

Sveučilište u Zagrebu  
Prirodoslovno matematički fakultet  
Matematički odsjek

Zoran Gajari

# **PROSTORNA ANALIZA PROMETNIH NESREĆA U REPUBLICI HRVATSKOJ**

Završni rad

Voditelj rada:  
Izv.prof.dr.sc. Miljenko Huzak

Zagreb, 2017.

## Sadržaj

<u>1.</u>	Uvod .....	6
<u>2.</u>	Uvod u prostornu korelacijsku analizu.....	8
2.1.	Globalni indikator prostorne asocijacije.....	9
2.1.1	Moranov indeks (Moran's I) .....	9
2.2.	Lokalni indikatori prostorne asocijacije .....	13
2.2.1	Lokalni Moranov indeks.....	13
2.2.2	Statistika $G_i$ (Getis Ord) .....	16
<u>3.</u>	Praktična primjena indikatora prostorne asocijacije.....	18
3.1	Podaci po registracijskim područjima .....	19
3.1.1	Globalni Moranov indeks s obzirom na broj prometnih nesreća po registracijskim područjima.....	22
3.1.2	Lokalni Moranov indeks za broj prometnih nesreća po registracijskim područjima .....	23
3.1.3.	Utvrđivanje koncentracije viših vrijednosti „hot spot“ i nižih vrijednosti „cold spots“ broja prometnih nesreća po registracijskim područjima .....	23
3.1.4	Globalni Moranov indeks za stopu prometnih nesreća (u odnosu na 10.000 stanovnika) po registarskim područjima .....	24
3.1.5	Lokalni Moranov indeks za stopu prometnih nesreća ( u odnosu na 10.000 stanovnika) po registarskim područjima .....	24
3.1.6	Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ obzirom na stopu prometnih nesreća ( u odnosu na 10.000 stanovnika) po registarskim područjima .....	25
3.1.7	Globalni Moranov indeks za broj registriranih vozila po registarskim područjima .....	26

3.1.8 Lokalni Moranov indeks za broj registriranih vozila po registarskim područjima .....	26
3.1.9 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za broj registriranih vozila po registarskim područjima.....	27
3.1.10 Globalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila po registarskim područjima .....	28
3.1.11 Lokalni Moranov indeks za stopu broja prometnih nesreća na 10 000 registriranih vozila po registarskim područjima .....	28
3.1.12 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za stopu broja prometnih nesreća na 10 000 registriranih vozila po registarskim područjima.....	29
3.1.13 Globalni Moranov indeks za visinu premije za osiguranje od auto odgovornosti za 2016. godinu, po registarskim područjima.....	30
3.1.14 Lokalni Moranov indeks za visinu premije za osiguranje od auto odgovornosti za 2016. godinu, po registarskim područjima.....	31
3.1.15 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za visinu premije za osiguranje od auto odgovornosti za 2016. godinu, po registarskim područjima.....	32
3.1.16 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati globalni Moranov indeks po registarskim područjima.....	33
3.1.17 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati lokalni Moranov indeks po registarskim područjima.....	34
3.1.18 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ po registarskim područjima.....	34
3.2. Podaci po područjima koja obuhvaćaju policijske postaje.....	36
3.2.1 Globalni Moranov indeks za broj prometnih nesreća na područjima policijskih postaja .....	40
3.2.2 Lokalni Moranov indeks za broj prometnih nesreća na područjima policijskih postaja .....	40

3.2.3 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ u odnosu na broj prometnih nesreća, na područjima policijskih postaja .....	41
3.2.4 Globalni Moranov indeks za stopu prometnih nesreća po policijskim postajama (u odnosu na 10.000 stanovnika) .....	43
3.2.5 Lokalni Moranov indeks za stopu prometnih nesreća na područjima policijskih postaja (u odnosu na 10.000 stanovnika) .....	43
3.2.6 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za stopu prometnih nesreća na područjima policijskih postaja (u odnosu na 10.000 stanovnika).....	44
3.2.7 Globalni Moranov indeks za broj registriranih vozila na područjima policijskih postaja .....	46
3.2.8 Lokalni Moranov koeficijent za broj registriranih vozila na područjima policijskih postaja .....	47
3.2.9 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ s obzirom na ukupni broj registriranih vozila na područjima policijskih postaja .....	48
3.2.10 Globalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila na područjima policijskih postaja .....	49
3.2.11 Lokalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila na područjima policijskih postaja .....	50
3.2.12 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za stopu prometnih nesreća na 10.000 registriranih vozila, na područjima policijskih postaja .....	51
3.2.13 Globalni Moranov indeks za premiju za osiguranje od auto odgovornosti na područjima policijskih postaja, u 2016. godini .....	52
3.2.14 Lokalni Moranov indeks za premiju za osiguranje od auto odgovornosti na područjima policijskih postaja, u 2016. godini .....	53
3.2.15 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za premiju za osiguranje od auto odgovornosti, za 2016. godinu, za područja policijskih postaja .....	54

3.2.16 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati globalni Moranov indeks .....	56
3.2.17 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati lokalni Moranov indeks .....	57
3.2.18 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te utvrđivanje koncentracije viših vrijednosti „ <i>hot spots</i> “ i nižih vrijednosti „ <i>cold spots</i> “ .....	58
<a href="#">4.</a> Utvrđivanje povezanosti varijabli navedenih u tablicama 1 i 2 uz pomoć Pearsonovog koeficijenta korelacije.....	60
<a href="#">5.</a> Zaključak .....	65
<a href="#">6.</a> Literatura: .....	67
<a href="#">7.</a> Sažetak.....	69
<a href="#">8.</a> Abstract .....	70
<a href="#">9.</a> Životopis.....	71

# 1. Uvod

Uvriježena praksa koju provode osiguravajuća društva je da se visina premije za police osiguranja od automobilske odgovornosti utvrđuje po registarskim područjima, ovisno o broju prijavljenih šteta po policama, odnosno broju prometnih nesreća. Na registarskim područjima na kojima imamo više prijavljenih šteta, proisteklih iz prometnih nesreća, obračunava se veća premija po policama za auto odgovornosti, a kod registarskih područja sa manjim brojem prijavljenih šteta, obračunava se manja premija (što možemo vidjeti kroz popularnost registarskih pločica grada Daruvara).

Metodu utvrđivanja buduće premije za osiguranja od auto odgovornosti koju primjenjuju osiguravajuća društva možemo smatrati jednostavnom obzirom da se za pokazatelje, koji su predmet obrade, uzimaju samo podaci koji se odnose na broj prometnih nezgoda. Ne ulazeći u diskusiju u pogledu pouzdanost takvog načina utvrđivanja visine premije cilj ove radnje je prezentiranja drugih metoda, koje bi osiguravajućim društvima davala dodatne podatke ili širu sliku problematike vezane za prometne nezgode, te predodžbu povezanosti određenih geografskih područja i njihov međusobni utjecaja s obzirom na broj prometnih nezgoda koje se pojavljuju.

U slučaju da imamo dva susjedna područja registarskih pločica kojima osiguravajuća društva obračunavaju različitu premiju za police od auto odgovornosti, te je utvrđena povezanost područja, s obzirom na prostornu autokorelacija pokazatelja koje se pojavljuju na svakom od njih, točnije broj prometnih nesreća, možemo postaviti pitanje je li broj prijavljenih šteta po policama od auto odgovornosti proisteklih iz prometnih nezgoda dovoljan pokazatelj kod utvrđivanja visine premije?

Uzmimo registarska područje Zagreba, Bjelovara i Križevaca, na kojima se obračunavaju različite visine premije. U slučaju da se utvrdi značajna autokorelacija između broja prometnih nesreća koje su se dogodila, u određenoj godini, na navedenim područjima, postavljamo pitanje je li ispravno obračunavati na području Zagreba višu premiju nego na područjima Bjelovara i Križevaca, ili bi bilo za osiguravajuća društva financijski isplativije, obračunavati za sva tri područja istu premiju, s obzirom na prostornu povezanost broja prometnih nesreća.

U ovoj radnji osim broja prometnih nezgoda, uzeli smo i druge pokazatelje koji se pojavljuju na području registarskih pločica, ali i na području policijskih postaja.

Utvrđivanje prostorne autokorelacije korisna je i u prevenciji prometnih nezgoda na način da se pojedina područje na kojima se događa veći broj prometnih nezgoda može promatrati kroz povezanost sa susjednim područjima, te kroz njihov međusobnim utjecaj. U slučaju da postoji prostorna autokorelacija s obzirom na broj prometnih nesreća na području susjednih policijskih postaja da li bi možda bilo učinkovitije obavljati zajedničku pojačanu prevenciju na prometnicama nego samo na području jedne policijske postaje koje je područje visokog rizika. Osobno smatram da bi bilo prihvatljivije, što će biti prikazano u ovom radu.

U poglavlju 2 ove radnje definiramo pojam prostorne autokorelacije, kao i indikatore uz pomoću kojih utvrđujemo prostornu autokorelaciju određenih pokazatelja koji se pojavljuju na određenim geografskim područjima. U poglavlju 3 bavimo se praktičnom primjenom indikatora prostorne autokorelacije, točnije prostornom povezanosti varijabli s obzirom na njihove vrijednosti (broj prometnih nesreća, broj registriranih vozila, te visina premije), na područjima registarskih oznaka i policijskih postaja. Poglavlje 4 se odnosi na utvrđivanje povezanosti navedenih varijabli uz pomoć Pearsonovog koeficijenta korelacije.

## 2. Uvod u prostornu korelacijsku analizu

Temeljni cilj ove radnje je procjena međusobnog utjecaja, kao i povezanost pokazatelja (varijabli), **prostorna autokorelacija**, koji se javljaju na pojedinim geografskim područjima.

Pokazatelji su (podaci se odnose na navedene pokazatelje):

- ukupni broj prometnih nesreća (2015. god.)
- broj prometnih nesreća na 10.000 stanovnika (2015. god.)
- ukupni broj registriranih vozila (2015. god.)
- broj prometnih nesreća na 10.000 registriranih vozila (2015. god.)
- premija za osobna i teretna vozila (2016. god.)

Geografska područja na kojima se javljaju navedeni pokazatelji su područja registarskih tablica (tablica 1.) i područja koju se u nadležnosti policijskih postaja (tablica 2.), na području Sjeverne Hrvatske.

**Općenito, prostorna autokorelacija je usporedba sličnosti objekta ili aktivnosti na zemljinoj površini sa susjednim objektima ili aktivnostima (vidjeti [5]).**

Prostorna autokorelacija također bi se mogla smatrati kao odnos između vrijednosti pojedinih varijabli koje se javljaju radi geografskog uređenja područja u kojemu se te varijable pojavljuju. Ona mjeri sličnost objekata unutar jednog područja, stupanj po kojemu je neki prostorni fenomen u korelaciji sam sa sobom u prostoru, razinu nezavisnosti između varijabli, prirodu i jačinu međuovisnosti, tj. prostorna autokorelacija je procjena korelacije neke varijable u odnosu na prostornu lokaciju varijable (vidjeti [2]).

Prostornu autokorelaciju možemo utvrditi pomoću globalnih i lokalnih indikatora prostorne asocijacije. U radnji su korišteni slijedeći indikatori:

1. Globalni indikator prostorne asocijacije:
  - Moranov indeks
2. Lokalni indikatori prostorne asocijacije:
  - Lokalni Moranov indeks
  - Getis-Ord  $G_i$  statistika.



## 2.1. Globalni indikator prostorne asocijacije

### 2.1.1 Moranov indeks (Moran's I)

Moranov indeks je standardizirana prostorna autokovarijanca koja se jednostavno može interpretirati linearnom algebram. Uzmimo da je  $n$  broj elementa koji se mogu mjeriti varijablom  $x$ . Tada statističku varijablu  $x$  možemo zapisati u vektorskom obliku:

$$x = [x_1 \quad x_2 \quad \cdots \quad x_n]^T, \quad (1)$$

gdje je  $x_i$  vrijednost mjerenja varijable  $x$  na  $i$ -tom elementu ( $i = 1, 2, \dots, n$ ).

U ovom radu  $x_i$  su vrijednosti od  $x$  mjerene na geografskim područjima, tj. registarskim područjima i područjima koje pokrivaju policijske postaje u Istočnoj i Zapadnoj Hrvatskoj, a odnosi se na varijable:

- broj prometnih nesreća,
- broj prometnih nesreća na 10.000 stanovnika,
- broj registriranih motornih vozila,
- broj prometnih nesreća na 10.000 vozila ili na
- ukupnu visinu premije za osobna i teretna vozila

Srednja vrijednost  $\mu$  od  $x$  je dana slijedećom jednačinom :

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i. \quad (2)$$

Centrirana vrijednost od  $x_i$  računa se formulom:

$$y_i = x_i - \mu, \quad y = [y_1, y_2, \dots, y_n]^T = x - \mu \quad (3)$$

gdje  $\mu$  predstavlja srednju vrijednost varijable  $x$ .

Varijanca od  $x$  je:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} (x - \mu)^T (x - \mu) = \frac{1}{n} y^T y, \quad (4)$$

gdje  $\sigma$  označava standardnu devijaciju od  $x$ .

Izračunom centrirane varijable  $y$  od  $x$  i standardne devijacije  $\sigma$ , te njihovim uvrštavanjem u donju formulu (5) dobivamo standardiziranu varijablu  $z$ :

$$z = \frac{x - \mu}{\sigma} = \frac{y}{\sigma}. \quad (5)$$

Vrijednosti  $z_i$  od  $z$  kraće zovemo  $z$  vrijednostima. Također se može pokazati da je norma od  $z$ , tj. dužina vektora  $z$ , jednaka drugom korijenu broja elemenata u sustavu  $n$ , točnije broju geografskih područja, za koja su dobivene vrijednosti promatrane varijable.

Dakle, imamo

$$\|z\|^2 = z^T z = \sum_{i=1}^n z_i^2 = \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma}\right)^2 = \frac{n}{\sigma^2} \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = n. \quad (6)$$

Uz pomoć gore dobivene jednakosti Moranov indeks se može dobiti na jednostavan način. Pretpostavimo da imamo jediničnu prostornu težinsku matricu reda  $n$ :

$$W = [w_{ij}]_{n \times n} \quad (7)$$

gdje  $w_{ij}$  predstavlja recipročnu vrijednost potencije udaljenosti  $r_{ij}$  između zemljopisnih područja  $i$  i  $j$ .

Jedinična prostorna matrica ima, po definiciji, sljedeća svojstva:

- (1) Simetričnost: za sve  $i, j$  je  $w_{ij} = w_{ji}$ ;
- (2) Elementi na glavnoj dijagonali su nula, naime,  $w_{ii} = 0$  za sve  $i$ ;
- (3) Vrijedi uvjet normalizacije, odnosno:

$$\sum_{i=1}^n \sum_{j=1}^n w_{ij} = 1. \quad (8)$$

Jedinična prostorna težinska matrica  $W$  jest normirana prostorna matrica susjedstva  $V = [v_{ij}]_{n \times n}$ , koja se konstruira uz pomoć funkcije udaljenosti na sljedeći način:

$$v_{ij} = \begin{cases} r_{ij}^{-b}, & i \neq j \\ 0, & i = j \end{cases}, \quad (9)$$

gdje  $r_{ij}$  predstavlja udaljenost između lokacije  $i$  i  $j$ . Eksponent  $b$  najčešće iznosi 1. Prostorna matrica susjedstva normira se na način:

$$w_{ij} = \frac{v_{ij}}{\sum_{i=1}^n \sum_{j=1}^n v_{ij}}. \quad (10)$$

Moranov indeks od  $x$  na danom zemljopisnom području, po definiciji, je broj:

$$I = z^T W z, \quad (11)$$

Proširenje jednadžbe (11) rezultira originalnom formulom Moranovog indeksa:

$$I = \frac{y^T(nW)y}{y^T y} = \frac{n \sum_{i=1}^n \sum_{j=1}^n v_{ij}(x_i - \mu)(x_j - \mu)}{\sum_{i=1}^n \sum_{j=1}^n v_{ij} \sum_{i=1}^n (x_i - \mu)^2} . \quad (12)$$

Jednadžba (12) je uobičajena matematička formula Moranovog indeksa (vidjeti [13] [1]).

Moranov indeks je široko korištena mjera globalne prostorne asocijacije koja testira postojanje odnosa između zemljopisnih područja s obzirom na vrijednosti pokazatelja  $x$  koje se na njima pojavljuju. Pozitivna vrijednost Moranovog indeksa čija se vrijednost kreće od -1 do 1, za statistički signifikantna područja, ukazuje da su susjedne lokacije sličnih vrijednosti više prostorno grupirane. Suprotno tome, negativna vrijednost indeksa za statistički signifikantna područja ukazuje na različite vrijednosti na susjednim lokacijama (veća raspršenost uzoraka ) (vidjeti [12] [8]).

Signifikantnost geografskih područja utvrđujemo testiranjem nul-hipoteze o nepostojanju prostorne autokorelacije. Testna statistika je  $z$ -vrijednost koja predstavlja standardizirani Moranov indeks i dobivamo je na način (vidjeti [6]):

$$z = \frac{I - E(I)}{\sqrt{\text{Var}(I)}} . \quad (13)$$

U formuli (13) Moranov indeks  $I$  tretiramo kao slučajnu varijablu u kojoj je varijabla  $x$  slučajna. Uz istinitost nul-hipoteze permutacije vrijednosti varijable  $x$  na zadana zemljopisna područja su jednako vjerojatna. Odavde slijedi da je očekivana vrijednost  $E(I)$  od  $I$ , uz uvjet istinitosti nul-hipoteze, jednaka:

$$E(I) = \frac{-1}{N-1}, \quad (14)$$

dok je varijanca  $Var(I)$  jednaka

$$Var(I) = \frac{NS_4 - S_3S_5}{(N-1)(N-2)(N-3)(\sum_i \sum_j w_{ij})^2}, \quad (15)$$

gdje su

$$\begin{aligned} S_1 &= \frac{\sum_i \sum_j (w_{ij} + w_{ji})^2}{2} \\ S_2 &= \sum_i (\sum_j w_{ij} + \sum_j w_{ji})^2 \\ S_3 &= \frac{1/N \sum_i (x_i - \bar{x})^4}{(1/N \sum_i (x_i - \bar{x})^2)^2} \\ S_4 &= (N^2 - 3N + 3)S_1 - NS_2 + 3(\sum_i \sum_j w_{ij})^2 \\ S_5 &= S_1 - 2NS_1 + 6(\sum_i \sum_j w_{ij})^2. \end{aligned} \quad (16)$$

Za testiranje nul-hipoteze uzimamo razinu signifikantnosti  $\alpha = 0.05$ . Ukoliko je  $p$  vrijednost manja od 0.05 (što odgovara kritičnoj  $z$ -vrijednosti 1.645) odbacujemo nul-hipotezu u korist alternativne hipoteze o postojanju prostorne autokorelacije, točnije prostorne autokorelacije promatrane varijable  $x$  na danom zemljopisnom području.

## 2.2. Lokalni indikatori prostorne asocijacije

### 2.2.1 Lokalni Moranov indeks

U analizi prostorne asocijacije dugo se smatralo da prostorna stacionarnost ili strukturalna stabilnost prostora može biti nerealna, pogotovo ako se koristi veliki broj geografskih jedinica. Kod velikog broja geografskih jedinica ukoliko postoji lokalna koreliranost, ona se može izgubiti ako koristimo globalni indikator prostorne asocijacije, kao što je Moranov indeks.

Lokalnim indikatorima prostorne asocijacije, u koje spada lokalni Moranov indeks, utvrđuje se prostorna autokorelacija na lokanoj razini. Drugim riječima, to je grupiranje

susjednih područja oko područja promatranja s obzirom na visinu utvrđenih vrijednosti varijable. Kao i u slučaju globalnog indikatora, prostorno grupiranje se utvrđuje na područjima koja su statistički signifikantna.

Lokalni Moranov indeks možemo definirati tako da:

- a) za svako promatranje daje naznaku opsega signifikantnog prostornog grupiranja sličnih vrijednosti oko neke zemljopisne jedinice,
- b) suma lokalnih Moranovih indeksa za sva promatranja je proporcionalna globalnom indikatoru prostorne asocijacije.

Lokalni Moranov indeks za varijablu  $x$ , promatran na lokaciji  $i$ , izražava se kao statistika  $L_i$ :

$$L_i = f(x_i, x_i^s)$$

gdje je  $f$  neka funkcija, a  $x_i^s$  su promatrane vrijednosti u susjedstvu od  $i$  (vidjeti [1]).

Varijabla  $x$ , kao i u slučaju Moranovog indeksa, opaža se na određenom zemljopisnom području (broj prometnih nezgoda, broj prometnih nezgoda na 10.000 na broj stanovnika ili registriranih vozila itd.).

Kada jednu i drugu stranu jednadžbe (11) pomnožimo sa  $z$  dobijemo

$$M^* z = z z^T W z = I z \tag{17}$$

gdje  $M^*$  možemo nazvati idealnom prostornom težinskom matricom. Iz jednadžbe (17) može se vidjeti da je  $z$  svojstveni vektor matrice  $M^*$ , a Moranov indeks pripadajuća svojstvena vrijednost vektora  $z$ , te se može zaključiti da je

$$M^* = z z^T W \tag{18}$$

Prema jednadžbi (6) dužina vektora  $z$  je jednaka drugom korijenu broja geografskih područja na koja se odnose vrijednosti varijable, te u skladu s navedenom jednadžbom, normalizacijom  $z$  dobivamo  $z/\sqrt{n}$ .

Također, ako jednadžbu (18) napišemo u obliku

$$\begin{aligned}
 & \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_n \end{bmatrix} \begin{bmatrix} z_1 & z_2 & \cdots & z_n \end{bmatrix} \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{nn} \end{bmatrix} \\
 = & \begin{bmatrix} z_1 \sum_{j=1}^n w_{1j} z_j & z_1 \sum_{j=1}^n w_{2j} z_j & \cdots & z_1 \sum_{j=1}^n w_{nj} z_j \\ z_2 \sum_{j=1}^n w_{1j} z_j & z_2 \sum_{j=1}^n w_{2j} z_j & \cdots & z_2 \sum_{j=1}^n w_{nj} z_j \\ \vdots & \vdots & \ddots & \vdots \\ z_n \sum_{j=1}^n w_{1j} z_j & z_n \sum_{j=1}^n w_{2j} z_j & \cdots & z_n \sum_{j=1}^n w_{nj} z_j \end{bmatrix}
 \end{aligned}
 \tag{19}$$

dobivamo matricu u kojoj glavna dijagonala upućuje na lokalni indikator prostorne asocijacije. Lokalni Moranov indeks na području  $i$  označavamo sa  $I_i$ .

Formulom, lokalni Moranov indeks varijable  $x$  za zemljopisno područje  $i$ , je :

$$I_i = \frac{ny_i \sum_{j=1}^n w_{ij} y_j}{y^T y} = z_i \sum_{j=1}^n w_{ij} z_j
 \tag{20}$$

Način utvrđivanje signifikantnosti područja kod loknog Moranovog indeksa isti je kao i kod Moranovog indeksa, razlika je što se testiranje obavlja za svako geografsko područje posebno. Pozitivna vrijednost lokalnog Moranovog indeksa govori da je određena statistički signifikantna geografska jedinica okružena sa susjednim statistički signifikantnim geografskim jedinicama na kojima su izmjerene visoke vrijednosti, a negativna vrijednost govori suprotno.

### 2.2.2 Statistika $G_i$ (Getis Ord)

Statistika  $G_i$  se može koristiti kao mjera prostornog grupiranja koja omogućava procjenu prostornog grupiranja vrijednosti varijable unutar određene udaljenosti od jedne točke. Trebala bi se koristiti u spoju sa Moranovim indeksom s namjerom identificiranja onih karakteristika uzoraka koje se ne mogu otkriti Moranovim indeksom. Osim toga, statistika  $G_i$  nam omogućava pronalaženje lokalnih džepova međusobnog utjecaja, koji se neće pokazati ako koristimo globalnu statistiku.

Statistika  $G_i$  mjeri stupanj korelacije vrijednosti varijable  $x$  mjernih točaka koje se nalaze u radijusu udaljenosti  $d$  od referentne mjerne točke  $i$ . Dano nam je  $n$  geografskih područja,  $i = 1, 2, 3, \dots, n$ , gdje je svako područje identificirano svojim Kartezijevim koordinatama. Kao i kod Moranovog indeksa, za svaku zemljopisnu jedinicu  $i$  izmjerena je vrijednosti varijable  $x$ .

Statistika  $G_i$  definira se izrazom

$$G_i(d) = \frac{\sum_{j=1}^n w_{ij}(d)x_j}{\sum_{j=1}^n x_j} \quad (21)$$

gdje je  $w_{ij}(d)$  simetrična nula/jedan prostorna težinska matrica sa jedinicama za sve veze definirane unutar udaljenosti  $d$  za dano  $i$ , i nulama za veze definirane izvan udaljenosti  $d$  uključujući samu točku  $i$  od koje se mjeri udaljenost. Brojnik možemo definirati kao zbroj svih vrijednosti  $x_j$  za točku  $j$  udaljenosti barem  $d$  od točke  $i$ , osim  $x_i$ . Nazivnik je suma svih  $x_j$ , ne uključujući  $x_i$ .



Standardiziranjem statistike  $G_i$ , uz nul-hipotezu da su vrijednosti od  $x$  neovisne o području  $i$ , dobivamo standardiziranu vrijednost  $Z_i$ , za koju pretpostavljamo da ima (aproksimativno) jediničnu normalnu razdiobu uz pretpostavku točnosti nul-hipoteze. Ako je nul-hipoteza točna, tada je svaka permutacija preostalih  $n - 1$  vrijednosti od  $x$  jednako vjerojatna (vrijednost  $x_i$  od  $x$  koja je opažena na području  $i$  se drži fiksnom). Tada slučajnu vrijednost  $Z_i$  možemo izraziti uz pomoć formule (vidjeti [3]):

$$Z_i = \{G_i(d) - E[G_i(d)]\} / \sqrt{\text{Var } G_i(d)}, \quad (22)$$

gdje je očekivana vrijednost od  $G_i(d)$  uz točnost nul-hipoteze

$$E[G_i] = W_i / (n - 1), \quad (21)$$

a varijanca od  $G_i(d)$

$$\begin{aligned} \text{Var}(G_i) &= E(G_i^2) - E^2(G_i) \\ &= \frac{1}{(\sum_j x_j)^2} \left[ \frac{W_i(n - 1 - W_i) \sum_j x_j^2}{(n - 1)(n - 2)} \right] + \frac{W_i(W_i - 1)}{(n - 1)(n - 2)} - \frac{W_i^2}{(n - 1)^2}. \end{aligned} \quad (23)$$

Ovdje je  $W_i = \sum_j w_{ij}(d)$  (vidjeti [3])

Pozitivna vrijednost od  $Z_i$  podrazumijeva grupiranje geografskih područja na kojima se pojavljuju visoke vrijednosti varijable  $x$  unutar udaljenosti  $d$ , od točke  $i$  (*hot-spots*). Negativan  $Z_i$  podrazumijeva grupiranje geografskih područja na kojima se pojavljuju male vrijednosti varijable unutar udaljenosti  $d$ , od točke  $i$  (*cold-spots*). Kao u slučaju Moranovog indeksa, statistike  $G_i(d)$  za zemljopisna područja  $i$  moraju biti statistički signifikantna.

Polazi se od nul-hipoteze da ne postoji autokorelacija između geografskih područja. Obzirom da se radi o dvostranom testu kod razine značajnosti  $\alpha = 0.05$  za kritične vrijednosti od  $Z_i$  uzimaju se vrijednosti manje od -1.95 i veće od 1.95. U slučaju da je  $p$  vrijednost manja od zadane signifikantnosti, odbacujemo nul-hipotezu u korist alternativne hipoteze o postojanju autokorelacije, odnosno kažemo da su geografska područja statistički signifikantna (vidjeti [3] [4]).

### 3. Praktična primjena indikatora prostorne asocijacije

U ovom poglavlju u radu navedeni indikatori prostorne asocijacije primijenjeni su na podatke navedene u tablici 1 i tablici 2. Izračun globalnog Moranovog indeksa, te loknog Moranovog indeksa i Getis-Ord statistike sproveden je pomoću procedura pisanih u R kodu i učitanih sa internetske stranice ([www.r-project.org](http://www.r-project.org)). Programski jezik R je besplatni softver namijenjen za statističku obradu podataka, kao i njihovo grafičko prikazivanje.

U svrhu izračuna navedenih indikatora prostorne asocijacije korišten je programski paket *spdep*. ([http://files.meetup.com/19237528/MAPS\\_R\\_CODE2.txt](http://files.meetup.com/19237528/MAPS_R_CODE2.txt)) [7]


Ulazni podaci, odnosno vrijednosti varijabli, koje sam koristio, su navedeni u tablicama 1 i 2, točnije: **broj prometnih nesreća, broj prometnih nesreća na 10.000 stanovnika, ukupan broj registriranih vozila, broj prometnih nesreća na 10.000 vozila, ukupna premija za osobna i teretna vozila**. Također, ulazni podaci su i **geografska dužina i širina područja (područja registarskih oznaka ili područja policijskih postaja)** na kojima se nalaze navedene vrijednosti, radi izračuna međusobnih udaljenosti, a što je vrlo važno kod utvrđivanja da li su promatrana područja graniče jedna sa drugom.

### 3.1 Podaci po registracijskim područjima


Tablica 1.

Registarske tablice	Broj prometnih nesreća	Broj prometnih nesreća na 10000 stanovnika	Ukupni broj registriranih motornih vozila [10]	Broj prometnih nesreća na 10.000 vozila	Broj registriranih vozila (osobna i teretna)	Premija za osobna i teretna vozila [11]
BJ (Bjelovar)	545	51.23	42441	128.41	30918	<b>94957.77</b>
BM (Beli Manastir)	193	44.23	15788	122.24	11363	<b>86486.10</b>
ČK (Čakovec)	809	71.09	55888	144.75	44737	<b>94957.77</b>
DA (Daruvar)	237	47.37	15825	149.76	12568	<b>71660.97</b>
DJ (Đakovo)	195	35.42	18052	108.02	13664	<b>86486.10</b>
KC (Koprivnica)	428	61.88	39313	108.86	20123	<b>94957.77</b>
KR (Krapina)	675	50.79	62086	108.72	50682	<b>125005.10</b>
KT (Kutina)	482	82.36	26298	183.28	19641	<b>94957.77</b>
KŽ (Križevci)	191	56.08	16513	115.67	12241	<b>78738.59</b>
NA (Našice)	256	44.41	14274	179.35	10784	<b>78738.59</b>
NG (Nova Gradiška)	229	50.43	21346	107.25	15790	<b>94957.77</b>
OS (Osijek)	1206	73.32	63418	190.17	53399	<b>94957.77</b>
PŽ (Požega)	383	60.36	27206	140.78	20400	<b>78738.59</b>
SB (Slavonski Brod)	822	75.59	42136	195.08	34327	<b>113691.59</b>
SK (Sisak)	719	61.89	44478	161.65	35209	<b>103421.02</b>
SL (Slatina)	203	57.84	14071	144.26	10255	<b>78738.59</b>
VK (Vinkovci)	588	70.37	29065	202.31	23164	<b>113691.59</b>
VT (Virovitica)	350	70.37	22963	152.42	16410	<b>94957.77</b>
VU (Vukovar)	278	51.43	20556	135.24	16123	<b>78738.59</b>
VŽ (Varaždin)	1186	67.41	85905	138.06	66217	<b>94957.77</b>
ZG (Zagreb)	8365	75.52	490444	170.56	443190	<b>125005.10</b>
ŽU (Županja)	236	59.32	15342	153.83	11025	<b>94957.77</b>


Grafički prikaz visine premije za osobna i teretna vozila u 2016. godini prikazano u tablici 1.



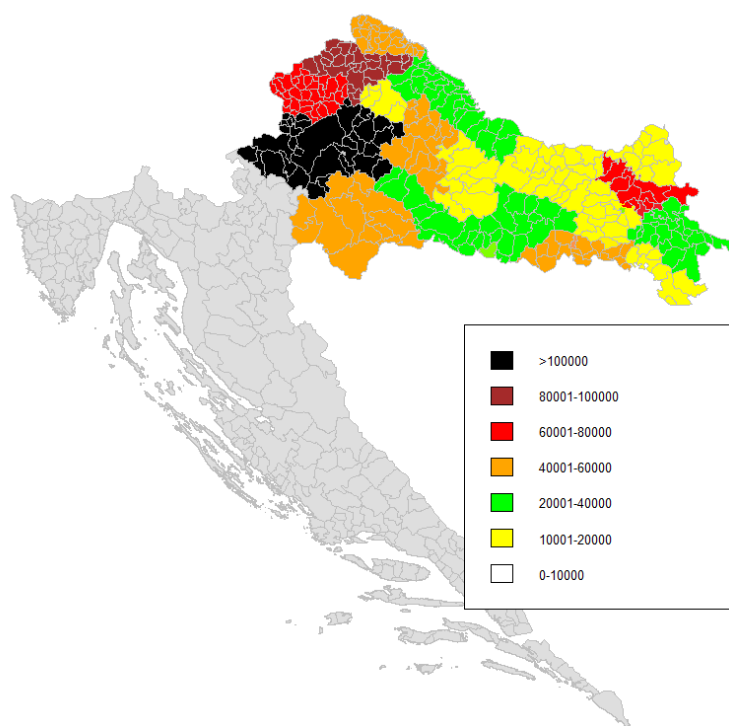
Grafički prikaz prometnih nesreća u 2015. godini prikazano u tablici 1.




Grafički prikaz stope prometnih nesreća (odnos broja prometnih nezgoda i broja stanovnika) u 2015. godini, prikazano u tablici 1.



1. Grafički prikaz ukupnog broja registriranih vozila u 2015. godini, prikazano u tablici



Grafički prikaz prometnih nezgoda u odnosu na 10.000 registriranih vozila u 2015. godini prikazano u tablici 1.



### 3.1.1 Globalni Moranov indeks s obzirom na broj prometnih nesreća po registracijskim područjima

1. Globalni Moranov koeficijent za broj prometnih nesreća iznosi: 0.007262845
  2.  $p$  vrijednost iznosi 0.1376 i  $z$  vrijednost iznosi 1.091166
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 zbog čega ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti prometnih nesreća po registracijskim područjima rezultat slučajnog prostornog procesa

Moran I statistic standard deviate = 1.0911, p-value = 0.1376		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
0.007262845	-0.047619048	0.002529951

### 3.1.2 Lokalni Moranov indeks za broj prometnih nesreća po registracijskim područjima

		$I_i$	$E.I_i$	$Var.I_i$	$Z.I_i$	$Pr(z > 0)$
1	BJ	0.058382094	-0.04761905	0.06389128	0.41936265	0.3374756
2	BM	-0.084622427	-0.04761905	0.15129322	-0.09513310	0.5378954
3	ČK	0.006795006	-0.04761905	0.09302526	0.17840649	0.4292019
4	DA	0.104520541	-0.04761905	0.05417995	0.65361638	0.2566795
5	DJ	0.065325519	-0.04761905	0.05417995	0.48522820	0.3137572
6	KC	0.024173563	-0.04761905	0.06389128	0.28402656	0.3881950
7	KR	-0.239181812	-0.04761905	0.09302526	-0.62807376	0.7350222
8	KT	0.047692144	-0.04761905	0.09302526	0.31249527	0.3773321
9	KŽ	0.024026502	-0.04761905	0.06389128	0.28344475	0.3884180
10	NA	0.093764963	-0.04761905	0.06389128	0.55934467	0.2879633
11	NG	0.118129564	-0.04761905	0.09302526	0.54343731	0.2934144
12	OS	-0.068967573	-0.04761905	0.06389128	-0.08445923	0.5336543
13	PŽ	0.082036388	-0.04761905	0.05806448	0.53806587	0.2952658
14	SB	0.004550170	-0.04761905	0.07360261	0.19229488	0.4237556
15	SK	0.016319471	-0.04761905	0.15129322	0.16438146	0.4347154
16	SL	0.123927130	-0.04761905	0.06389128	0.67867250	0.2486727
17	VK	0.033671982	-0.04761905	0.06389128	0.32160429	0.3738762
18	VT	0.091645596	-0.04761905	0.07360261	0.51332720	0.3038612
19	VU	0.058620437	-0.04761905	0.06389128	0.42030559	0.3371311
20	VŽ	-0.050691586	-0.04761905	0.07360261	-0.01132533	0.5045181
21	ZG	-0.457577471	-0.04761905	0.15129322	-1.05397445	0.8540527
22	ŽU	0.107242393	-0.04761905	0.07360261	0.57081674	0.2840619

Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata za sva registracijska područja veća od 0.05, zbog čega ne odbacujemo nul- hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu signifikantna, te ne možemo utvrditi da li postoji autokorelacija, odnosno statističko prostorna povezanost broja prometnih nesreća po registracijskim područjima.

### 3.1.3. Utvrđivanje koncentracije viših vrijednosti „hot spot“ i nižih vrijednosti „cold spots“ broja prometnih nesreća po registracijskim područjima

1	BJ (Bjelovar)	-0.7082636	0.2393907765
2	BM (Beļi Manastir)	0.1943135	0.4229652176
3	ČK (Čakovec)	-0.4558893	0.3242348081
4	DA (Daruvar)	-0.8439873	0.1993382568
5	DJ (Đakovo)	-0.5168972	0.3026139551
6	KC (Koprivnica)	-0.2308303	0.4087233056
7	KR (Krapina)	3.3341047	0.0004278722
8	KT (Kutina)	-0.3263134	0.3720936223
9	KŽ (Križevci)	-0.1701802	0.4324341930
10	NA (Našice)	-0.6009050	0.2739516274
11	NG (Nova Gradiška)	-0.4804852	0.3154412079
12	OS (Osijek)	-0.6532229	0.2568063015
13	PŽ (Požega)	-0.7581584	0.2241780903
14	SB (Slavonski Brod)	-0.6066604	0.2720381412
15	SK (Sisak)	-0.2157211	0.4146025708
16	SL (Slatina)	-0.7246110	0.2343453547
17	VK (Vinkovci)	-0.4802249	0.3155337556
18	VT (Virovitica)	-0.5780845	0.2816035367

19	VU (Vukovar)	-0.4013600	0.3440775608
20	VŽ (Varaždin)	-0.4246162	0.3355582333
21	ZG (Zagreb)	0.6137547	0.2696887231
22	ŽU (Županja)	-0.5573611	0.2886403554

Standardizirana Getis-Ord Gi statistika ukazuje, osim na području registarske oznake Krapina, da područja registarskih oznaka nisu statistički signifikantna zbog čega ne možemo utvrditi signifikantni „hot spots“ ili „cold spots“, odnosno koncentraciju nižih ili viših vrijednosti zbog prevelike p vrijednosti.

### 3.1.4 Globalni Moranov indeks za stopu prometnih nesreća (u odnosu na 10.000 stanovnika) po registarskim područjima

1. Globalni Moranov koeficijent za stopu prometnih nesreća (u odnosu na broj stanovnika) iznosi: - 0.32072006
  2.  $p$  vrijednost iznosi 0.9446 i  $z$  vrijednost iznosi 1.594608
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 zbog čega ne odbacujemo nul-hipotezu (vrijednost nije statistički signifikantna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti stope prometnih nesreća u odnosu na broj stanovnika rezultat slučajnog prostornog procesa

Moran I statistic standard deviate = -1.595, p-value = 0.9446		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
-0.32072006	-0.04761905	0.02931868

### 3.1.5 Lokalni Moranov indeks za stopu prometnih nesreća ( u odnosu na 10.000 stanovnika) po registarskim područjima

		Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	BJ	0.06156058	-0.04761905	0.2024452	0.24265423	0.4041366
2	BM	-1.46148111	-0.04761905	0.9430300	-1.45594268	0.9272958
3	ČK	-0.07452070	-0.04761905	0.4493068	-0.04013354	0.5160067
4	DA	-0.18853583	-0.04761905	0.1201580	-0.40652415	0.6578212
5	DJ	-0.42032227	-0.04761905	0.1201580	-1.07519384	0.8588560
6	KC	0.02036890	-0.04761905	0.2024452	0.15110476	0.4399465



7	KR	-0.73323440	-0.04761905	0.4493068	-1.02284312	0.8468090
8	KT	-0.82790919	-0.04761905	0.4493068	-1.16408478	0.8778052
9	KŽ	-0.07949990	-0.04761905	0.2024452	-0.07085592	0.5282438
10	NA	0.28496663	-0.04761905	0.2024452	0.73917928	0.2298991
11	NG	0.40184079	-0.04761905	0.4493068	0.67053180	0.2512594
12	OS	-0.89103203	-0.04761905	0.2024452	-1.87450462	0.9695695
13	PŽ	-0.01401048	-0.04761905	0.1530729	0.08590151	0.4657724
14	SB	-1.43744627	-0.04761905	0.2847324	-2.60460789	0.9954010
15	SK	0.30374383	-0.04761905	0.9430300	0.36182046	0.3587431
16	SL	0.06302823	-0.04761905	0.2024452	0.24591610	0.4028736
17	VK	-0.36754084	-0.04761905	0.2024452	-0.71103350	0.7614683
18	VT	-0.56518970	-0.04761905	0.2847324	-0.96995409	0.8339653
19	VU	0.01975767	-0.04761905	0.2024452	0.14974630	0.4404824
20	VŽ	-0.19168831	-0.04761905	0.2847324	-0.26999322	0.6064173
21	ZG	-0.99124892	-0.04761905	0.9430300	-0.97171503	0.8344038
22	ŽU	0.03255211	-0.04761905	0.2847324	0.15024488	0.4402857

Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata za sva registracijska područja veća od 0.05, zbog čega ne odbacujemo nul- hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu signifikantna, te ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost stope prometnih nesreća po registarskim područjima.

### 3.1.6 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ obzirom na stopu prometnih nesreća ( u odnosu na 10.000 stanovnika) po registarskim područjima

	<b>Reg. tablice</b>	<b>LocalG</b>	<b>P</b>
1	BJ (Bjelovar)	-0.25616851	0.39891036
2	BM (Beli Manastir)	1.07378251	0.14146009
3	ČK (Čakovec)	-0.05196483	0.47927836
4	DA (Darugar)	0.36885680	0.35611723
5	DJ (Đakovo)	0.33410340	0.36915077
6	KC (Koprivnica)	0.28354959	0.38837779
7	KR (Krapina)	1.32919589	0.09189168
8	KT (Kutina)	-0.54943155	0.29135466
9	KŽ (Križevci)	0.49203279	0.31134808
10	NA (Našice)	-0.62243653	0.26682743
11	NG (Nova Gradiška)	-0.78361804	0.21663213
12	OS (Osijek)	-1.62926734	0.05162822
13	PŽ (Požega)	-0.97629466	0.16445923
14	SB (Slavonski Brod)	-1.93426409	0.02654033
15	SK (Sisak)	1.83509382	0.03324589
16	SL (Slatina)	-0.78063062	0.21750989
17	VK (Vinkovci)	-0.82299471	0.20525550
18	VT (Virovitica)	-1.10559053	0.13445190
19	VU (Vukovar)	-0.13222598	0.44740278
20	VŽ (Varaždin)	-0.50079287	0.30825845
21	ZG (Zagreb)	-0.71440270	0.23748910
22	ŽU (Županija)	-1.12516730	0.13025907

Standardizirana Getis-Ord  $G_i$  statistika ukazuje da je područje registarske oznake Slavonski Brod statistički signifikantno, međutim okruženo je područjima koja nisu signifikantna iz kojeg razloga ne možemo utvrditi „*hot spots*“ ili „*cold spots*“. Isti je slučaj sa registarskim područjem Siska.

### 3.1.7 Globalni Moranov indeks za broj registriranih vozila po registarskim područjima

1. Globalni Moranov koeficijent za broj registriranih vozila iznosi: 0.075557243
2.  $p$  vrijednost iznosi 0.01126 i  $z$  vrijednost iznosi 2.281481

-  $p$  vrijednost je manja od razine signifikantnosti koja iznosi 0,05 zbog čega odbacujemo nul hipotezu (područja su statistički signifikantna), te obzirom da je vrijednost globalnog Moranovog indeksa pozitivna može se zaključiti da su na susjednim registarskim područjima opažene slične vrijednosti s obzirom na broj registriranih vozila.

Moran I statistic standard deviate = 2.2815, p-value = 0.01126		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
0.075557243	-0.047619048	0.002914817

### 3.1.8 Lokalni Moranov indeks za broj registriranih vozila po registarskim područjima

		$I_i$	$E.I_i$	$Var.I_i$	$Z.I_i$	$Pr(z > 0)$
1	BJ	0.036219723	-0.04761905	0.06588184	0.326634481	0.3719722
2	BM	-0.038737121	-0.04761905	0.16266788	0.022021975	0.4912152
3	ČK	-0.005745197	-0.04761905	0.09814385	0.133663044	0.4468345
4	DA	0.112843059	-0.04761905	0.05512784	0.683418920	0.2471711
5	DJ	0.087009111	-0.04761905	0.05512784	0.573390398	0.2831902
6	KC	0.005525762	-0.04761905	0.06588184	0.207051311	0.4179849
7	KR	0.205852581	-0.04761905	0.09814385	0.809091801	0.2092312
8	KT	0.068817266	-0.04761905	0.09814385	0.371669472	0.3550695
9	KŽ	-0.008271160	-0.04761905	0.06588184	0.153298728	0.4390814
10	NA	0.118936584	-0.04761905	0.06588184	0.648898019	0.2582021
11	NG	0.110880648	-0.04761905	0.09814385	0.505937507	0.3064503
12	OS	-0.033561829	-0.04761905	0.06588184	0.054766695	0.4781622
13	PŽ	0.090812349	-0.04761905	0.05942944	0.567850186	0.2850683
14	SB	0.041894306	-0.04761905	0.07663585	0.323349243	0.3732154
15	SK	0.027111680	-0.04761905	0.16266788	0.185288436	0.4265014
16	SL	0.141834699	-0.04761905	0.06588184	0.738108699	0.2302242

17	VK	0.064010656	-0.04761905	0.06588184	0.434907500	0.3318148
18	VT	0.096878018	-0.04761905	0.07663585	0.521966998	0.3008467
19	VU	0.078552583	-0.04761905	0.06588184	0.491562610	0.3115143
20	VŽ	-0.049261204	-0.04761905	0.07663585	-0.005931966	0.5023665
21	ZG	0.383500526	-0.04761905	0.16266788	1.068924040	0.1425519
22	ŽU	0.127156315	-0.04761905	0.07663585	0.631341343	0.2639087

Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata za sva registracijska područja veća od 0.05, zbog čega ne odbacujemo nul- hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu signifikantna, te ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost broja registriranih vozila po registarskim područjima .

### 3.1.9 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za broj registriranih vozila po registarskim područjima

	Reg. tablice	LocalG	P
1	BJ (Bjelovar)	-0.669274880	0.2516600738
2	BM (Beli Manastir)	0.078875469	0.4685658378
3	ČK (Čakovec)	-0.376033549	0.3534459776
4	DA (Daruvar)	-0.852703024	0.1969120068
5	DJ (Đakovo)	-0.704470617	0.2405698711
6	KC (Koprivnica)	-0.093695932	0.4626753510
7	KR (Krapina)	3.425298923	0.0003070617
8	KT (Kutina)	-0.364625670	0.3576954251
9	KŽ (Križevci)	0.007010444	0.4972032603
10	NA (Našice)	-0.663573844	0.2534815513
11	NG (Nova Gradiška)	-0.494657579	0.3104209252
12	OS (Osijek)	-0.708246521	0.2393960907
13	PŽ (Požega)	-0.844150655	0.1992926123
14	SB (Slavonski Brod)	-0.633502260	0.2632028526
15	SK (Sisak)	-0.280920348	0.3893857466
16	SL (Slatina)	-0.779845590	0.2177408839
17	VK (Vinkovci)	-0.559752484	0.2878241389
18	VT (Virovitica)	-0.573073232	0.2832975554
19	VU (Vukovar)	-0.522790768	0.3005599325
20	VŽ (Varaždin)	-0.238464187	0.4057605444
21	ZG (Zagreb)	1.487431929	0.0684503846
22	ŽU (Županja)	-0.609169920	0.2712059080

Standardizirana Getis-Ord  $G_i$  statistika ukazuje, osim na području registarske oznake Krapina, da područja registarskih oznaka nisu statistički signifikantna zbog čega ne možemo utvrditi signifikantni „hot spots“ ili „cold spots“, odnosno koncentraciju nižih ili viših vrijednosti.

### 3.1.10 Globalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila po registarskim područjima

1. Globalni Moranov koeficijent za stopu prometnih nezgoda na 10.000 registriranih vozila iznosi: - 0.07481141
  2.  $p$  vrijednost iznosi 0.5628 i  $z$  vrijednost iznosi - 0.1580721
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 iz kojeg razloga ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti prometnih nesreća na 10.000 registriranih vozila rezultat slučajnog prostornog procesa.

Moran I statistic standard deviate = -0.1582, p-value = 0.5628		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
-0.07481141	-0.04761905	0.02955794

### 3.1.11 Lokalni Moranov indeks za stopu broja prometnih nesreća na 10 000 registriranih vozila po registarskim područjima


		I <sub>i</sub>	E.I <sub>i</sub>	Var.I <sub>i</sub>	Z.I <sub>i</sub>	Pr(z > 0)
1	BJ	0.347728651	-0.04761905	0.2036827	0.87599602	0.19051610
2	BM	-1.265475814	-0.04761905	0.9501014	-1.24942800	0.89424571
3	ČK	0.105370660	-0.04761905	0.4524889	0.22743549	0.41004256
4	DA	-0.013224255	-0.04761905	0.1207473	0.09898149	0.46057648
5	DJ	-1.327658406	-0.04761905	0.1207473	-3.68370300	0.99988506
6	KC	0.705508385	-0.04761905	0.2036827	1.66875041	0.04758343
7	KR	-0.318430958	-0.04761905	0.4524889	-0.40259074	0.65637534
8	KT	0.356034781	-0.04761905	0.4524889	0.60007439	0.27422833
9	KŽ	0.643966050	-0.04761905	0.2036827	1.53238730	0.06271345
10	NA	-0.010123033	-0.04761905	0.2036827	0.08308221	0.46689309
11	NG	0.095920103	-0.04761905	0.4524889	0.21338623	0.41551286
12	OS	-0.270163560	-0.04761905	0.2036827	-0.49310545	0.68903096
13	PŽ	-0.060213747	-0.04761905	0.1539215	-0.03210245	0.51280483
14	SB	-0.258105020	-0.04761905	0.2866181	-0.39316182	0.65290002
15	SK	0.607959629	-0.04761905	0.9501014	0.67257364	0.25060929
16	SL	-0.029659001	-0.04761905	0.2036827	0.03979517	0.48412821
17	VK	-0.031629660	-0.04761905	0.2036827	0.03542866	0.48586896
18	VT	-0.039133973	-0.04761905	0.2866181	0.01584907	0.49367740
19	VU	-0.231310038	-0.04761905	0.2036827	-0.40701534	0.65800164
20	VŽ	0.394334269	-0.04761905	0.2866181	0.82551425	0.20453985
21	ZG	-1.056926368	-0.04761905	0.9501014	-1.03547220	0.84977578
22	ŽU	0.009380191	-0.04761905	0.2866181	0.10646754	0.45760570

Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata za gotovo sva registracijska područja veća od 0.05, zbog čega ne odbacujemo nul-hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu signifikantna, osim područja koje pokriva koprivnička registracijska oznaka, međutim navedeno područje je okruženo područjima koja statistički nisu signifikantna, zbog čega ne možemo utvrditi da postoji autokorelacija, odnosno statistička prostorna povezanost broja prometnih nezgoda na 10 000 registriranih vozila.

### 3.1.12 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za stopu broja prometnih nesreća na 10 000 registriranih vozila po registarskim područjima

	<b>Reg. tablice</b>	<b>LocalG</b>	<b>P</b>
1	BJ (Bjelovar)	-1.21425394	0.11232538
2	BM (Beli Manastir)	1.42263511	0.07742098
3	ČK (Čakovec)	-1.71090161	0.04354964
4	DA (Darugar)	-0.42238043	0.33637368
5	DJ (Đakovo)	2.66167638	0.00388763
6	KC (Koprivnica)	-1.32247775	0.09300456
7	KR (Krapina)	0.26271411	0.39638547
8	KT (Kutina)	0.51101246	0.30467116
9	KŽ (Križevci)	-1.40677863	0.07974652
10	NA (Našice)	0.09425002	0.46245527
11	NG (Nova Gradiška)	-0.20096628	0.42036247
12	OS (Osijek)	-0.25417739	0.39967926
13	PŽ (Požega)	0.63165596	0.26380585
14	SB (Slavonski Brod)	-0.15153591	0.43977649
15	SK (Sisak)	1.23640423	0.10815417
16	SL (Slatina)	0.59147802	0.27710009
17	VK (Vinkovci)	0.17012756	0.43245491
18	VT (Virovitica)	-0.38287051	0.35090789
19	VU (Vukovar)	1.14704731	0.12568103
20	VŽ (Varaždin)	-2.24968347	0.01223452
21	ZG (Zagreb)	-1.27610406	0.10095937
22	ŽU (Županja)	0.09383547	0.46261993

Standardizirana Getis-Ord  $G_i$  statistika ukazuje da su registarska područja Čakovca i Varaždina statistički signifikantna, te s obzirom na manji broj prometnih nezgoda na 10.000 registriranih vozila predstavljaju „cold-spots“. Registarsko područje Đakova je također statistički signifikantno na kojemu se pojavljuju veće vrijednosti no okruženo je područjima koja nisu statistički signifikantna.



### 3.1.13 Globalni Moranov indeks za visinu premije za osiguranje od auto odgovornosti za 2016. godinu, po registarskim područjima


1. Globalni Moranov koeficijent za visinu premiju od auto odgovornosti iznosi: 0.31721363
  2.  $p$  vrijednost iznosi 0.01506 i  $z$  vrijednost iznosi 2.168509
- $p$  vrijednost je manja od razine signifikantnosti koja iznosi 0,05 zbog čega odbacujemo nul hipotezu (područja su statistički signifikantna), te obzirom da je vrijednost globalnog Moranovog indeksa pozitivna može se zaključiti da su na susjednim registarskim područjima opažene slične vrijednosti koje se odnose na visinu obračunate premije za osiguranja od auto odgovornosti

Moran I statistic standard deviate = 2.1685, p-value = 0.01506		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
0.31721363	-0.04761905	0.02830504

### 3.1.14 Lokalni Moranov indeks za visinu premije za osiguranje od auto odgovornosti za 2016. godinu, po registarskim područjima

		$I_i$	$E.I_i$	$Var.I_i$	$Z.I_i$	$Pr(z > 0)$
1	BJ	-0.030764203	-0.04761905	0.1972026	0.037954954	4.848618e-01
2	BM	-0.026049520	-0.04761905	0.9130720	0.022572939	4.909955e-01
3	ČK	-0.024836515	-0.04761905	0.4358257	0.034510048	4.862352e-01
4	DA	0.512483982	-0.04761905	0.1176615	1.632866553	5.124853e-02
5	DJ	-0.057424820	-0.04761905	0.1176615	-0.028586736	5.114029e-01
6	KC	-0.011252537	-0.04761905	0.1972026	0.081892729	4.673660e-01
7	KR	2.326392507	-0.04761905	0.4358257	3.596055592	1.615394e-04
8	KT	-0.022515514	-0.04761905	0.4358257	0.038025806	4.848336e-01
9	KŽ	-0.052004471	-0.04761905	0.1972026	-0.009875413	5.039397e-01
10	NA	0.362282820	-0.04761905	0.1972026	0.923046562	1.779915e-01
11	NG	-0.063859847	-0.04761905	0.4358257	-0.024600898	5.098133e-01
12	OS	-0.009752964	-0.04761905	0.1972026	0.085269576	4.660235e-01
13	PŽ	0.500991191	-0.04761905	0.1494779	1.418976994	7.795286e-02
14	SB	-1.210370125	-0.04761905	0.2767436	-2.210283282	9.864572e-01
15	SK	0.030684195	-0.04761905	0.9130720	0.081945899	4.673449e-01
16	SL	0.989218012	-0.04761905	0.1972026	2.334824404	9.776298e-03
17	VK	-0.512252742	-0.04761905	0.1972026	-1.046295634	8.522877e-01
18	VT	-0.041796084	-0.04761905	0.2767436	0.011068920	4.955842e-01
19	VU	-0.243717948	-0.04761905	0.1972026	-0.441589635	6.706069e-01
20	VŽ	0.017773347	-0.04761905	0.2767436	0.124304952	4.505369e-01
21	ZG	4.549791943	-0.04761905	0.9130720	4.811281957	7.498264e-07
22	ŽU	-0.004320779	-0.04761905	0.2767436	0.082306043	4.672017e-01

Prema tablici za izračunate Lokalne Moranove indekse statistički signifikantna područja su područja registracijskih oznaka Podravske Slatine, Zagreba i Krapine. Grafički je prikazano grupiranje visokih vrijednosti obračunate premije za osiguranje od auto odgovornosti za područja registarskih područja Zagreba i Krapine. Što se tiče registracijskog područja Podravske Slatine ono je okruženo registracijskim područjima koja nisu statistički signifikantna (obojana zelenom bojom) iz koje razloga ne možemo utvrditi autokorelaciju, odnosno grupiranje.




**3.1.15 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za visinu premije za osiguranje od auto odgovornosti za 2016. godinu, po registarskim područjima**

	<b>Reg. tablice</b>	<b>LocalG</b>	<b>P</b>
1	BJ (Bjelovar)	-1.34556992	0.089220629
2	BM (Beli Manastir)	0.02222986	0.491132300
3	ČK (Čakovec)	-0.72595274	0.233933872
4	DA (Daruvar)	-1.18075992	0.118849054
5	DJ (Đakovo)	0.22471124	0.411101960
6	KC (Koprivnica)	-0.48907447	0.312394488
7	KR (Krapina)	1.90956505	0.028094619
8	KT (Kutina)	-0.65780700	0.255331079
9	KŽ (Križevci)	-0.00654636	0.497388399
10	NA (Našice)	-0.84529299	0.198973638
11	NG (Nova Gradiška)	-1.87169707	0.030624262
12	OS (Osijek)	-0.42324835	0.336057038
13	PŽ (Požega)	-1.29778393	0.097180796
14	SB (Slavonski Brod)	-1.55589686	0.059866310
15	SK (Sisak)	0.07748878	0.469117358
16	SL (Slatina)	-2.11455659	0.017233879
17	VK (Vinkovci)	-0.70029208	0.241872460
18	VT (Virovitica)	-1.54003295	0.061776161
19	VU (Vukovar)	0.38158776	0.351383583
20	VŽ (Varaždin)	0.66072866	0.254393169
21	ZG (Zagreb)	2.46672884	0.006817679
22	ŽU (Županija)	-0.15552731	0.438202814



Pozitivna standardizirana Getis-Ord  $G_i^*$  statistika ukazuje na „*hot-spots*“ na područjima registarskih oznaka Krapinske i Zagrebačke registracijske oznake. Ova područja su statistički signifikantna. U slučaju područja registarskih oznaka Krapine vidimo da je  $Z$  vrijednost približno jednako vrijednosti, 1.96 točnije 1.90956505, odnosno  $P$  vrijednost iznosi 0.028094619 što je nešto više od 0,025.

Ostala registracijska područja nisu statistički signifikantna.



### 3.1.16 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati globalni Moranov indeks po registarskim područjima

1. Globalni Moranov indeks iznosi: 0.04673048
  2.  $p$  vrijednost iznosi 0.2925 i  $z$  vrijednost iznosi 0.5460659
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 te ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti rezultat slučajnog procesa koja se dobiva ako stavimo u odnos obračunatu premiju za motorna vozila i broj registriranih vozila

Moran I statistic standard deviate = 0.546, p-value = 0.2925		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
0.04673048	-0.04761905	0.02985694

### 3.1.17 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati lokalni Moranov indeks po registarskim područjima

		Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	BJ	-0.251855046	-0.04761905	0.2052292	-0.45082995	0.67394394
2	BM	-1.863152619	-0.04761905	0.9589382	-1.85399675	0.96813019
3	ČK	-0.031626690	-0.04761905	0.4564655	0.02367056	0.49055769
4	DA	0.121258611	-0.04761905	0.1214837	0.48452165	0.31400785
5	DJ	0.223783485	-0.04761905	0.1214837	0.77867259	0.21808630
6	KC	0.591520104	-0.04761905	0.2052292	1.41083392	0.07914680
7	KR	1.261189394	-0.04761905	0.4564655	1.93718948	0.02636109
8	KT	-0.003374955	-0.04761905	0.4564655	0.06548643	0.47389336
9	KŽ	-0.964612980	-0.04761905	0.2052292	-2.02416976	0.97852366
10	NA	0.405256437	-0.04761905	0.2052292	0.99967604	0.15873366
11	NG	0.065455478	-0.04761905	0.4564655	0.16736352	0.43354202
12	OS	-0.917650185	-0.04761905	0.2052292	-1.92050422	0.97260288
13	PŽ	-0.311659095	-0.04761905	0.1549819	-0.67070159	0.74879467
14	SB	-0.340708663	-0.04761905	0.2889746	-0.54521851	0.70719838
15	SK	-0.032243746	-0.04761905	0.9589382	0.01570104	0.49373645
16	SL	0.684284915	-0.04761905	0.2052292	1.61560270	0.05309012
17	VK	0.087487904	-0.04761905	0.2052292	0.29823469	0.38276202
18	VT	0.154061838	-0.04761905	0.2889746	0.37517587	0.35376484
19	VU	0.070025975	-0.04761905	0.2052292	0.25968928	0.39755173
20	VŽ	0.564589892	-0.04761905	0.2889746	1.13885865	0.12738106
21	ZG	0.745114901	-0.04761905	0.9589382	0.80952850	0.20910561
22	ŽU	0.770925600	-0.04761905	0.2889746	1.52269363	0.06391769


Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednosti, zaključujemo da je  $p$  vrijednost izračunata za gotovo sva registracijska područja veća od 0.05, zbog čega ne odbacujemo nul-hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu signifikantna, osim područja koje pokriva krapinska registracijska oznaka. Međutim, navedeno područje je okruženo područjima koja statistički nisu signifikantna, zbog čega ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost s obzirom na odnos iznosa obračunate premije i broja registriranih vozila.

### 3.1.18 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ po registarskim područjima

	Registarske. tablice	localG	P
1	BJ (Bjelovar)	0.509206162	0.305303862
2	BM (Beli Manastir)	-1.375985226	0.084413104

3	ČK (Čakovec)	-0.052792419	0.478948651
4	DA (Daruvar)	0.596450476	0.275437164
5	DJ (Đakovo)	0.856006845	0.195996997
6	KC (Koprivnica)	-1.707174674	0.043894795
7	KR (Krapina)	-1.810656402	0.035097028
8	KT (Kutina)	-0.122612696	0.451206900
9	KŽ (Križevci)	-2.414376906	0.007881074
10	NA (Našice)	0.810136486	0.208930868
11	NG (Nova Gradiška)	0.194513892	0.422886760
12	OS (Osijek)	1.298535936	0.097051618
13	PŽ (Požega)	1.633882495	0.051141763
14	SB (Slavonski Brod)	0.992005709	0.160597370
15	SK (Sisak)	-0.001947631	0.499223008
16	SL (Slatina)	1.236617020	0.108114649
17	VK (Vinkovci)	0.783760966	0.216590191
18	VT (Virovitica)	0.727741130	0.233386034
19	VU (Vukovar)	0.807446778	0.209704563
20	VŽ (Varaždin)	-0.797623139	0.212544609
21	ZG (Zagreb)	-1.078952199	0.140304519
22	ŽU (Županja)	0.995353326	0.159782225

Negativna standardizirana Getis-Ord  $G_i^*$  statistika ukazuje da su registarska područja Koprivnice i Križevaca, statistički signifikantna te s obzirom na manje vrijednosti dobivene ako stavimo u odnos iznos obračunate premije za motorna vozila i broj registriranih vozila predstavljaju „cold-spots“. Registarsko područje Krapine je također statistički signifikantno, na kojemu se pojavljuju manje vrijednosti, no okruženo je područjima koja nisu statistički signifikantna.




## 3.2. Podaci po područjima koja obuhvaćaju policijske postaje

Tablica 2


Policijske postaje na području Hrvatske	Broj prometnih nesreća	Stopa prometnih nesreća	Ukupni broj registriranih vozila	Stopa prometnih nesreća na 10000 vozila	Broj registriranih vozila (osobna i teretna)	Premija za osobna i teretna vozila
PP Čazma	85	65.29	6594	128.90	4505	94957.77
PP Daruvar	106	47.81	15825	66.98	12568	71660.97
PP Garešnica	118	88.91	7188	164.16	4894	94957.77
PP Grubišno Polje	62	66.47	4719	131.38	3198	71660.97
PPrP Bjelovar	343	57.57	28659	119.68	21519	94957.77
PP Nova Gradiška	229	50.42	14790	154.83	12120	94957.77
PPrP Slavonski Brod	822	72.65	42136	195.08	34327	113691.59
PP Đurđevac	159	54.62	12394	128.29	7882	94957.77
PP Križevci	191	56.08	16513	115.67	12241	78738.59
PPrP Koprivnica	269	48.80	26919	99.93	21388	94957.77
PP Donja Stubica	147	56.79	12137	121.12	10088	125008.10
PP Klanjec	27	28.94	4869	55.45	3628	125008.10
PPrP Krapina	312	53.87	27475	113.56	22755	125008.10
PP Zlatar Bistrica	121.00	48.01	10578	114.39	8785	125008.10
PP Pregrada	68.00	46.63	7027	96.77	5424	125008.10
PPrP Čakovec	809	71.09	55888	144.75	36550	94957.77
PP Beli Manastir	193	48.96	15788	122.24	11363	86486.10
PP Donji Miholjac	73.00	41.60	7072	103.22	5006	78738.59
PP Đakovo	195.00	41.01	18052	108.02	13664	86486.10
PP Našice	183	54.37	14274	128.21	10784	78738.59
PPrP Osijek	1041	75.66	52529	198.18	44918	94957.77
PP Valpovo	165	55.43	10889	151.53	8481	94957.77
PP Pakrac	690	47.16	11014	62.65	8998	71660.97
PP Požega i Pleternica	383	60.41	27206	140.78	20400	78738.59
PP Ivanec	208	56.37	16193	128.45	12186	94957.77
PP Ludbreg	119	60.17	10252	116.08	7159	94957.77
PP Novi Marof	123	46.34	12340	99.68	9488	94957.77
PPrP Varaždin	736	75.31	47120	156.20	37384	94957.77
PP Orahovica	66	57.56	4793	137.70	3557	78738.59
PP Slatina	137	100.10	9278	147.66	6698	78738.59
PPrP Virovitica	350	70.37	14920	234.58	13015	94957.77
PP Vukovar	206	49.36	15781	130.54	12917	78738.59
PP Županja	163	60.53	10467	155.73	7898	94957.77
PP Vrbanja	73	56.83	4875	149.74	3127	94957.77

PP Ilok	72	106.40	2531	284.47	1690	78738.59
PPrP Vinkovci	588	69.07	31309	91.98	24680	113691.59
PP Dvor	8	14.36	1613	49.60	999	103421.02
PP Glina	45	45.60	3411	131.93	2521	103421.02
PP Hrv. Kostajnica	44	57.41	2374	185.34	1758	103421.02
PPrP Kutina	362	97.07	18350	197.28	13711	94957.77
PP Novska	120	63.26	7948	150.98	5930	94957.77
PP Petrinja	131	52.85	9402	139.33	7712	103421.02
PP Gvozd	18	30.23	1939	92.83	1424	103421.02
PPrP Sisak i PP Sunja	473	75.04	25739	183.77	20795	103421.02
PP Dugo Selo	163	55.66	13359	122.02	11737	125005.10
PP Ivanić-Grad	166	60.14	12328	134.65	10003	125005.10
PP Jastrebarsko	180	63.38	13421	134.12	11169	125005.10
PP Samobor	320	85.03	27901	107.17	24079	125005.10
PP Velika Gorica	326	49.62	29859	109.18	26877	125005.10
PP Vrbovec	192	64.84	12680	151.42	9694	125005.10
PP Zaprešić	357	68.73	23247	153.57	20276	125005.10
PP Sv. I. Zelina	118	67.85	9183	128.50	7426	125005.10
PPrP Zagreb ( I i II)	6543	82.82	348466	187.77	321928	125005.10


Grafički prikaz premije za osobna i teretna vozila u 2016. godini prikazano u tablici 2.




Grafički prikaz prometnih nesreća po policijskim postajama u 2015. godini, prikazano u tablici 2.




Grafički prikaz stope prometnih nesreća (odnos prometnih nezgoda i broja stanovnika) u 2015. godini prikazano u tablici 2.



Grafički prikaz ukupnog broja registriranih vozila po postajama u 2015. godini prikazano u tablici 2.



Grafički prikaz prometnih nesreća u odnosu na 10.000 registriranih vozila u 2015. godini, po policijskim postajama, prikazano u tablici 2.



### 3.2.1 Globalni Moranov indeks za broj prometnih nesreća na područjima policijskih postaja

1. Globalni Moranov koeficijent za broj prometnih nesreća iznosi: -0.0385885305
  2.  $p$  vrijednost iznosi 0.7903 i  $z$  vrijednost iznosi 0.8074626
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 zbog čega ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti broja prometnih nesreća po policijskim postajama rezultat slučajnog prostornog procesa

Moran I statistic standard deviate = -0.8075, p-value = 0.7903		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
-0.0385885305	-0.0192307692	0.0005747232

### 3.2.2 Lokalni Moranov indeks za broj prometnih nesreća na područjima policijskih postaja

	Pol. postaje	$I_i$	$E.I_i$	$Var.I_i$	$Z.I_i$	$Pr(z > 0)$
1	PP Čazma	0.0484363520	-0.01923077	0.02609580	0.41888264	0.3376510
2	PP Daruvar	0.0361780988	-0.01923077	0.02884453	0.32624776	0.3721185
3	PP Garešnica	0.0406198949	-0.01923077	0.02733273	0.36201574	0.3586701
4	PP Grub. Polje	0.0577416721	-0.01923077	0.02884453	0.45321421	0.3251972
5	PPrP Bjelovar	0.0018122603	-0.01923077	0.02419284	0.13528973	0.4461914
6	PP Nova Grad.	0.0280657110	-0.01923077	0.04774203	0.21646036	0.4143145
7	PPrP Sla.Brod	-0.0864916541	-0.01923077	0.04774203	-0.30783085	0.6208945
8	PP Đurđevac	0.0264470643	-0.01923077	0.03316396	0.25082586	0.4009744
9	PP Križevci	0.0189312032	-0.01923077	0.02223041	0.25595117	0.3989943
10	PPrP Kopriv.	0.0013935519	-0.01923077	0.02884453	0.12143613	0.4516728
11	PP Donja Stub.	-0.0717684090	-0.01923077	0.02223041	-0.35236832	0.6377190
12	PP Klanjec	-0.2678075686	-0.01923077	0.03073428	-1.41791130	0.9218917
13	PPrP Krapina	-0.0301303261	-0.01923077	0.02884453	-0.06417666	0.5255852
14	PP Z. Bistrica	-0.1009305819	-0.01923077	0.02344525	-0.53357278	0.7031814
15	PP Pregrada	-0.2312984317	-0.01923077	0.03073428	-1.20965889	0.8867951
16	PPrP Čakov.	-0.0985869577	-0.01923077	0.04093893	-0.39220448	0.6525464
17	PP B.Manast.	-0.0152397389	-0.01923077	0.05908053	0.01641961	0.4934498
18	PP D.Miholj.	0.0714280516	-0.01923077	0.04093893	0.44806582	0.3270528
19	PP Đakovo	-0.0284076217	-0.01923077	0.03640353	-0.04809744	0.5191807
20	PP Našice	0.0187050549	-0.01923077	0.03316396	0.20831298	0.4174923
21	PPrP Osijek	-0.0714650927	-0.01923077	0.04093893	-0.25815927	0.6018580
22	PP Valpovo	0.0138896751	-0.01923077	0.03640353	0.17358988	0.4310939
23	PP Pakrac	0.0557077994	-0.01923077	0.03316396	0.41150224	0.3403521
24	PP Požega	-0.0049843930	-0.01923077	0.03316396	0.07822962	0.4688227



25	PP Ivanec	0.0188381344	-0.01923077	0.02506503	0.24045635	0.4049883
26	PP Ludberg	0.0105491265	-0.01923077	0.02733273	0.18012818	0.4285260
27	PP N.Marof	0.0360255584	-0.01923077	0.02506503	0.34901805	0.3635379
28	PPrP Varaždin	-0.0811069842	-0.01923077	0.03073428	-0.35294921	0.6379367
29	PP Orahovica	0.0205760248	-0.01923077	0.03640353	0.20863418	0.4173669
30	PP Slatina	0.0478948476	-0.01923077	0.03316396	0.36859981	0.3562130
31	PPrP Virovi.	0.0001355434	-0.01923077	0.03316396	0.10634419	0.4576546
32	PP Vukovar	0.0024450403	-0.01923077	0.04774203	0.09920302	0.4604885
33	PP Županja	0.0203401939	-0.01923077	0.04774203	0.18110322	0.4281433
34	PP Vrbanja	0.0330244329	-0.01923077	0.04774203	0.23915479	0.4054928
35	PP Ilok	0.0218598150	-0.01923077	0.05908053	0.16905193	0.4328779
36	PPrP Vinkovci	-0.0126399542	-0.01923077	0.04093893	0.03257398	0.4870072
37	PP Dvor	0.0774723514	-0.01923077	0.04774203	0.44257823	0.3290354
38	PP Glina	0.0716697708	-0.01923077	0.03640353	0.47642518	0.3168857
39	PP H.Kost.	0.0763109669	-0.01923077	0.04093893	0.47219880	0.3183924
40	PPrP Kutina	-0.0024507653	-0.01923077	0.02609580	0.10387397	0.4586347
41	PP Novska	0.0723121013	-0.01923077	0.03640353	0.47979175	0.3156877
42	PP Petrinja	0.0682427784	-0.01923077	0.03073428	0.49895940	0.3089040
43	PP Gvozd	0.0507073603	-0.01923077	0.04093893	0.34565733	0.3648001
44	PPrP Sisak	-0.0330879907	-0.01923077	0.02609580	-0.08578094	0.5341797
45	PP Dugo Selo	-0.0729670691	-0.01923077	0.02279733	-0.35589817	0.6390416
46	PP Ivanić Grad	-0.0831902043	-0.01923077	0.02419284	-0.41120766	0.6595399
47	PP Jastrebov	-0.1927350263	-0.01923077	0.03640353	-0.90936531	0.8184213
48	PP Samobor	-0.0238596579	-0.01923077	0.03073428	-0.02640373	0.5105323
49	PP V.Gorica	0.0053416282	-0.01923077	0.02344525	0.16047971	0.4362516
50	PP Vrbovec	-0.0524478402	-0.01923077	0.02223041	-0.22278586	0.5881489
51	PP Zaprešić	-0.0015575980	-0.01923077	0.02884453	0.10405974	0.4585610
52	PP Sv.I.Zelina	-0.0685494703	-0.01923077	0.02128553	-0.33804100	0.6323339
53	PPrP Zagreb	-1.4665908449	-0.01923077	0.02609580	-8.95965420	1.0000000


Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata za sva područja policijskih postaja veća od 0.05, zbog čega ne odbacujemo nul-hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu signifikantna, te ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost broja prometnih nesreća po policijskim postajama.

### 3.2.3 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ u odnosu na broj prometnih nesreća, na područjima policijskih postaja

ID	Registarske tablice	localG	P
1	PP Čazma	-0.61337843	0.269813072
2	PP Daruvar	-0.44140367	0.329460393
3	PP Garešnica	-0.55161390	0.290606456
4	PP Grubišno Polje	-0.59425698	0.276170123
5	PPrP Bjelovar	-0.87317428	0.191284045
6	PP Nova Gradiška	-0.42300073	0.336147365
7	PPrP Slavonski Brod	-0.31154532	0.377693048
8	PP Đurđevac	-0.35283788	0.362104992
9	PP Križevci	-0.51197021	0.304335929
10	PPrP Koprivnica	-0.05471469	0.478182882
11	PP Donja Stubica	1.45211385	0.073234976
12	PP Klanjec	2.19201961	0.014189045
13	PPrP Krapina	2.23884061	0.012583144
14	PP Zlatar Bistrica	1.65117799	0.049351118
15	PP Pregrada	2.16973880	0.015013320
16	PPrP Čakovec	-0.41727692	0.338237933
17	PP Beli Manastir	0.14397161	0.442761444
18	PP Donji Miholjac	-0.54012620	0.294555003

19	PP Đakovo	0.40462397	0.342876970
20	PP Našice	-0.28604092	0.387423389
21	PPRP Osijek	-0.17782778	0.429429114
22	PP Valpovo	-0.17970330	0.428692753
23	PP Pakrac	-0.50629877	0.306323464
24	PP Požega i Pleternica	-0.37692663	0.353114065
25	PP Ivanec	-0.46549985	0.320786771
26	PP Ludbreg	-0.15669413	0.437742957
27	PP Novi Marof	-0.56261674	0.286847945
28	PPRP Varaždin	-0.53751948	0.295454416
29	PP Orahovica	-0.17952830	0.428761447
30	PP Slatina	-0.56728444	0.285260473
31	PPRP Virovitica	-0.65715849	0.255539506
32	PP Vukovar	-0.03700536	0.485240366
33	PP Županja	-0.20449711	0.418982523
34	PP Vrbanja	-0.22764670	0.409960458
35	PP Ilok	-0.13233018	0.447361569
36	PPRP Vinkovci	-0.09686948	0.461415024
37	PP Dvor	-0.42468917	0.335531639
38	PP Glina	-0.54813092	0.291801006
39	PP Hrv. Kostajnica	-0.52447269	0.299974905
40	PPRP Kutina	-0.69088743	0.244818142
41	PP Novska	-0.72273628	0.234920960
42	PP Petrinja	-0.84499831	0.199055890
43	PP Gvozd	-0.32858389	0.371235114
44	PPRP Sisak i PP Sunja	-0.86658038	0.193085985
45	PP Dugo Selo	1.53386272	0.062531715
46	PP Ivanić-Grad	1.61438673	0.053221784
47	PP Jastrebarsko	2.54782578	0.005419829
48	PP Samobor	2.08619123	0.018480652
49	PP Velika Gorica	-0.83067100	0.203079758
50	PP Vrbovec	1.36551330	0.086045888
51	PP Zaprešić	-0.68704964	0.246025725
52	PP Sv. I. Zelina	1.31818960	0.093720094
53	PPRP Zagreb ( I i II)	-1.13342612	0.128517675

Standardizirana Getis-Ord  $G_i^*$  statistika ukazuje da su područje policijskih postaja Klanjec, Krapina, Pregrada, koja su statistički signifikantna „hot-spots“, obzirom na pozitivni lokalni  $G$  (z vrijednost). Isti je slučaj sa područjima policijskih postaja Jastrebarsko i Samobor, koja su također „hot-spots“.



### 3.2.4 Globalni Moranov indeks za stopu prometnih nesreća po policijskim postajama (u odnosu na 10.000 stanovnika)

1. Globalni Moranov koeficijent za stopu prometnih nesreća iznosi: -0.046520201
  2.  $p$  vrijednost iznosi 0.659 i  $z$  vrijednost iznosi 0.4097355
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 zbog čega ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti stope prometnih nesreća po policijskim postajama rezultat slučajnog prostornog procesa.

Moran I statistic standard deviate = -0.4097, p-value = 0.659		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
-0.046520201	-0.019230769	0.004436952

### 3.2.5 Lokalni Moranov indeks za stopu prometnih nesreća na područjima policijskih postaja (u odnosu na 10.000 stanovnika)

	Pol. Posatje	Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	PP Čazma	5.892560e-02	-0.01923077	0.06981785	0.295788412	0.3836958
2	PP Daruvar	-4.549274e-01	-0.01923077	0.08917782	-1.459001749	0.9277179
3	PP Garešnica	5.096356e-01	-0.01923077	0.07852984	1.887246400	0.0295636
4	PP Grub. Polje	2.635042e-01	-0.01923077	0.08917782	0.946784265	0.1718743
5	PPrP Bjelov.	-1.778244e-02	-0.01923077	0.05641479	0.006097774	0.4975673
6	PP Nova Grad.	1.812374e-01	-0.01923077	0.22227762	0.425204210	0.3353439
7	PPrP Sl. Brod	-2.975317e-01	-0.01923077	0.22227762	-0.590291803	0.7225024
8	PP Đurđevac	-9.899246e-02	-0.01923077	0.11960063	-0.230636282	0.5912013
9	PP Križevci	-2.226208e-02	-0.01923077	0.04259289	-0.014687952	0.5058594
10	PPrP Kopriv.	-1.887246e-01	-0.01923077	0.08917782	-0.567577848	0.7148397
11	PP D. Stub.	-9.622472e-04	-0.01923077	0.04259289	0.088518663	0.4647322
12	PP Klanjec	-6.691563e-01	-0.01923077	0.10248780	-2.030147093	0.9788292
13	PPrP Krapina	-1.134326e-01	-0.01923077	0.08917782	-0.315450429	0.6237901
14	PP Z. Bist.	2.977000e-02	-0.01923077	0.05114931	0.216662133	0.4142358
15	PP Pregrada	-1.876987e-01	-0.01923077	0.10248780	-0.526236584	0.7006380
16	PPrP Čakovac	-2.524173e-01	-0.01923077	0.17436169	-0.558441883	0.7117286
17	PP B. Manas.	9.562181e-02	-0.01923077	0.30213750	0.208948110	0.4172443
18	PP D. Mihoļj.	-2.122196e-01	-0.01923077	0.17436169	-0.462175184	0.6780221
19	PP Đakovo	-3.084454e-01	-0.01923077	0.14241774	-0.766369592	0.7782717
20	PP Našice	-2.459577e-02	-0.01923077	0.11960063	-0.015513256	0.5061886
21	PPrP Osijek	-3.999441e-01	-0.01923077	0.17436169	-0.911743187	0.8190480
22	PP Valpovo	1.103333e-01	-0.01923077	0.14241774	0.343322590	0.3656778
23	PP Pakrac	-1.783403e-01	-0.01923077	0.11960063	-0.460075972	0.6772691
24	PP Požega	1.976193e-03	-0.01923077	0.11960063	0.061321353	0.4755516
25	PP Ivanec	4.743356e-02	-0.01923077	0.06255786	0.266533980	0.3949140
26	PP Ludbreg	-7.005567e-05	-0.01923077	0.07852984	0.068374526	0.4727437
27	PP N. Marof	1.367680e-01	-0.01923077	0.06255786	0.623706496	0.2664101
28	PPrP Varaž.	-2.169903e-01	-0.01923077	0.10248780	-0.617733793	0.7316245

29	PP Orahovica	-3.531177e-02	-0.01923077	0.14241774	-0.042611912	0.5169945
30	PP Slatina	-4.345831e-01	-0.01923077	0.11960063	-1.201019035	0.8851280
31	PPrP Vorov.	2.218161e-01	-0.01923077	0.11960063	0.697003152	0.2429004
32	PP Vukovar	-5.575856e-01	-0.01923077	0.22227762	-1.141880680	0.8732481
33	PP Županja	-1.078087e-02	-0.01923077	0.22227762	0.017922715	0.4928502
34	PP Vrbanja	-1.272218e-01	-0.01923077	0.22227762	-0.229055048	0.5905869
35	PP Ilok	-2.610497e-01	-0.01923077	0.30213750	-0.439934516	0.6700077
36	PPrP Vinkovci	2.576454e-01	-0.01923077	0.17436169	0.663071065	0.2536425
37	PP Dvor	3.688440e-01	-0.01923077	0.22227762	0.823128287	0.2052175
38	PP Glina	6.827595e-01	-0.01923077	0.14241774	1.860154529	0.0314318
39	PP H.Kost.	9.000253e-02	-0.01923077	0.17436169	0.261595047	0.3968168
40	PPrP Kutina	3.093535e-01	-0.01923077	0.06981785	1.243550663	0.1068324
41	PP Novska	-3.653286e-03	-0.01923077	0.14241774	0.041277678	0.4835372
42	PP Petrinja	3.216083e-01	-0.01923077	0.10248780	1.064665643	0.1435136
43	PP Gvozd	2.854831e-01	-0.01923077	0.17436169	0.729737631	0.2327752
44	PPrP Sisak	-1.495256e-01	-0.01923077	0.06981785	-0.493110099	0.6890326
45	PP Dugo Selo	-7.546018e-02	-0.01923077	0.04658589	-0.260517178	0.6027675
46	PP Ivan. Grad	2.775097e-03	-0.01923077	0.05641479	0.092649262	0.4630911
47	PP Jastrebov	-8.494530e-02	-0.01923077	0.14241774	-0.174132298	0.5691192
48	PP Samobor	-6.371544e-01	-0.01923077	0.10248780	-1.930184017	0.9732079
49	PP V.Gorica	2.054285e-03	-0.01923077	0.05114931	0.094114140	0.4625092
50	PP Vrbovec	2.483889e-02	-0.01923077	0.04259289	0.213536001	0.4154544
51	PP Zaprešić	-2.369242e-01	-0.01923077	0.08917782	-0.728982223	0.7669937
52	PP Sv.I.Zeli.	2.994676e-03	-0.01923077	0.03593790	0.117239542	0.4533351
53	PPrP Zagreb	-2.122623e-01	-0.01923077	0.06981785	-0.730541727	0.7674704


Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata manja od 0.05 za područja policijskih postaja Garešnica i Glina zbog čega odbacujemo nul-hipotezu, međutim navedena područja su okružena područjima susjednih postaja koja nisu signifikantna iz kojeg razloga ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost stope prometnih nesreća na području policijskih postaja.

### 3.2.6 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za stopu prometnih nesreća na područjima policijskih postaja (u odnosu na 10.000 stanovnika)

ID	Registarske.tablice	localG	P
1	PP Čazma	0.71212756	0.23819289
2	PP Daruvar	1.99617456	0.02295746
3	PP Garešnica	1.17280027	0.12043795
4	PP Grubišno Polje	2.25208952	0.01215831
5	PPrP Bjelovar	0.48868003	0.31253412
6	PP Nova Gradiška	-0.67395287	0.25017064
7	PPrP Slavonski Brod	-0.78463022	0.21633520
8	PP Đurđevac	0.84555485	0.19890056
9	PP Križevci	0.42819522	0.33425450
10	PPrP Koprivnica	0.87930704	0.18961741
11	PP Donja Stubica	0.00631650	0.49748010
12	PP Klanjec	1.02068505	0.1537018
13	PPrP Krapina	0.98437339	0.16246598
14	PP Zlatar Bistrica	-0.23932481	0.40542687

15	PP Pregrada	0.67020706	0.25136290
16	PPrP Čakovec	-0.86002132	0.19488865
17	PP Beli Manastir	-0.27817906	0.39043745
18	PP Donji Miholjac	0.40388183	0.34314981
19	PP Đakovo	0.65076552	0.25759893
20	PP Našice	0.18688289	0.42587623
21	PPrP Osijek	-0.96008428	0.16850640
22	PP Valpovo	-1.04917039	0.14704985
23	PP Pakrac	0.61423794	0.26952905
24	PP Požega i Pleternica	0.23692965	0.40635568
25	PP Ivanec	-0.86534647	0.19342433
26	PP Ludbreg	-0.02584141	0.48969192
27	PP Novi Marof	-0.71757002	0.23651122
28	PPrP Varaždin	-0.67334430	0.25036414
29	PP Orahovica	0.61150844	0.27043152
30	PP Slatina	-0.40433005	0.34298502
31	PPrP Virovitica	1.04330575	0.14840336
32	PP Vukovar	1.78138201	0.03742503
33	PP Županja	-0.72012225	0.23572486
34	PP Vrbanja	1.36617418	0.08594215
35	PP Ilok	-0.07917875	0.46844522
36	PPrP Vinkovci	1.13264424	0.12868184
37	PP Dvor	-0.41470048	0.33918059
38	PP Glina	-2.09443213	0.01811075
39	PP Hrv. Kostajnica	-1.34902328	0.08866474
40	PPrP Kutina	0.70373070	0.24080025
41	PP Novska	-0.03900032	0.48444507
42	PP Petrinja	-2.30831002	0.01049095
43	PP Gvozd	-0.46507446	0.32093907
44	PPrP Sisak i PP Sunja	-0.55548989	0.28927981
45	PP Dugo Selo	1.29233121	0.09812123
46	PP Ivanić-Grad	1.54022452	0.06175282
47	PP Jastrebarsko	-1.07696887	0.14074709
48	PP Samobor	-1.23412547	0.10857808
49	PP Velika Gorica	-0.06550119	0.47388748
50	PP Vrbovec	0.43523389	0.33169633
51	PP Zaprešić	-1.45328803	0.07307190
52	PP Sv. I. Zelina	0.07934278	0.46837999
53	PPrP Zagreb ( I i II)	-0.48758691	0.31292124

Standardizirana Getis-Ord  $G_i$  statistika ukazuje da su područje policijskih postaja Daruvar i Grubišno Polje, obzirom na pozitivni lokalni  $G$  ( $z$  vrijednost), statistički signifikantna te predstavljaju „*hot-spots*“. U slučaju područja policijskih postaja Glina i Petrinja, navedena područja su statistički signifikantna te predstavljaju „*cold-spots*“, obzirom na negativni lokalni  $G$  ( $z$  vrijednost).



### 3.2.7 Globalni Moranov indeks za broj registriranih vozila na područjima policijskih postaja

1. Globalni Moranov koeficijent za broj registriranih vozila za područja policijskih postaja iznosi: -0.0275816668
  2.  $p$  vrijednost iznosi 0.6271 i  $z$  vrijednost iznosi 0.3214823
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 zbog čega ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti broja registriranih vozila po policijskim postajama rezultat slučajnog prostornog procesa

Moran I statistic standard deviate = -0.3241, p-value = 0.6271		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
-0.0275816668	-0.0192307692	0.0006639485

### 3.2.8 Lokalni Moranov koeficijent za broj registriranih vozila na područjima policijskih postaja

	Pol. postaje	Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	PP Čazma	0.051125713	-0.01923077	0.02710587	0.427338905	0.3345662
2	PP Daruvar	0.021233191	-0.01923077	0.03023835	0.232696221	0.4079987
3	PP Garešnica	0.054867381	-0.01923077	0.02851549	0.438800348	0.3304031
4	PP Grub.Polj.	0.077340214	-0.01923077	0.03023835	0.555351049	0.2893273
5	PPRP Bjelov.	-0.028008266	-0.01923077	0.02493723	-0.055583585	0.5221632
6	PP Nova.Grad.	0.024482680	-0.01923077	0.05177415	0.192113803	0.4238265
7	PPRP Sl.Brod	-0.057321730	-0.01923077	0.05177415	-0.167403844	0.5664738
8	PP Đurđevac	0.024329924	-0.01923077	0.03516082	0.232308598	0.4081492
9	PP Križevci	0.009309053	-0.01923077	0.02270082	0.189422025	0.4248810
10	PPRP Kopriv.	0.002660042	-0.01923077	0.03023835	0.125887552	0.4499105
11	PP Donj.Stub.	-0.077260252	-0.01923077	0.02270082	-0.385148240	0.6499362
12	PP Klanjec	-0.282137835	-0.01923077	0.03239193	-1.460776701	0.9279616
13	PPRP Krapina	0.077023492	-0.01923077	0.03023835	0.553529677	0.2899504
14	PP Z.Bistri.	-0.110266150	-0.01923077	0.02408527	-0.586589782	0.7212604
15	PP Pregrada	-0.246620417	-0.01923077	0.03239193	-1.263433139	0.8967832
16	PPRP Čakov.	-0.091921077	-0.01923077	0.04402127	-0.346453737	0.6354991
17	PP B.Manast.	-0.003091161	-0.01923077	0.06469564	0.063453488	0.4747027
18	PP Đ.Miholj.	0.080596690	-0.01923077	0.04402127	0.475793779	0.3171107
19	PP Đakovo	-0.008985417	-0.01923077	0.03885267	0.051977625	0.4792733
20	PP Našice	0.020280452	-0.01923077	0.03516082	0.210712817	0.4165557
21	PPRP Osijek	-0.056390257	-0.01923077	0.04402127	-0.177108112	0.5702883
22	PP Valpovo	0.019713260	-0.01923077	0.03885267	0.197574293	0.4216891
23	PP Pakrac	0.048362056	-0.01923077	0.03516082	0.360471635	0.3592472
24	PP Požega	-0.013915915	-0.01923077	0.03516082	0.028344048	0.4886939
25	PP Ivanec	0.010445293	-0.01923077	0.02593119	0.184287146	0.4268941
26	PP Ludberg	-0.007275563	-0.01923077	0.02851549	0.070797297	0.4717795
27	PP N.Marof	0.019869504	-0.01923077	0.02593119	0.242811113	0.4040759
28	PPRP Varaždin	-0.071016901	-0.01923077	0.03239193	-0.287736560	0.6132258
29	PP Orahovica	0.032298447	-0.01923077	0.03885267	0.261422575	0.3968833
30	PP Slatina	0.058936972	-0.01923077	0.03516082	0.416867521	0.3383877
31	PPRP Virovi.	0.033624035	-0.01923077	0.03516082	0.281873965	0.3890201
32	PP Vukovar	0.014909702	-0.01923077	0.05177415	0.150042057	0.4403657
33	PP Županja	0.027257997	-0.01923077	0.05177415	0.204310889	0.4190553
34	PP Vrbanja	0.059856223	-0.01923077	0.05177415	0.347575016	0.3640797
35	PP Ilok	0.046919902	-0.01923077	0.06469564	0.260073898	0.3974034
36	PPRP Vinkov.	-0.019270339	-0.01923077	0.04402127	-0.000188597	0.5000752
37	PP Dvor	0.116494767	-0.01923077	0.05177415	0.596492601	0.2754231
38	PP Glina	0.092647066	-0.01923077	0.03885267	0.567588524	0.2851572
39	PP H.Kost.	0.117825530	-0.01923077	0.04402127	0.653232437	0.2568032
40	PPRP Kutina	0.015487509	-0.01923077	0.02710587	0.210875679	0.4164921
41	PP Novska	0.087180926	-0.01923077	0.03885267	0.539857219	0.2946478
42	PP Petrinja	0.080746816	-0.01923077	0.03239193	0.555500196	0.2892763
43	PP Gvozd	0.057253224	-0.01923077	0.04402127	0.364535051	0.3577293
44	PPRP Sisak	-0.018557429	-0.01923077	0.02710587	0.004089807	0.4983684
45	PP Dugo Selo	-0.070501970	-0.01923077	0.02334689	-0.335551298	0.6313954
46	PP Ivan Grad	-0.086506843	-0.01923077	0.02493723	-0.426026408	0.6649557
47	PP Jastrebov	-0.196539418	-0.01923077	0.03885267	-0.899537910	0.8158169
48	PP Samobor	0.084509020	-0.01923077	0.03239193	0.576403933	0.2821711
49	PP V.Gorica	-0.031886483	-0.01923077	0.02408527	-0.081547550	0.5324967
50	PP Vrbovec	-0.066363022	-0.01923077	0.02270082	-0.312822091	0.6227921
51	PP Zaprešić	-0.002877956	-0.01923077	0.03023835	0.094040174	0.4625386
52	PP Sv.I.Zeli.	-0.081725996	-0.01923077	0.02162403	-0.424989813	0.6645779
53	PPRP Zagreb	-1.300975027	-0.01923077	0.02710587	-7.785198563	1.0000000

Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata za sva područja policijskih postaja veća od 0.05, zbog čega ne odbacujemo nul-hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu


signifikantna, te ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost broja registriranih vozila na području policijskih postaja.

### 3.2.9 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ s obzirom na ukupni broj registriranih vozila na područjima policijskih postaja

ID	Registarske.tablice	localG	P
1	PP Čazma	-0.57686575	0.282015073
2	PP Daruvar	-0.49244371	0.311202853
3	PP Garešnica	-0.60237292	0.273462967
4	PP Grubišno Polje	-0.68463632	0.246786722
5	PPRP Bjelovar	-0.85754643	0.195571483
6	PP Nova Gradiška	-0.31097916	0.377908234
7	PPRP Slavonski Brod	-0.26301199	0.396270669
8	PP Đurđevac	-0.32689737	0.371872754
9	PP Križevci	-0.35610412	0.360881297
10	PPRP Koprivnica	0.09682309	0.461433442
11	PP Donja Stubica	1.63057008	0.051490533
12	PP Klanjec	2.24471337	0.012393270
13	PPRP Krapina	2.34636905	0.009478663
14	PP Zlatar Bistrica	1.84325415	0.032645956
15	PP Pregrada	2.23797603	0.012611309
16	PPRP Čakovec	-0.26711552	0.394690108
17	PP Beli Manastir	0.03305574	0.486815069
18	PP Donji Miholjac	-0.58049289	0.280791141
19	PP Đakovo	0.23807088	0.405913059
20	PP Našice	-0.33240422	0.369792028
21	PPRP Osijek	-0.17510882	0.430497064
22	PP Valpovo	-0.21578843	0.414576332
23	PP Pakrac	-0.56461107	0.286169166
24	PP Požega i Pleternica	-0.37977172	0.352057438
25	PP Ivanec	-0.31147674	0.377719112
26	PP Ludbreg	0.07891226	0.468551206
27	PP Novi Marof	-0.37187193	0.354994101
28	PPRP Varaždin	-0.37784336	0.352773480
29	PP Orahovica	-0.23740259	0.406172241
30	PP Slatina	-0.59894787	0.274603823
31	PPRP Virovitica	-0.58989693	0.277629877
32	PP Vukovar	-0.21848207	0.413526763
33	PP Županja	-0.22723217	0.410121607
34	PP Vrbanja	-0.34042977	0.366766453
35	PP Ilok	-0.20753228	0.417797092
36	PPRP Vinkovci	-0.22773179	0.409927378
37	PP Dvor	-0.55255560	0.290283875
38	PP Glina	-0.60237437	0.273462483
39	PP Hrv. Kostajnica	-0.65354524	0.256702418
40	PPRP Kutina	-0.64947123	0.258016919
41	PP Novska	-0.73380570	0.231533584
42	PP Petrinja	-0.88913708	0.186964707
43	PP Gvozd	-0.32128530	0.373997098
44	PPRP Sisak i PP Sunja	-0.97359054	0.165129943
45	PP Dugo Selo	1.61416730	0.053245571
46	PP Ivanić-Grad	1.61359100	0.053308085
47	PP Jastrebarsko	2.58720960	0.004837836
48	PP Samobor	2.21126224	0.013508841
49	PP Velika Gorica	-0.85683421	0.195768258
50	PP Vrbovec	1.47727086	0.069801523
51	PP Zaprešić	-0.57033155	0.284226423
52	PP Sv. I. Zelina	1.45471255	0.072874428
53	PPRP Zagreb ( I i II)	-0.74178871	0.229107680



Pozitivna standardizirana Getis-Ord  $G_i$  statistika ukazuje da su područje policijskih postaja Klanjec, Krapina, Zlatar Bistrice, Pregrada, koja su statistički signifikantna, „*hot-spot*“, obzirom na pozitivni lokalni  $G$  ( $z$  vrijednost). Isti je slučaj sa područjima policijskih postaja Jasterbarsko i Samobor, koje su također „*hot-spot*“.



### 3.2.10 Globalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila na područjima policijskih postaja

1. Globalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila iznosi: -0.145296972
  2.  $p$  vrijednost iznosi 0.9722 i  $z$  vrijednost iznosi 1.914158
- $p$  vrijednost je veća od razine signifikantnosti koja iznosi 0,05 zbog čega ne odbacujemo nul-hipotezu (vrijednost nije statistički značajna). Iz navedenog se zaključuje da je sasvim moguće da je prostorna distribucija vrijednosti stope prometnih nesreća na 10.000 vozila, po policijskim postajama rezultat slučajnog prostornog procesa

Moran I statistic standard deviate = -1.9144, p-value = 0.9722		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
-0.145296972	-0.019230769	0.004336216

### 3.2.11 Lokalni Moranov indeks za stopu prometnih nesreća na 10.000 registriranih vozila na područjima policijskih postaja

	Pol.Postje	Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	PP Čazma	-0.004551567	-0.01923077	0.06867748	0.05601383	0.4776654
2	PP Daruvar	-0.683813215	-0.01923077	0.08760419	-2.245362260	0.9876276
3	PP Garešnica	0.100954528	-0.01923077	0.07719450	0.432571754	0.3326630
4	PP Grub.Polje	-0.027903430	-0.01923077	0.08760419	-0.029301504	0.5116879
5	PPrP Bjelovar	0.022590967	-0.01923077	0.05557437	0.177404559	0.4295953
6	PP NOVA Grad.	-0.338073596	-0.01923077	0.21772534	-0.683316903	0.7527967
7	PPrP Sla.Brod	-0.220379974	-0.01923077	0.21772534	-0.431085915	0.6667970
8	PP Đurđevac	-0.038500267	-0.01923077	0.11734617	-0.056251737	0.5224294
9	PP Križevci	0.048519345	-0.01923077	0.04206179	0.330343787	0.3705701
10	PPrP Kopriv.	-0.030399600	-0.01923077	0.08760419	-0.037735079	0.5150505
11	PP Donja Stub.	0.083587313	-0.01923077	0.04206179	0.501332214	0.3080687
12	PP Klanjec	0.030746234	-0.01923077	0.10061631	0.157556390	0.4374032
13	PPrP Krapina	0.025659317	-0.01923077	0.08760419	0.151665917	0.4397252
14	PP Z.Bistrica	0.135289258	-0.01923077	0.05042672	0.688104509	0.2456935
15	PP Pregrada	0.109645603	-0.01923077	0.10061631	0.406292791	0.3422637
16	PPrP Čakov.	-0.128828762	-0.01923077	0.17088173	-0.265127509	0.6045444
17	PP B.Manast.	-0.117427198	-0.01923077	0.29579802	-0.180550236	0.5716397
18	PP D.Miholjac	-0.044168804	-0.01923077	0.17088173	-0.060327372	0.5240525
19	PP Đakovo	-0.286215859	-0.01923077	0.13965265	-0.714434498	0.7625207
20	PP Našice	-0.021723450	-0.01923077	0.11734617	-0.007276661	0.5029029
21	PPrP Osijek	-0.515676697	-0.01923077	0.17088173	-1.200947831	0.8851143
22	PP Valpovo	-0.020183200	-0.01923077	0.13965265	-0.002548641	0.5010168
23	PP Pakrac	-0.585104323	-0.01923077	0.11734617	-1.651904513	0.9507230
24	PP Požega	-0.024602297	-0.01923077	0.11734617	-0.015680625	0.5062554
25	PP Ivanec	0.065624973	-0.01923077	0.06157996	0.341949145	0.3661946
26	PP Ludbreg	0.085191507	-0.01923077	0.07719450	0.375837381	0.3535189
27	PP N.Marof	0.285083821	-0.01923077	0.06157996	1.226317879	0.1100395
28	PPrP Varaždin	-0.217129250	-0.01923077	0.10061631	-0.623890355	0.7336502
29	PP Orahovica	0.014228964	-0.01923077	0.13965265	0.089536039	0.4643280
30	PP Slatina	-0.002643667	-0.01923077	0.11734617	0.048421258	0.4806903
31	PPrP Virovi.	-1.019513861	-0.01923077	0.11734617	-2.920037778	0.9982501
32	PP Vukovar	-0.161112984	-0.01923077	0.21772534	-0.304069929	0.6194627
33	PP Županja	-0.178306447	-0.01923077	0.21772534	-0.340917501	0.6334172
34	PP Vrbanja	0.258757426	-0.01923077	0.21772534	0.595760723	0.2756675
35	PP Ilok	-0.943338015	-0.01923077	0.29579802	-1.699122696	0.9553520
36	PPrP Vinkovci	-1.095036885	-0.01923077	0.17088173	-2.602472796	0.9953723
37	PP Dvor	-1.231247870	-0.01923077	0.21772534	-2.597492253	0.9953046
38	PP Glina	0.015086548	-0.01923077	0.13965265	0.091830878	0.4634162
39	PP H.Kost.	-0.113880237	-0.01923077	0.17088173	-0.228965667	0.5905522
40	PPrP Kutina	-0.191614758	-0.01923077	0.06867748	-0.657793755	0.7446647
41	PP Novska	-0.068732544	-0.01923077	0.13965265	-0.132463484	0.5526911
42	PP Petrinja	-0.038730540	-0.01923077	0.10061631	-0.061474545	0.5245094
43	PP Grozd	-0.111998658	-0.01923077	0.17088173	-0.224413957	0.5887824
44	PPrP Sisak	-0.046692035	-0.01923077	0.06867748	-0.104788441	0.5417282
45	PP Dugo Selo	-0.015791148	-0.01923077	0.04596543	0.016043345	0.4935999
46	PP Ivanić Grad	-0.001901167	-0.01923077	0.05557437	0.073510827	0.4706998
47	PP Jastrebov.	0.008129894	-0.01923077	0.13965265	0.073215331	0.4708174
48	PP Samobor	0.321382935	-0.01923077	0.10061631	1.073811200	0.1414537
49	PP V.Gorica	0.050084366	-0.01923077	0.05042672	0.308672333	0.3787854
50	PP Vrbovec	-0.031691796	-0.01923077	0.04206179	-0.060758907	0.5242244
51	PP Zaprešić	-0.260913000	-0.01923077	0.08760419	-0.816549042	0.7929069
52	PP Sv.I.Zelina	0.025909511	-0.01923077	0.03555574	0.239391880	0.4054009
53	PPrP Zagreb	-0.569384944	-0.01923077	0.06867748	-2.099313188	0.9821053

Kako je vidljivo iz tablice, ako uzmemo u obzir  $p$  vrijednost, zaključujemo da je  $p$  vrijednost izračunata sa sva područja policijskih postaja veća od 0.05, zbog čega ne odbacujemo nul- hipotezu. Iz navedenog proizlazi da navedena područja statistički nisu


signifikantna, te ne možemo utvrditi da li postoji autokorelacija, odnosno statistička prostorna povezanost stope prometnih nezgoda na 10.000 registriranih vozila.

### 3.2.12 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za stopu prometnih nesreća na 10.000 registriranih vozila, na područjima policijskih postaja

ID	Registarske.tablice	localG	P
1	PP Čazma	0.102514228	0.459174260
2	PP Daruvar	1.286823754	0.099077863
3	PP Garešnica	0.548024752	0.291837454
4	PP Grubišno Polje	1.018195874	0.154292440
5	PPrP Bjelovar	-0.279441284	0.389953096
6	PP Nova Gradiška	-1.439889487	0.074949334
7	PPrP Slavonski Brod	-0.261246793	0.396951097
8	PP Đurđevac	0.653082189	0.256851647
9	PP Križevci	-0.535254627	0.296236898
10	PPrP Koprivnica	0.064743150	0.474189253
11	PP Donja Stubica	-1.210571465	0.113029843
12	PP Klanjec	-0.165235045	0.434379491
13	PPrP Krapina	-0.193608407	0.423241257
14	PP Zlatar Bistrica	-1.215406109	0.112105620
15	PP Pregrada	-0.416736196	0.338435688
16	PPrP Čakovec	-1.268642292	0.102284337
17	PP Beli Manastir	0.658683426	0.255049539
18	PP Donji Miholjac	0.100101410	0.460131908
19	PP Đakovo	1.099924705	0.135682465
20	PP Našice	0.360236051	0.359335309
21	PPrP Osijek	-0.734893922	0.231202050
22	PP Valpovo	-0.111234163	0.455715331
23	PP Pakrac	0.872253559	0.191535034
24	PP Požega i Pleternica	-0.492698040	0.311112981
25	PP Ivanec	-1.616287020	0.053016136
26	PP Ludbreg	-0.677465144	0.249055439
27	PP Novi Marof	-1.374253829	0.084681447
28	PPrP Varaždin	-1.264942511	0.102945968
29	PP Orahovica	0.576536730	0.282126225
30	PP Slatina	-0.008182098	0.496735852
31	PPrP Virovitica	-1.126808050	0.129911823
32	PP Vukovar	3.031942993	0.001214925
33	PP Županja	-0.716407689	0.236869824
34	PP Vrbanja	1.515753737	0.064790817
35	PP Ilok	-0.391832756	0.347590895
36	PPrP Vinkovci	2.423958437	0.007676181
37	PP Dvor	1.195210123	0.116002472
38	PP Glina	-0.517443693	0.302423233
39	PP Hrv. Kostajnica	-0.166644470	0.433824901
40	PPrP Kutina	-0.373245747	0.354482776
41	PP Novska	-0.441548605	0.329407941
42	PP Petrinja	-1.133898098	0.128418647
43	PP Gvozd	0.212240507	0.415959703
44	PPrP Sisak i PP Sunja	-0.064914082	0.474121204
45	PP Dugo Selo	0.200501285	0.420544276
46	PP Ivanić-Grad	0.793760333	0.213667485
47	PP Jastrebarsko	-0.924747093	0.177548738
48	PP Samobor	-1.494221743	0.067558836
49	PP Velika Gorica	-0.399141595	0.344894438

50 PP Vrbovec -0.345653648 0.364801511  
 51 PP Zaprešić -1.877178540 0.030246814  
 52 PP Sv. I. Zelina -0.863496631 0.193932236  
 53 PPrP Zagreb ( I i II) -1.585225227 0.056457585

Standardizirana pozitivna Getis-Ord  $G_i^*$  statistika ukazuje da su područje policijskih postaja Vukovar i Vinkovci, koja su statistički signifikantna, „hot-spots“, obzirom na pozitivni lokalni  $G$  (z vrijednost).



### 3.2.13 Globalni Moranov indeks za premiju za osiguranje od auto odgovornosti na područjima policijskih postaja, u 2016. godini


1. Globalni Moranov indeks za premiju za osiguranje od auto odgovornosti iznosi: 0.565381212
2.  $p$  vrijednost iznosi  $2.2e-16$  i  $z$  vrijednost iznosi - 8.127013  
 -  $p$  vrijednost je dovoljno mala, ispod 0.05, čime možemo odbaciti nul-hipotezu. Obzirom da je vrijednost globalnog Moranovog koeficijenta pozitivna 0.565381212 upućuje na grupiranje područja policijskih postaja za koja područja se obračunavaju veće premije, odnosno manje premije.

Moran I statistic standard deviate = 8.5812, p-value < 2.2e-16		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
0.565381212	-0.019230769	0.004641291

### 3.2.14 Lokalni Moranov indeks za premiju za osiguranje od auto odgovornosti na područjima policijskih postaja, u 2016. godini

	Pol.postaje	Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	PP Čazma	-0.110992599	-0.01923077	0.07213105	-0.34166535	6.336986e-01
2	PP Daruvar	1.114970685	-0.01923077	0.09236987	3.73185736	9.503656e-05
3	PP Garešnica	0.157757827	-0.01923077	0.08123852	0.62096095	2.673127e-01
4	PP Grub.Polj.	0.943359772	-0.01923077	0.09236987	3.16720684	7.695540e-04
5	PPrP Bjelov.	0.020093446	-0.01923077	0.05811956	0.16311688	4.352132e-01
6	PP Nova Grad	0.386820672	-0.01923077	0.23151176	0.84390689	1.993607e-01
7	PPrP S.Brod	-0.864900112	-0.01923077	0.23151176	-1.75757579	9.605901e-01
8	PP Đurđevac	0.203463120	-0.01923077	0.12417373	0.63196560	2.637047e-01
9	PP Križevci	-0.413217204	-0.01923077	0.04367021	-1.88533547	9.703077e-01
10	PPrP Kopriv.	0.072543097	-0.01923077	0.09236987	0.30196309	3.813401e-01
11	PP Donja St.	1.297931129	-0.01923077	0.04367021	6.30298871	1.459801e-10
12	PP Klanjec	1.684702301	-0.01923077	0.10628406	5.22659043	8.633220e-08
13	PPrP Krapina	1.177099359	-0.01923077	0.09236987	3.93627903	4.137737e-05
14	PP Z.Bistri.	1.199178548	-0.01923077	0.05261504	5.31175755	5.428649e-08
15	PP Pregrada	1.380144590	-0.01923077	0.10628406	4.29239973	8.837619e-06
16	PPrP Čakov.	0.159687537	-0.01923077	0.18142068	0.42006006	3.372208e-01
17	PP B.Manast.	0.504923153	-0.01923077	0.31499689	0.93391146	1.751748e-01
18	PP D.Miholj.	1.217000950	-0.01923077	0.18142068	2.90239482	1.851607e-03
19	PP Đakovo	0.091274399	-0.01923077	0.14802662	0.28721867	3.869724e-01
20	PP Našice	0.956688569	-0.01923077	0.12417373	2.76948528	2.807247e-03
21	PPrP Osijek	0.153159475	-0.01923077	0.18142068	0.40473363	3.428367e-01
22	PP Valpovo	0.299869143	-0.01923077	0.14802662	0.82938613	2.034430e-01
23	PP Pakrac	1.379744463	-0.01923077	0.12417373	3.97004257	3.592990e-05
24	PP Požega	1.181457322	-0.01923077	0.12417373	3.40733898	3.279980e-04
25	PP Ivanec	-0.194357531	-0.01923077	0.06454149	-0.68933927	7.546951e-01
26	PP Ludbreg	0.020568007	-0.01923077	0.08123852	0.13963321	4.444749e-01
27	PP N.Marof	-0.194352973	-0.01923077	0.06454149	-0.68932133	7.546895e-01
28	PPrP Varaž.	-0.136388781	-0.01923077	0.10628406	-0.35936678	6.403396e-01
29	PP Orahovi.	0.948671934	-0.01923077	0.14802662	2.51571700	5.939526e-03
30	PP Slatina	1.540149368	-0.01923077	0.12417373	4.42524313	4.816686e-06
31	PPrP Virovi.	0.324805644	-0.01923077	0.12417373	0.97631407	1.644544e-01
32	PP Vukovar	0.687502723	-0.01923077	0.23151176	1.46882193	7.094055e-02
33	PP Županja	0.127701709	-0.01923077	0.23151176	0.30537345	3.80409e-01
34	PP Vrbanja	0.163010834	-0.01923077	0.23151176	0.37875729	3.524341e-01
35	PP Ilok	0.336014089	-0.01923077	0.31499689	0.63295767	2.633806e-01
36	PPrP Vinko.	-0.456692312	-0.01923077	0.18142068	-1.02706159	8.478043e-01
37	PP Dvor	0.028712295	-0.01923077	0.23151176	0.09964127	4.603146e-01
38	PP Glina	0.063755535	-0.01923077	0.14802662	0.21569323	4.146134e-01
39	PP H.Kost.	0.012223492	-0.01923077	0.18142068	0.07384755	4.705658e-01
40	PPrP Kutina	-0.008561355	-0.01923077	0.07213105	0.03972642	4.841556e-01
41	PP Novska	0.287188014	-0.01923077	0.14802662	0.79642607	2.128922e-01
42	PP Petrinja	0.097254084	-0.01923077	0.10628406	0.35730195	3.604329e-01
43	PP Gvozd	0.112816072	-0.01923077	0.18142068	0.31001637	3.782743e-01
44	PPrP Sisak	0.082685542	-0.01923077	0.07213105	0.37947448	3.521678e-01
45	PP Dugo Sel.	0.855935156	-0.01923077	0.04784446	4.00105527	3.153031e-05
46	PP Iv.Grad	0.681624263	-0.01923077	0.05811956	2.90714735	1.823707e-03
47	PP Jastrebo.	1.697373003	-0.01923077	0.14802662	4.46169774	4.065643e-06
48	PP Samobor	1.989107984	-0.01923077	0.10628406	6.16031479	3.630024e-10
49	PP V.Gorica	1.314983520	-0.01923077	0.05261504	5.81661903	3.002489e-09
50	PP Vrbovec	0.579342265	-0.01923077	0.04367021	2.86433967	2.089398e-03
51	PP Zaprešić	1.989091093	-0.01923077	0.09236987	6.60797137	1.948110e-11
52	PP Sv.I.Zel.	0.833214381	-0.01923077	0.03671311	4.44893269	4.314903e-06
53	PPrP Zagreb	1.989066524	-0.01923077	0.07213105	7.47768006	3.782304e-14

Izračunom lokalnog Moranovog indeksa za područje svake policijske postaje utvrdili smo grupiranja nižih vrijednosti obračunate premije na statistički signifikantnim područjima policijskih postaja Daruvar, Grubišno polje, Donji Miholjac, Našice, Pakrac, Požega, Orahovica i Slatina. Također utvrđeno je grupiranje viših vrijednosti obračunate premije na statistički signifikantnim područjima policijskih postaja Donja Stubica, Klanjac, Krapina, Zlatar Bistrica, Pregrada, Dugo Selo, Ivanić Grad, Jastrebarsko, Samobor, Velika Gorica, Vrbovec, Zaprešić, Sv.I.Zelina, Zagreb.




### 3.2.15 Utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“ za premiju za osiguranje od auto odgovornosti, za 2016. godinu, za područja policijskih postaja

ID	Registarske.tablice	LG10	LGP10
1	PP Čazma	1.26135649	1.035902e-01
2	PP Daruvar	-2.34412314	9.535937e-03
3	PP Garešnica	-1.73992123	4.093643e-02
4	PP Grubišno Polje	-1.99962955	2.277014e-02
5	PPRP Bjelovar	-0.28396842	3.882173e-01
6	PP Nova Gradiška	-2.50586121	6.107678e-03
7	PPRP Slavonski Brod	-2.30718581	1.052223e-02
8	PP Đurđevac	-1.80887615	3.523512e-02
9	PP Križevci	1.46840589	7.099700e-02
10	PPRP Koprivnica	-0.76081732	2.233831e-01
11	PP Donja Stubica	4.55544490	2.613741e-06
12	PP Klanjec	3.75705897	8.596100e-05
13	PPRP Krapina	2.84344715	2.231420e-03
14	PP Zlatar Bistrica	3.84104411	6.125605e-05
15	PP Pregrada	3.09294562	9.909022e-04
16	PPRP Čakovec	-1.17708238	1.195813e-01

17	PP Beli Manastir	-1.13316394	1.285727e-01
18	PP Donji Miholjac	-2.33793873	9.695213e-03
19	PP Đakovo	-0.33155395	3.701130e-01
20	PP Našice	-2.23694588	1.264494e-02
21	PPrP Osijek	-1.12953871	1.293353e-01
22	PP Valpovo	-2.43384203	7.469757e-03
23	PP Pakrac	-2.47907220	6.586232e-03
24	PP Požega i Pleternica	-2.74651143	3.011639e-03
25	PP Ivanec	2.35337869	9.301839e-03
26	PP Ludbreg	-0.24516771	4.031633e-01
27	PP Novi Marof	2.35332295	9.303233e-03
28	PPrP Varaždin	1.28017164	1.002424e-01
29	PP Orahovica	-2.03173262	2.109037e-02
30	PP Slatina	-3.55968990	1.856465e-04
31	PPrP Virovitica	-2.87750804	2.004148e-03
32	PP Vukovar	-1.19061067	1.169032e-01
33	PP Županja	-0.83561337	2.016862e-01
34	PP Vrbanja	-1.06321149	1.438430e-01
35	PP Ilok	-0.52060951	3.013194e-01
36	PPrP Vinkovci	-1.36046878	8.684081e-02
37	PP Dvor	0.35276429	3.621326e-01
38	PP Glina	0.96982741	1.660663e-01
39	PP Hrv. Kostajnica	0.17400188	4.309320e-01
40	PPrP Kutina	0.07665427	4.694493e-01
41	PP Novska	-2.33157705	9.861476e-03
42	PP Petrinja	1.74148619	4.079920e-02
43	PP Gvozd	1.54405315	6.128773e-02
44	PPrP Sisak i PP Sunja	1.80035976	3.590192e-02
45	PP Dugo Selo	2.91190207	1.796176e-03
46	PP Ivanić-Grad	2.12569260	1.676443e-02
47	PP Jastrebarsko	3.20595076	6.730851e-04
48	PP Samobor	4.42133954	4.904545e-06
49	PP Velika Gorica	4.20097065	1.328865e-05
50	PP Vrbovec	2.10578945	1.761132e-02
51	PP Zaprešić	4.74371535	1.049168e-06
52	PP Sv. I. Zelina	3.24303000	5.913288e-04
53	PPrP Zagreb ( I i II)	5.37069816	3.921620e-02

Statističko signifikantna područja policijskih postaja Donja Stubica, Klanjec, Krapina, Zlatar Bistrica, Pregrada, Novi Marof, Petrinja, Sisak, Dugo Selo, Ivanić Grad, Jastrebarsko, Samobor, Velika Gorica, Vrbovec, Zaprešić, Sv.I.Zelina, Zagreb, predstavljaju „*hot-spots*“.

Statističko signifikantna područja policijskih postaja Daruvar, Garešnica, Grubišno Polje, Nova Gradiška, Slavonski Brod, predstavljaju „*cold-spots*“.



**3.2.16 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati globalni Moranov indeks**

1. Globalni Moranov indeks za visinu premiju od auto odgovornosti iznosi: 0.238892532
2.  $p$  vrijednost iznosi  $1.369e-05$  i  $z$  vrijednost iznosi 4.19423
  - $p$  vrijednost je manja od razine signifikantnosti koja iznosi 0,05 zbog čega odbacujemo nul-hipotezu (područja su statistički signifikantna). Pozitivna vrijednost Moranovog indeks ukazuje na grupiranje područja viših i nižih vrijednosti.

Moran I statistic standard deviate = 4.1942, p-value = 1.369e-05		
alternative hypothesis: greater		
sample estimates:		
Moran I statistic	Expectation	Variance
0.238892532	-0.019230769	0.003787529




### 3.2.17 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te izračunati lokalni Moranov indeks

	Pol. postaje	Ii	E.Ii	Var.Ii	Z.Ii	Pr(z > 0)
1	PP Čazma	0.115061354	-0.01923077	0.06246611	0.53731418	2.955253e-01
2	PP Daruvar	0.148156659	-0.01923077	0.07903295	0.59541360	2.757835e-01
3	PP Garešnica	0.178728836	-0.01923077	0.06992119	0.74863854	2.270375e-01
4	PP Gr.Polje	0.121440875	-0.01923077	0.07903295	0.50038292	3.084027e-01
5	PPrP Bjelov.	0.130539389	-0.01923077	0.05099676	0.66321446	2.535966e-01
6	PP NOVA Grad.	0.111485739	-0.01923077	0.19292995	0.29759841	3.830048e-01
7	PPrP Sl.Brod	0.224594814	-0.01923077	0.19292995	0.55511051	2.894095e-01
8	PP Đurđevac	0.052412952	-0.01923077	0.10506655	0.22102729	4.125356e-01
9	PP Križevci	0.109749695	-0.01923077	0.03916900	0.65170749	2.572949e-01
10	PPrP Kopriv.	0.147561429	-0.01923077	0.07903295	0.59329630	2.764914e-01
11	PP D.Stub.	-0.010086729	-0.01923077	0.03916900	0.04620265	4.815744e-01
12	PP Klanjec	-0.452613552	-0.01923077	0.09042265	-1.44122917	9.252400e-01
13	PPrP Krapina	0.157648535	-0.01923077	0.07903295	0.62917714	2.646165e-01
14	PP Z.Bistri.	0.111109498	-0.01923077	0.04649095	0.60449736	2.727565e-01
15	PP Pregrada	0.048787930	-0.01923077	0.09042265	0.22619850	4.105235e-01
16	PPrP Čakov.	0.166583191	-0.01923077	0.15192703	0.47671720	3.167818e-01
17	PP B.Manas.	0.146994311	-0.01923077	0.26126815	0.32520208	3.725141e-01
18	PP D.Miholj.	0.162354988	-0.01923077	0.15192703	0.46586948	3.206545e-01
19	PP Đakovo	0.130812668	-0.01923077	0.12459175	0.42508166	3.353886e-01
20	PP Našice	0.123893470	-0.01923077	0.10506655	0.44155109	3.294070e-01
21	PPrP Osijek	0.198802254	-0.01923077	0.15192703	0.55937719	2.879522e-01
22	PP Valpovo	0.030330607	-0.01923077	0.12459175	0.14041022	4.441679e-01
23	PP Pakrac	0.100759684	-0.01923077	0.10506655	0.37018129	3.556237e-01
24	PP Požega	0.171392256	-0.01923077	0.10506655	0.58808909	2.782362e-01
25	PP Ivanec	0.050179272	-0.01923077	0.05625355	0.29264920	3.848952e-01
26	PP Ludbreg	0.008597726	-0.01923077	0.06992119	0.10524109	4.580923e-01
27	PP N.Marof	0.041699987	-0.01923077	0.05625355	0.25689853	3.986286e-01
28	PPrP Varažd.	0.196765802	-0.01923077	0.09042265	0.71830394	2.362850e-01
29	PP Orahovica	0.151625395	-0.01923077	0.12459175	0.48404531	3.141769e-01
30	PP Slatina	0.035855137	-0.01923077	0.10506655	0.16994495	4.325267e-01
31	PPrP Virovi.	0.081464832	-0.01923077	0.10506655	0.31065494	3.780315e-01
32	PP Vukovar	-0.096091072	-0.01923077	0.19292995	-0.17498558	5.694545e-01
33	PP Županja	0.011857788	-0.01923077	0.19292995	0.07077840	4.717871e-01
34	PP Vrbanja	-0.001333203	-0.01923077	0.19292995	0.04074686	4.837489e-01
35	PP Ilok	-0.482874393	-0.01923077	0.26126815	-0.90707053	8.178152e-01
36	PPrP Vikovci	-0.063800256	-0.01923077	0.15192703	-0.11434577	5.455181e-01
37	PP Dvor	4.392251728	-0.01923077	0.19292995	10.04349195	4.906861e-24
38	PP Glina	2.702162250	-0.01923077	0.12459175	7.70986239	6.297674e-15
39	PP H.Kost.	2.749536466	-0.01923077	0.15192703	7.10344342	6.084309e-13
40	PPrP Kutina	0.099648149	-0.01923077	0.06246611	0.47564464	3.171638e-01
41	PP Novska	-0.097256001	-0.01923077	0.12459175	-0.22104995	5.874732e-01
42	PP Petrinja	0.163377443	-0.01923077	0.09042265	0.60726982	2.718359e-01
43	PP Gvozd	0.614728919	-0.01923077	0.15192703	1.62646275	5.192563e-02
44	PPrP Sisak	-0.423259958	-0.01923077	0.06246611	-1.61655508	9.470128e-01
45	PP Dugo Selo	0.005408614	-0.01923077	0.04258591	0.11939795	4.524800e-01
46	PP Iv.Grad	-0.016664356	-0.01923077	0.05099676	0.01136463	4.954663e-01
47	PP Jastreb.	-0.010817506	-0.01923077	0.12459175	0.02383526	4.904920e-01
48	PP Samobor	0.050104393	-0.01923077	0.09042265	0.23057644	4.088219e-01
49	PP V.Gorica	-0.080822030	-0.01923077	0.04649095	-0.28565044	6.124271e-01
50	PP Vrbovec	-0.007795739	-0.01923077	0.03916900	0.05777848	4.769625e-01
51	PP Zaprešić	0.027784018	-0.01923077	0.07903295	0.16723624	4.335921e-01
52	PP Sv.I.Zel.	0.088698005	-0.01923077	0.03347415	0.58990555	2.776270e-01
53	PPrP Zagreb	0.043771940	-0.01923077	0.06246611	0.25207919	4.004899e-01

Izračunom lokalnog Moranovog indeksa za područje svake policijske postaje utvrdili smo grupiranja viših vrijednosti obračunate premije na statistički signifikantnim područjima

policijskih postaja Dvor, Glina, Hrvatska Kostajnica. Iz navedenog se može zaključiti da sa na područjima obračunava veća premija u odnosu na broj registriranih vozila.




### 3.2.18 Odnos iznosa obračunate premije za motorna vozila i broja registriranih vozila, te utvrđivanje koncentracije viših vrijednosti „hot spots“ i nižih vrijednosti „cold spots“

	Registarske tablice	localG	P
1	PP Čazma	-1.0014802	1.582973e-01
2	PP Daruvar	-1.2224376	1.107711e-01
3	PP Garešnica	-1.2558138	1.045917e-01
4	PP Grubišno Polje	-1.1505158	1.249658e-01
5	PPrP Bjelovar	-1.1125294	1.329553e-01
6	PP Nova Gradiška	-0.9202849	1.787119e-01
7	PPrP Slavonski Brod	-0.8625239	1.941996e-01
8	PP Đurđevac	-0.9400197	1.736037e-01
9	PP Križevci	-1.3918266	8.198745e-02
10	PPrP Koprivnica	-1.0255217	1.525585e-01
11	PP Donja Stubica	-0.8835952	1.884574e-01
12	PP Klanjec	-1.0060406	1.571980e-01
13	PPrP Krapina	-1.3046234	9.601056e-02
14	PP Zlatar Bistrica	-0.8270850	2.040944e-01
15	PP Pregrada	-1.1209163	1.311617e-01
16	PPrP Čakovec	-0.6436480	2.599019e-01
17	PP Beli Manastir	-0.8030752	2.109656e-01
18	PP Donji Miholjac	-0.5900495	2.775787e-01
19	PP Đakovo	-0.8992296	1.842652e-01
20	PP Našice	-1.0909555	1.376462e-01
21	PPrP Osijek	-0.7726062	2.198777e-01
22	PP Valpovo	-1.1640359	1.222047e-01
23	PP Pakrac	-1.1689401	1.212139e-01
24	PP Požega i Pleternica	-0.9310483	1.759143e-01
25	PP Ivanec	-0.6826250	2.474219e-01
26	PP Ludbreg	-1.2574947	1.042873e-01
27	PP Novi Marof	-1.0988957	1.359068e-01
28	PPrP Varaždin	-1.0253624	1.525961e-01

29	PP Orahovica	-0.9687478	1.663355e-01
30	PP Slatina	-1.1758340	1.198306e-01
31	PPrP Virovitica	-0.9067111	1.822798e-01
32	PP Vukovar	0.5250184	2.997852e-01
33	PP Županja	-0.6259828	2.656631e-01
34	PP Vrbanja	0.4298634	3.336475e-01
35	PP Ilok	-0.4469587	3.274524e-01
36	PPrP Vinkovci	0.2911683	3.854613e-01
37	PP Dvor	2.7994579	2.559424e-03
38	PP Glina	4.3687843	6.247005e-06
39	PP Hrv. Kostajnica	2.6550779	3.964504e-03
40	PPrP Kutina	-1.0706932	1.421537e-01
41	PP Novska	0.3810697	3.515758e-01
42	PP Petrinja	4.2950693	8.731940e-06
43	PP Gvozd	0.6413539	2.606464e-01
44	PPrP Sisak i PP Sunja	3.4865495	2.446474e-04
45	PP Dugo Selo	-1.5186366	6.442700e-02
46	PP Ivanić-Grad	-1.4642202	7.156690e-02
47	PP Jastrebarsko	1.4174681	7.817306e-02
48	PP Samobor	-0.3973978	3.455371e-01
49	PP Velika Gorica	0.7763958	2.187577e-01
50	PP Vrbovec	-1.5370395	6.214182e-02
51	PP Zaprešić	-0.2907909	3.856056e-01
52	PP Sv. I. Zelina	-1.0122777	1.557027e-01
53	PPrP Zagreb ( I i II)	-0.2717681	3.929002e-01

Statističko signifikantna područja policijskih postaja Dvor, Glina, Hrvatska Kostajnica, Petrinja, Sisak i Sunja, predstavljaju „*hot-spots*“. Može se zaključiti da se na područjima navedenih postaja obračunava veća premija u odnosu na broj registriranih vozila.



## 4. Utvrđivanje povezanosti varijabli navedenih u tablicama 1 i 2 uz pomoć Pearsonovog koeficijenta korelacije

Osim međusobnog utjecaja varijabli s obzirom na vrijednosti koje se javljaju na određenim geografskim jedinicama, u R programu izračunat je Pearsonov koeficijent korelacije  $r$  u odnosu na slijedeće varijable:

$X$  = broj prometnih nesreća na 10.000 vozila,  $Y$  = broj prometnih nesreća na 10.000 stanovnika

$X$  = broj prometnih nesreća na 10.000 stanovnika,  $Y$  = premija za vozila


$X$  = broj prometnih nesreća na 10.000 vozila,  $Y$  = premija za vozila

Da bi utvrdili linearnu povezanost varijabli potrebno je obaviti testiranje nul-hipoteze o statističkoj značajnosti koeficijenta korelacije  $r$ . U slučaju da se zadovolji uvjet  $t > t_{\alpha}$ , uz razinu značajnosti  $\alpha = 0.05$ , tada odbacujemo nul-hipotezu u korist alternative (koeficijent korelacije je statistički značajno pozitivan). Vrijednost  $t$  se dobiva formulom:

$$t = r \sqrt{\frac{n-2}{1-r^2}} \quad (24)$$


PODACI IZ TABLICE 1. (za područja regstarskih oznaka)

1.




$$r = 0,6405696$$

2.



$$r = 0,4764303$$

3.



$$r = 0,2617603$$

Za dobivene koeficijent korelacije  $r$  (slika 1., 2., 3.) izračunate su vrijednosti  $t$ , uz pomoć formule (24). Iz tablice  $t$  distribucije je očitana kritična vrijednost  $t_{0.05} = 1.725$ . Dobivene  $t$  vrijednosti iznose 3.370, 2.423 i 1.213.


U slučaju koeficijenta korelacije  $r$  (slika 1. i 2.) odbacujemo nul-hipotezi u korist alternative o postojanju statističke značajnosti koeficijenta korelacije iz čega zaključujemo da postoji linearna povezanost varijabli:

- broja prometnih nesreća na 10.000 vozila i broja prometnih nesreća na 10.000 stanovnika
- broja prometnih nesreća na 10.000 stanovnika i premije za vozila

U slučaju koeficijenta korelacije  $r$  (slika 3.) ne odbacuje se nul-hipoteza iz čega zaključujemo da na postoji linearna povezanost između varijabli  $X =$  broj prometnih nezgoda na 10.000 vozila,  $Y =$  premija za vozila.


PODACI IZ TABLICE 2. (za područja policijskih postaja)

1.




$$r = 0,7373$$

2.



$$r = -0,0387519$$

3.



$$r = -0,073100355$$

Za dobivene koeficijent korelacije  $r$  (slika 1., 2., 3.) izračunate vrijednosti  $t$ , iznose 7.794, -0.2772 i -0.52. Iz tablice  $t$  distribucije je očitana kritična vrijednost  $t_{0.05} = 1.684$ .

U slučaju koeficijenta korelacije  $r$  (slika 1.) odbacujemo nul-hipotezi u korist alternative o postojanju statističke značajnosti koeficijenta korelacije, iz čega zaključujemo da postoji linearna povezanost broja prometnih nesreća na 10.000 vozila i broja prometnih nesreća na 10.000 stanovnika

Izračunani koeficijenti korelacije  $r$  (slika 2. i 3.) imaju negativni predznak iz kojeg razloga, u slučaju da se zadovolji uvjet  $t < t_{\alpha}$ , odbacujemo nul-hipotezu u korist alternative. Očitana kritična vrijednost je  $t_{0,05} = -1.684$ .

Obzirom da su izračunane  $t$  vrijednosti (slika 2. i 3.) veće od kritične vrijednosti, ne odbacuje se nul-hipoteza o nenegativnosti koeficijenta korelacije iz čega zaključujemo da ne postoji linearna povezanost:

- broja prometnih nesreća na 10.000 stanovnika i premije za vozila
- broja prometnih nesreća na 10.000 vozila i premija za vozila.



## 5. Zaključak

Poglavlje 3 prikazuje praktičnu primjenu indikatora prostorne asocijacije uz pomoć kojih smo pokušali utvrditi prostornu autokorelaciju između statističkih vrijednosti više pokazatelja, na registarskim područjima i područjima policijskih postaja Sjeverne Hrvatske.

Izračunom Moranovog indeksa, globalnog indikatora prostorne asocijacije, lokalnog Moranovog indeksa i Getis-Ord  $G_i$  statistike, lokalnih indikatora prostorne asocijacije, dobili smo različite rezultate u pogledu prostorne autokorelacije između vrijednosti pokazatelja čije su statističke vrijednosti prikazane u tablici 1. i 2.

Gledajući statističke vrijednosti pokazatelja, navedene u tablici 1, koje se odnose na registarska područja: broj prometnih nesreća, broj prometnih nesreća na 10.000 stanovnika, broj registriranih vozila, broj prometnih nesreća na 10.000 registriranih vozila, utvrđeno je ne postojanje prostorne autokorelacije. Izuzetak su registarska područja Varaždina i Čakovca, koja s obzirom na broj prometnih nezgoda na 10.000 vozila predstavljaju „*cold spots*“. Postojanje prostorne autokorelacije utvrđeno je, s obzirom na vrijednosti obračunate premije za police od auto odgovornosti, na registarskim područjima Zagreba i Krapine, na kojim se registarskim područjima obračunava najviša premija na području Sjeverne Hrvatske. Područja Zagreba i Krapine predstavljaju i „*hot-spots*“.

Koristeći statističke vrijednosti na područjima policijskih postaja, navedene u tablici 2, za slijedeće pokazatelje: broj prometnih nesreća, broj prometnih nesreća na 10.000 stanovnika, broj registriranih vozila, broj prometnih nesreća na 10.000 registriranih vozila, utvrđeno je kao i u prethodnom slučaju, ne postojanje prostorne autokorelacije, s obzirom na rezultate dobivene izračunom Moranovog indeksa i lokalnog Moranovog indeksa. Međutim izračunom Getis-Ord statistike, za navedene pokazatelje utvrđena je pojava grupiranja viših vrijednosti „*hot-spots*“ ili nižih vrijednosti „*cold-spots*“, pa tako imamo npr. grupiranja područja policijskih postaja Klanjec, Krapina, Pregrada, s obzirom na veći broj prometnih nezgoda, što predstavlja „*hot-spots*“. Također, s obzirom na broj prometnih nezgoda na 10.000 stanovnika, područja policijskih postaja Daruvar i Grubišno Polje predstavljaju „*hot-spots*“, te područja Gline i Petrinja „*cold-spots*“.

Postojanje prostorne autokorelacije utvrđeno je između statističkih vrijednosti koje se odnose na obračunatu premiju za police od autoodgovornosti, na područjima policijskih postaja koje se nalaze u sjeverozapadnoj Hrvatskoj, oko Grada Zagreba. Ta su područja približno grupirana kao „*hot spots*“, s obzirom na veću obračunatu premiju. Također, utvrđeno je postojanje prostorne autokorelacije s obzirom na manju visinu obračunate premije, na područjima policijskih postaja koja se nalaze u Zapadnoj Slavoniji. Ta područja, obzirom na manju premiju, predstavljaju „*cold spot*“.

Kod većine pokazatelja nije utvrđena prostorna autokorelacija između njihovih vrijednosti izmjenjenih na registarskim područjima Sjeverne Hrvatske, međutim ne možemo prostornu autokorelaciju zanemariti kao jedan od načina utvrđivanja visine premije za police osiguranja od auto odgovornosti. Ako uzmemo u obzir vrijednosti utvrđene za područja policijskih postaja, koja su zemljopisno manja od registarskih područja, utvrđeno je postojanje autokorelacije, s obzirom na više ili niže vrijednosti utvrđene premije, broj prometnih nezgoda itd. uzimajući u obzir Getis Ord  $G_i$  statistiku.

U poglavlju 4 smo uz pomoć Personovog koeficijenta utvrdili stupanj korelacije između pokazatelja navedenih u tablicama 1 i 2. Gledajući tablicu 1 utvrđena je visoka pozitivna korelacija između broja prometnih nezgoda na 10.000 stanovnika i broja prometnih nezgoda na 10.000 vozila, što je isti slučaj i kod tablice 2, iz čega se može zaključiti da bi se navedeni pokazatelji osim kod utvrđivanja prostorne autokorelacije, trebali uzeti u obzira u smislu mogućeg utjecaja.

## 6. Literatura:

[1] Anselin, I, Local Indicators of Spatial Association –LISA , Geographical Analysis, Vol.27, 1995.

[2] Brajković, D., Otkrivanje prostorne autokorelacije pomoću lokalnih indikatora, Ekonomski vjesnik, Review of Contemporary Entrepreneurship, Bissines, and Economic Issues, Vol.XXII, 2009.

[3] Getis, A., Ord. J.K., The Analysis of Spatial Association by Use of Distance Statistics, Geographical Analysis, 1992.

[4] Getis A.,Ord, J.K, Local Spatial Autocorrelation Statistics: Distributional Issues and an Application, *Geographical Analysis* 27,1995.

[5] Goodchild, M. F, *Spatial Autocorrelation*. Catmog 47, Geo Books. 1986.

[6] Grieve, J. (2011). "A regional analysis of contraction rate in written Standard American English", *International Journal of Corpus Linguistics*, 2011.

[7] Grupa autora: Pacake „spdep“, „Spatial Dependence: Weighting Schemes, Statistics and Models“, version 0.6-8, date 21.09.2016. godine, <https://cran.r-project.org/web/packages/spdep/spdep.pdf> pristupljeno dana **01.09.2016.** u 16,00 sati

[8] Helbich, M, Leitner, M. and Kpusta, D. N, Geospatial examination of lithium in drinking water and suicide mortality, *International Jurnal of Health Geographics*, 2012

[9] Podaci MUP-a RH o ukupnom broju registriranih osobnih i teretnih vozila za 2014. i 2015. godinu, PU Koprivničko-križevačka, 2016.

[10] Osayomi,T. and Ayooluwa Areola, A., Geospatial Analysis of Road Traffic Accidents, Injuries and Deaths in Nigeria, *Indonesian Journal of Geography*, © 2015 Faculty of Geography UGM and The Indonesian Geographers Association, JG Vol. 47, No.1, 2015

[11] Ukupna premija obračunata na Internet stranici „Izvor osiguranja d.d. Zagreb“ Zagreb, [https://incubis.izvorosiguranje.hr/calc\\_ao.aspx](https://incubis.izvorosiguranje.hr/calc_ao.aspx), pristupljena dana 02.07.2016., u 16,00 sati

[12] Rdogan, S., Explorative spatial analysis of traffic accident statistic and road mortality among the provinces of Turkey, Journal of safety research, 2009.

[13] Chen, Y., New Approaches for Calculating Moran's Index of Spatial Autocorrelation, 2013.

## 7. Sažetak

U ovome radu, pojam prostorne autokorelacije obrađen je kroz više poglavlja.

U 2. poglavlju teorijski su obrađeni: Moranov indeks (globalni indikator prostorne asocijacije), lokalni Moranov indeks i Getis-Ord  $G_i$  statistika (lokalni indikatori prostorne asocijacije). Pomoću navedenih indikatora možemo utvrditi postojanje prostorne autokorelacije između vrijednosti varijable koje se javljaju na određenom geografskom području.

Praktična primjena globalnog Moranovog indeksa, lokalnog Moranovog indeksa i Getis-Ord  $G$  statistike pokazana je u 3. poglavlju. Cilj je bio utvrditi postojanje prostorne autokorelacije između vrijednosti varijabli: ukupan broj prometnih nezgoda, broj prometnih nezgoda na 10.000 stanovnika, ukupan broj registriranih vozila, broj prometnih nezgoda na 10.000 vozila, te premije za osobna i teretna vozila (2016. godine) na područjima registarskih oznaka i policijskih postaja. Izračuni indikatora prostorne autokorelacije i grafički prikaz korelacije vrijednosti varijabli, izmjerene na geografskim jedinicama, obavljani su programskim jezikom R.

U 4. poglavlju cilj je bio utvrditi postojanje međusobnog utjecaja korelacija varijabli s obzirom na vrijednosti koje se pojavljuju na geografski jedinicama registarskih oznaka i policijskih postaja. Korelaciju između varijabli utvrđena je uz pomoć Pearsonovog koeficijenta korelacije koji smo izračunali u R programu. Varijable koje smo koristili za utvrđivanje međusobne korelacije su: broj prometnih nezgoda na 10.000 vozila i broj prometnih nezgoda na 10.000 stanovnika, broj prometnih nezgoda na 10.000 stanovnika i premija za vozila, broj prometnih nezgoda na 10.000 vozila i premija za vozila.

## 8. Abstract

In this study, the term of spatial autocorrelation is elaborated through several chapters.

In Chapter 2, the Moran index (global spatial association indicator), the local Moran index and the Getis-Ord  $G$  statistics (local spatial association indicators) have been theoretically analyzed. Using those indicators we can determine the existence of spatial autocorrelation between the value of variables which occur in a particular geographic area.

The practical application of the global Moran index, the local Moran index and the Getis-Ord  $G_i$  statistics is shown in chapter 3. The goal was to determine the existence of spatial autocorrelation between the value of these variables:

total number of traffic accidents, the number of traffic accidents per 10,000 inhabitants, total number of registered vehicles, the number of accidents at 10,000 vehicles, premiums for personal and commercial vehicles in 2016.

in the areas of registration labels and police stations The calculations of the spatial autocorrelation indicator and the graphical representation of the correlation of the variables values, measured on the geographic units, were performed in the R programming language.

In the 4th chapter, the goal was to determine the correlation between of the variables in relation to the values that appear on the geographical units of the registration labels and the police stations.. The correlation between the variables was determined by the Pearson's correlation coefficient which we calculated in the R program The variables we used to determine correlation were: the number of traffic accidents on 10,000 vehicles and the number of traffic accidents per 10,000 inhabitants, the number of traffic accidents per 10,000 inhabitants and vehicle premiums, the number of accidents at 10,000 vehicles and vehicle premiums.

## 9. Životopis

Zoran Gajari rođen je 23.09.1970. godine. Osnovnu i srednju školu završio je u Vukovaru. U Zagrebu 1996. godine završava Ekonomski fakultet, smjer Poslove financije. Zaposlen je u PU Koprivničko-križevačkoj, Služba kriminalističke policije, na radnom mjestu Policijskog službenika za obradu gospodarskog kriminaliteta, na kojem radnom mjestu je proveo 21 godinu radnoga staža. Tijekom 1998. godine položio je državni ispit, kao i ispit za zvanje Samostalni policijski inspektor, da bi 2011. godine položio ispit za zvanje Glavni policijski inspektor. Godine 2000. završio je Tečaj za stručno osposobljavanje kriminalističkih službenika na poslovima suzbijanja gospodarskog kriminaliteta. Oženjen je i otac dvoje djece.