent varijacije za 2008. godinu koji iznosi

$$V = \frac{3\,430{,}98}{2\,674{,}1} \cdot 100\% = 128\%$$

Analogno je izračunat koeficijent varijacije za svaku promatranu godinu pojedinačno, a dobiveni rezultati prikazani su u tablici 11.

Tablica 11: Vrijednosti koeficijenta varijacije za razdoblje od 2008. do 2016. godine

Godina	**Vrijednosti koeficijenta varijacije**
2008.	128%
2009.	127%
2010.	132%
2011.	131%
2012.	134%
2013.	120%
2014.	114%
2015.	107%
2016.	100%

Izvor: Izračun autorice

Dobiveni rezultati pokazuju da koeficijent varijacije u razdoblju od 2008. do 2016. godine prelazi vrijednost od 20% pa se na temelju toga može zaključiti da je vrijednost standardne devijacije velika u odnosu na vrijednost aritmetičke sredine. Budući da koeficijent varijacije

prelazi iznos od 100% može se reći da pokazuje nedovoljnu reprezentativnost aritmetičke sredine.

Na temelju podataka iz tablice 5 i primjenom formule (30) izračunat je koeficijent kvartilne devijacije za 2008. godinu koji iznosi:

$$V_q = \frac{3070-1131}{3070+1131} = \frac{1939}{4201} = 0{,}4135.$$

Analogno je izračunat koeficijent kvartilne devijacije za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 12.

.

Tablica 12: Vrijednosti koeficijenta kvartilne devijacije za razdoblje od 2008. do 2016. godine

Godina	Koeficijent kvartilne devijacije
2008.	0,4135
2009.	0,4185
2010.	0,4215
2011.	0,4339
2012.	0,4309
2013.	0,4672
2014.	0,4351
2015.	0,4194
2016.	0,4453

Izvor: Izračun autorice

Dobiveni podaci koji su prikazani u tablici 12 pokazuju da se radi o relativno velikoj disperziji. Budući da se koeficijent kvartilne devijacije dobije primjenom interkvartila, usporede li se podaci iz tablice 10 i tablice 12 vidljivo je da 2013. godine raspon u kojem se kreće 50% središnjih vrijednosti iznosi 1240, a u relativnom iznosu je to 0,4672. To je ujedno i najveća dobivena vrijednost koeficijenta kvartilne devijacije.

Na temelju podataka iz tablice 1, izračunata je prosječna stopa promjene broja prometnih nesreća po županijama u promatranom razdoblju. Prosječna stopa izračunata je primjenom formule (9), pa tako za požeško-slavonsku županiju iznosi:

$$G = \left[\sqrt[8]{\frac{472}{746}} - 1\right]100 = -5{,}56\%$$

Analogno je izračunata prosječna stopa promjene za svaku županiju pojedinačno za promatrano razdoblje. Dobiveni rezultat prikazan je u tablici 13.

Tablica 13: Prosječna stopa promjene broja prometnih nesreća

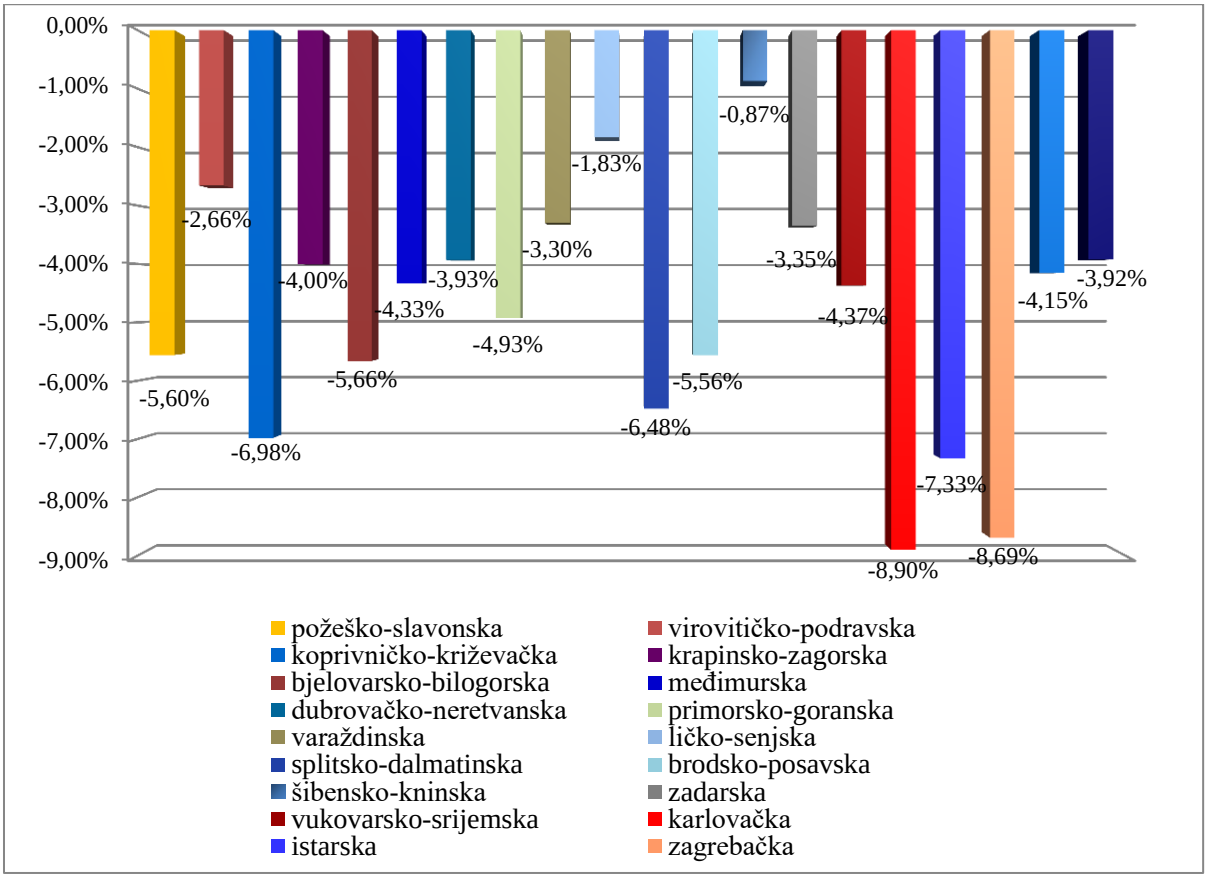
Policijska uprava	**Prosječna stopa promjene broja prometnih nesreća**
Požeško-slavonska	-5,56%
virovitičko-podravska	-2,66%
koprivničko-križevačka	-6,98%
krapinsko zagorska	-4,00%
bjelovarsko bilogorska	-5,66%
međimurska	-4,33%
dubrovačko-neretvanska	-3,93%
primorsko-goranska	-4,93%
varaždinska	-3,30%
ličko-senjska	-1,83%
splitsko-dalmatinska	-6,48%
brodsko-posavska	-5,56%
šibensko-kninska	-0,87%
zadarska	-3,35%
vukovarsko-srijemska	-4,37%
karlovačka	-8,90%
istarska	-7,33%
zagrebačka	-8,69%
sisačko-moslavačka	-4,15%

osječko-baranjska	-3,92%

Izvor: Izračun autorice

Na temelju dobivenih podataka može se zaključiti da se prosječna stopa promjene broja prometnih nesreća u razdoblju od 2008. do 2016. godine po županijama u Republici Hrvatskoj smanjivala. U ličko-senjskoj županiji u navedenom razdoblju broj prometnih nesreća se smanjivao prosječno godišnje 1,83%. Nakon šibensko-kninske županije to je najmanja stopa promjene broja prometnih nesreća. Najveća stopa promjene dogodila se u karlovačkoj i zagrebačkoj županiji. Dobiveni rezultati prikazani su grafički.

Grafikon 2: Prosječna stopa promjene broja prometnih nesreća po županijama



Izvor: Izrada autorice

Na temelju podataka iz tablice 1 i primjenom formule (32) izračunat je treći moment za 2008. godinu koji iznosi

$$\alpha_3 = 2{,}34545 \cdot 10^{11} - 1{,}4708 \cdot 10^{11} + 38\ 243\ 966\ 374 = 1{,}2571 \cdot 10^{11}$$

Na temelju dobivenog rezultata i primjenom formule (31) dobiven je koeficijent asimetrije koji za 2008. godinu iznosi

$$\alpha_3 = \frac{1{,}2571 \cdot 10^{11}}{40\ 388\ 205\ 689} = 3{,}11$$

Analogno je izračunat koeficijent asimetrije za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 14.

Tablica 14: Vrijednosti koeficijenta asimetrije za razdoblje od 2008. do 2016. godine

Godina	Vrijednosti koeficijenta asimetrije
2008.	3,11
2009.	3,07
2010.	3,04
2011.	3,03
2012.	3,09
2013.	2,95
2014.	2,92
2015.	2,88
2016.	2,73

Izvor: Izračun autorice

Budući da dobiveni podaci koji su prikazani u tablici 14 imaju vrijednost veću od 2 može se zaključiti da je distribucija ekstremno asimetrična. 2008. godine zabilježena je najveća vrijednost 3,11, dok je 2016. godine zabilježena najmanja vrijednost, odnosno 2,73.

Na temelju podataka iz tablice 1 i primjenom formule (34) izračunata je Pearsonova mjera asimetrije koja za 2008. godinu iznosi

$$S_k = \frac{3\,(2674{,}1-1623)}{3344{,}11} = 0{,}94$$

Analogno je izračunata Pearsonova mjera asimetrije za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 15.

Tablica 15: Vrijednost Pearsonove mjere asimetrije za razdoblje od 2008. do 2016. godine

Godina	Vrijednost Pearsonove mjere asimetrije
2008.	0,94
2009.	0,95
2010.	1,02

2011.	1,02
2012.	1,00
2013.	0,95
2014.	0,88
2015.	0,92
2016.	0,93

Izvor: Izračun autorice

Na temelju dobivenih podataka iz tablice 15 može se zaključiti da je distribucija blago pozitivno asimetrična. 2010. I 2011. godine zabilježena je najveća asimetričnost koja iznosi 1,02, dok je 2014. godine zabilježena najmanja asimetričnost s vrijednosti 0,88.

Na temelju podataka iz tablice 1, primjenom formule (35) izračunata je Bowleyjeva mjera asimetrije koja za 2008. godinu iznosi:

$$S_{kQ} = \frac{1131+3.070-2\cdot 1591}{3070-1131} = 0,42$$

Analogno je izračunata Bowleyjeva mjera asimetrije za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 16.

Tablica 16: Vrijednosti Bowleyjeve mjere asimetrije za razdoblje od 2008. do 2016. godine

Godina	**Vrijednost Bowleyjeve mjere asimetrije**
2008.	0,42
2009.	0,45
2010.	0,49
2011.	0,46
2012.	0,50
2013.	0,44
2014.	0,37
2015.	0,46
2016.	0,36

Izvor: Izračun autorice

Na temelju dobivenih podataka koji su prikazani u tablici 16 može se zaključiti da je distribucija pozitivno asimetrična. 2012. godine zabilježena je najveća pozitivna asimetričnost s vrijednosti 0,50 te ona predstavlja jaku pozitivnu asimetriju, dok 2016. godine ima najmanju vrijednost, odnosno 0,36, pa je ona blago pozitivno asimetrična.

Koristeći podatke iz tablice 1, primjenom formule (37) izračunat je četvrti moment oko sredine koji za 2008. godinu iznosi

$$\mu_4 = 3{,}61199 \cdot 10^{15} - 2{,}50879 \cdot 10^{15} + 7{,}86612 \cdot 10^{14} - 1{,}53402 \cdot 10^{14} = 1{,}73641 \cdot 10^{15}$$

Na temelju dobivenog rezultata i primjenom formule (36) dobivena je mjera zaobljenosti koja za 2008. godinu iznosi

$$\alpha_4 = \frac{1{,}73641 \cdot 10^{15}}{1{,}25061 \cdot 10^{14}} = 12{,}53.$$

Analogno je izračunata mjera zaobljenosti za svaku promatranu godinu pojedinačno, a dobivene vrijednosti prikazane su u tablici 17.

Tablica 17: Vrijednosti mjere zaobljenosti za razdoblje od 2008. do 2016. godine

Godina	Vrijednosti mjere zaobljenosti
2008.	12,53
2009.	11,72
2010.	10,37
2011.	9,86
2012.	8,91
2013.	7,38
2014.	6,61
2015.	6,62
2016.	6,11

Izvor: Izračun autorice

Na temelju dobivenih podataka koji su prikazani u tablici 17, može se zaključiti da je distribucija šiljastija, odnosno uža i viša od normalne. 2008. godine zabilježena je najveća vrijednost distribucije, 12,53, dok je 2016. godine zabilježena najmanja vrijednost distribucije, odnosno 6,11.

4. ZAKLJUČAK

Prometne su nesreće najvećim dijelom uzrokovane vožnjom neprilagođenom brzinom, ali i alkoholiziranost uvelike pridonosi nastanku prometnih nesreća. Na ponašanje čovjeka kao čimbenika sigurnosti u prometu utječu osobne značajke vozača, psihofizičke osobine, obrazovanje i kultura. Analize su pokazale da je upravo čovjek najčešći uzrok prometnih nesreća. U današnje vrijeme nastoji se što više ulagati u izgradnju i održavanje cesta kako bi se podignula razina kvalitete prometnica u Republici Hrvatskoj. Statističke analize također su važne u svim prometnim segmentima. Analizirajući statističke podatke prometnih nesreća u Republici Hrvatskoj, može se zaključiti da su izmjene Zakona o sigurnosti prometa na cestama u pravilu slijedile u godini nakon što se dogodio veliki broj prometnih nesreća. Godina koja je slijedila nakon izmjena Zakona statistički gledano imala je manje prometnih nesreća od prethodnih godina. Na kraju obrađenog razdoblja uočava se smanjenje prometnih nesreća, kako u Republici Hrvatskoj tako i u ličko-senjskoj županiji.

Marina Bubaš

Marina Bubaš

(potpis studenta)

LITERATURA

KNJIGE:

1. Štambuk, Lj., Devčić, K.: Statistika, priručnik i zbirka zadataka, Gospić, 2010.
2. Šošić, I.: Statistika, Zagreb, 2004.
3. Šošić, I.: Primijenjena statistika, Zagreb, 2006.

INTERNET:

1. https://bs.wikipedia.org/wiki/Statistika (15. srpnja 2017.)
2. Statistika MUP-a i Bilteni o sigurnosti cestovnog prometa (http://stari.mup.hr/main.aspx?id=180991) (5. rujna 2017.)

POPIS TABLICA

Redni broj	Naslov	Broj stranice
1.	Broj prometnih nesreća u Republici Hrvatskoj od 2008. do 2016. godine	20
2.	Relativne frekvencije broja prometnih nesreća u Republici Hrvatskoj prema županijama	22
3.	Prosječan broj prometnih nesreća	24
4.	Vrijednost medijana za razdoblje od 2009. do 2016. godine	26
5.	Vrijednost kvartila za razdoblje od 2009. do 2016.godine	27
6.	Vrijednost prvog decila za razdoblje od 2009. do 2016. godine	28
7.	Vrijednosti raspona varijacije za razdoblje od 2008. do 2016. godine	29
8.	Vrijednosti varijance za razdoblje od 2008. do 2016. godine	30
9.	Vrijednost standardne devijacije za razdoblje od 2009. do 2016. godine	31
10.	Vrijednosti interkvartila za razdoblje od 2009. do 2016. godine	31
11.	Vrijednosti koeficijent varijacije za razdoblje od 2009. do 2016 godine	32
12.	Vrijednosti koeficijenta kvartilne devijacije za razdoblje od 2008. do 2016. godine	33
13.	Prosječna stopa promjene broja prometnih nesreća	34
14.	Vrijednosti koeficijenta asimetrije za razdoblje od 2008. do 2016. godine	37
15.	Vrijednosti Pearsonove mjere asimetrije za razdoblje od 2008. do 2016. godine	38
16.	Vrijednosti Bowleyjeve mjere asimetrije za razdoblje od 2008. do 2016. godine	38
17.	Vrijednosti mjere zaobljenosti za razdoblje od 2008. do 2016. godine	40

POPIS GRAFIKONA

Redni broj	Naslov	Broj stranice
1.	Prosječan broj prometnih nesreća	26
2.	Prosječna stopa promjene broja prometnih nesreća po županijama	36