

STATISTIČKA OBRADA PODATAKA O VREMENSKIM NEPRILIKAMA U SVRHU ODREĐIVANJA MJESEČNOG INTERVALA S MATEMATIČKI OČEKIVANIM DANIMA ZASTOJA PRI RADU GRADILIŠTA NA PODRUČJU GRADA RIJEKE

STATISTICAL DATA ANALYSIS OF WEATHER CONDITIONS AIMING AT DETERMINING THE MATHEMATICAL EXPECTATION OF CONSTRUCTION SITE DELAYS IN RIJEKA WITHIN A MONTHLY PERIOD

Martina Šopić*, Diana Car-Pušić*

Sažetak

Meteorološki i klimatski uvjeti mogu uvelike utjecati na kontinuirani i zadovoljavajući tijek izvođenja radova na gradilištu. Posebno je važno, ali nedovoljno primijenjeno u praksi, prilikom izrade vremenskog plana i definiranja roka za građenje uzeti u obzir i moguće zastoje pri radu gradilišta zbog nepovoljnih vremenskih uvjeta. Meteorološki i klimatski uvjeti imaju različit utjecaj ovisno o lokaciji gradilišta. Iz tog razloga, kako bi se statistički obradio utjecaj vremenskih neprilika na području grada Rijeke, s pripadajućom umjereno toplom, vlažnom klimom i vrućim ljetima (Cfa - Köppen-ova klasifikacija klime), od Državnog hidrometeorološkog zavoda (DHMZ) zatraženi su meteorološki podaci o vremenskim neprilikama za vremensko razdoblje od 25 godina, izmjerenih i zabilježenih u glavnoj meteorološkoj postaji u gradu Rijeci. Vremenske neprilike za koje su zatraženi podaci, a koje su karakteristične za klimatsko područje grada Rijeke, su Oborine (≥ 10 mm), Olujni vjetar, Hladni dani ($T_{\min} < 0$ °C) i Vrući dani ($T_{\max} \geq 30$ °C). Zatraženi meteorološki podaci su u obliku ukupnog broja dana u mjesecu sa zabilježenim djelovanjem pojedine vremenske neprilike. Ciljevi ovog rada su, primjenom odgovarajućih statističkih testova,

* Sveučilište u Rijeci, Građevinski fakultet, Radmile Matejčić 3, 51000 Rijeka
E-mail: fmartina.sopic.diana.car.pusic@gradri.uniri.hr

testiranje različitosti na razini značajnosti od 5 %, među skupinama vremenskih neprilika (Kruskal-Wallis test, Mann-Whitney test) te, zatim, određivanje 95 % pouzdanog intervala s matematički očekivanim danima zastoja pri radu gradilišta za svaki mjesec pojedinačno (intervalna procjena očekivanja u skupini s normalnom distribucijom podataka). Mjesečni intervali dobiveni statističkom obradom s matematički očekivanim danima zastoja, zbog vremenskih neprilika predstavljaju vrijedan ulazni parametar u svrhu preciznije izrade vremenskog plana i definiranja roka za građenje na području grada Rijeke.

Ključne riječi: vremenske neprilike, meteorološki podaci, statistička obrada, zastoji, gradilište, vremenski plan, Rijeka

Abstract

Meteorological and climate conditions can significantly affect the continuous and satisfactory progress of work on a construction site. When it comes to creating schedules and defining deadlines at a construction site it is very important to consider possible time delays during work execution as a result of adverse weather conditions. Still, this practice isn't widely applied. Weather and climate conditions may have different effects depending on the location of the construction site. Hence, to be able to statistically analyze the effect of weather conditions in Rijeka area, with its moderately warm and humid climate with hot summers (Cfa - Köppen climate classification), data on weather conditions that were measured and recorded in the central meteorological station in Rijeka during the period of last 25 years were requested from the Croatian Meteorological and Hydrological Service (DHMZ). The weather conditions the data was requested on are specific to the microclimate of the Rijeka area. They are as follows: precipitation (≥ 10 mm), storm winds, cold days ($T_{min} < 0$ °C) and hot days ($T_{max} \geq 30$ °C). Requested meteorological data are in the form of the total number of days in a month with specific weather conditions recorded. The aim of this paper is to apply appropriate statistical tests in order to examine variations on the scale of significance of 5 % between distinct weather conditions (Kruskal-Wallis test, Mann-Whitney test), and to determine the 95% reliable interval of the mathematical expectation of work delays on a construction site for each month (an interval expectations assessment within a group containing normal data distribution). Monthly intervals obtained via statistical analysis that include mathematical expectation of execution delays due to poor weather condition represent a valuable input parameter for the purpose of creating a more precise schedule and defining construction deadlines in the Rijeka area.

Keywords: weather conditions, meteorological data, statistical analysis, delays, deadlines, schedules, Rijeka

1. Uvod

Meteorološki i klimatski uvjeti mogu uvelike utjecati na kontinuirani i zadovoljavajući tijek izvođenja radova na gradilištu. Vremenske neprilike tako utječu na smanjenje produktivnosti na gradilištu, kašnjenje projekta, prekoračenje troškova i pojavu ugovornih (pri)tužbi [1]. Zanemarivanje klimatskog utjecaja i analize utjecaja klime na fond radnog vremena jedan je od ključnih čimbenika za održavanje vremenskog roka i proračuna [2]. Kvantificiranje vremenskog utjecaja na izvođenje radova na gradilištu predstavlja vrijedan ulazni parametar pri izradi vremenskog plana za građenje, procjeni troškova i davanju ponude za izvođenje radova [3]. Stoga je posebno važno, ali nedovoljno primijenjeno u praksi, prilikom izrade vremenskog plana i definiranja roka za građenje uzeti u obzir i procjenu zastoja pri radu gradilišta zbog nepovoljnih vremenskih uvjeta na temelju matematičke i statističke obrade dostupnih podataka.

Meteorološki i klimatski uvjeti imaju različit utjecaj ovisno o lokaciji gradilišta. Iz tog razloga, kako bi se statistički obradio utjecaj vremenskih neprilika na području grada Rijeke s pripadajućom umjereno toplom, vlažnom klimom i vrućim ljetima (Cfa - Köppen-ova klasifikacija klime), od Državnog hidrometeorološkog zavoda (DHMZ) zatraženi su meteorološki podaci o vremenskim neprilikama za vremensko razdoblje od 25 godina, izmjereni i zabilježeni u glavnoj meteorološkoj postaji u gradu Rijeci. Vremenske neprilike za koje su zatraženi podaci, karakteristične za klimatsko područje grada Rijeke, su Oborine (≥ 10 mm), Olujni vjetar, Hladni dani ($T_{\min} < 0$ °C) i Vrući dani ($T_{\max} \geq 30$ °C). Zatraženi meteorološki podaci su u obliku ukupnog broja dana u mjesecu sa zabilježenim djelovanjem pojedine vremenske neprilike.

Ciljevi ovog rada su, primjenom odgovarajućih statističkih testova, testiranje različitosti na razini značajnosti od 5 %, među skupinama vremenskih neprilika (Kruskal-Wallis test, Mann-Whitney test) te, zatim, određivanje 95 % pouzdanog intervala s matematički očekivanim danima zastoja pri radu gradilišta za svaki mjesec pojedinačno (intervalna procjena očekivanja u skupini s normalnom distribucijom podataka). Mjesečni intervali dobiveni statističkom obradom s matematički očekivanim danima zastoja, zbog vremenskih neprilika predstavljaju vrijedne ulazne parametre u svrhu preciznije izrade vremenskog plana i definiranja roka za građenje na području grada Rijeke.

2. Statistički testovi

2.1. Kruskal-Wallis i Mann-Whitney

Kruskal-Wallis (H test) je neparametrijski test koji omogućuje međusobnu usporedbu tri ili više nezavisnih skupina podataka s podacima koji po svojoj prirodi imaju ordinalnu skalu. Neparametrijske testove koristimo u slučajevima kada imamo podatke koji se ne distribuiraju normalno, kao i u nekim drugim specifičnim slučajevima kada nisu zadovoljeni svi (pred)uvjeti za korištenje odgovarajućeg parametrijskog testa. Parametrijski testovi imaju veću snagu od neparametrijskih testova. Međutim, značajno gube na snazi ako su pretpostavke o opravdanosti korištenja parametrijskih testova netočne. Veća snaga testa predstavlja vjerodostojniju obradu podataka i manju mogućnost statističkih pogrešaka.

Ordinalna skala izražava mogućnost određenog redoslijeda ili poretka među podacima. Pri obradi podataka na ordinalnoj skali može se koristiti rangiranje podataka. Rangiranje podataka je postupak pri kojem podatke svih skupina poredamo po veličini, od najmanje vrijednosti prema najvećoj. Pritom, svakom podatku dodijelimo odgovarajuću vrijednost ranga počevši od vrijednosti 1 (rang za podatak koji ima najmanju vrijednost, prethodnog poretka podataka po veličini), zatim rang vrijednosti 2 za sljedeći podatak, sve do ranga vrijednosti n (za podatak s najvećom vrijednosti). Ako imamo više podataka iste vrijednosti, dodijelimo im aritmetičku sredinu rangova koje bi dobili da imamo podatke različitih vrijednosti.

Testna statistika (H) Kruskal-Wallis-ovog testa je (1), pri čemu je k broj nezavisnih skupina s brojem podataka n_i ($i = 1, 2, \dots, k$), R_i je suma rangova i -te skupine ($i = 1, 2, \dots, k$), a n je ukupan broj podataka svih skupina ($n = n_1 + n_2 + \dots + n_k$) [4].

$$H = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(n+1) \quad (1)$$

Nulta hipoteza H_0 je pretpostavka istinitosti suda da sve skupine imaju distribuciju istog oblika. Testna statistika (H) ima aproksimativno distribuciju (2) s $(k - 1)$ stupnjeva slobode (df) te pretpostavlja da su skupine nezavisne, da imaju distribuciju istog oblika te da svaka skupina ima minimalno pet podataka, $n_i \geq 5$ [4].

$$H \sim \chi^2 \quad (2)$$

Za razinu značajnosti α , kritično područje testa je oblika (3), gdje je χ_α^2 kvantil χ^2 distribucije s $(k - 1)$ stupnjeva slobode (df) ovisno o razini značajnosti α [4, 5].

$$[\chi_\alpha^2 \text{ s } (k - 1) \text{ stupnjeva slobode (df)}, \infty) \quad (3)$$

Nultu hipotezu odbacujemo ako je (4), gdje je χ_{α}^2 kvantil χ^2 distribucije s $(k - 1)$ stupnjeva slobode (df) ovisno o razini značajnosti α [4, 5].

$$H > \chi_{\alpha}^2 \quad (4)$$

Vrijednost testne statistike (H) možemo iščitati provođenjem Kruskal-Wallisov-og testa u Real Statistics-u (*H-ties*), odnosno, ovisno o zadanoj razini značajnosti α , nultu hipotezu odbacujemo ako je (5), pri čemu je vrijednost p najveća razina značajnosti za koju ne odbacujemo nultu hipotezu. Real Statistics je dodatak u Excel-u s naprednim mogućnostima obrade podataka u svrhu jednostavnije primjene širokog spektra statističkih analiza.

$$p < \alpha \quad (5)$$

Neparametrijski Kruskal-Wallis-ov test, dakle, koristimo u slučajevima kada imamo tri ili više nezavisnih skupina podataka s podacima koji nemaju normalnu distribuciju, kao i u slučajevima kada su varijance među skupinama jako različite ili su prisutne ekstremno odstupajuće vrijednosti (outlieri) [6]. Primjenom Kruskal Wallis-ovog testa možemo zaključiti postojanje razlika među testiranim skupinama podataka, ali ne možemo znati koje se točno skupine razlikuju. U tu svrhu, potrebno je provesti *post hoc* analizu koristeći Mann-Whitney-jev test, međusobno uspoređujući svake dvije skupine. Pritom, važno je smanjiti razinu značajnosti da bi smanjili mogućnost pogreške prve vrste. Pogreška prve vrste je odbacivanje nulte hipoteze, iako je istinita. Moguće korekcije su [6]: Bonferroni-jeva (6) i Dunn-Šidákova (7), gdje je m broj hipoteza koje testiramo.

$$\alpha' = \frac{\alpha}{m} \quad (6)$$

$$\alpha' = 1 - (1 - \alpha)^{\frac{1}{m}} \quad (7)$$

Mann-Whitney-jev (U test) je neparametrijski test za međusobnu usporedbu dviju nezavisnih skupina podataka s podacima koji po svojoj prirodi imaju ordinalnu skalu.

Testna statistika (U) Mann-Whitney-jevog testa je (8), pri čemu je R_1 suma rangova prve skupine, R_2 suma rangova druge skupine, n_1 ukupan broj podataka prve skupine, a n_2 ukupan broj podataka druge skupine [4].

$$U = \min\{U_1, U_2\} \quad (8)$$

$$U_1 = n_1 n_2 + \frac{n_1(n_1+1)}{2} - R_1$$

$$U_2 = n_1 n_2 + \frac{n_2(n_2+1)}{2} - R_2$$

Nulta hipoteza H_0 je pretpostavka istinitosti suda da dvije skupine imaju distribuciju istog oblika. Testiramo postoji li statistički značajna razlika između medijana dviju ispitivanih skupina. Nultu hipotezu H_0 odbacujemo ako je (9), gdje je U_{crit} kritična vrijednost na razini značajnosti α . Kritičnu vrijednost (U_{crit}) možemo iščitati provedbom Mann-Whitney testa u Real Statistics-u, odnosno nultu hipotezu možemo odbaciti ako je vrijednost p manja od razine značajnosti α (5). Za velike uzorke ($n > 30$, ali u praksi se češće uzima $n > 40$), testna statistika (U) ima normalnu distribuciju pa kritičnu vrijednost (U_{crit}) možemo tražiti među kvantilima normalne distribucije [6, 7]

$$U < U_{crit} \quad (9)$$

Ako primjenom Kruskal-Wallis-ovog testa zaključimo da nema značajnih razlika među skupinama, nije potrebno provoditi Mann-Whitney-jev test.

2.1.1. Primjena Kruskal-Wallis i Mann-Whitney testova

Karakteristika mjeseca od listopada do travnja za vremensko razdoblje od 25 godina na području grada Rijeke ogleda se u tome da za vremensko razdoblje od 25 godina (od 1992. do 2016. g.) nije zabilježen niti jedan vrući dan ($T_{max} \geq 30 \text{ }^\circ\text{C}$), dok se karakteristika mjeseca od svibnja do rujna ogleda u tome da za isto vremensko razdoblje nije zabilježen niti jedan hladni dan ($T_{min} < 0 \text{ }^\circ\text{C}$) (prema podacima iz DHMZ-a). Sukladno navedenom, svaki pojedini mjesec ima tri karakteristične skupine vremenskih neprilika. Tako je u mjesecima od listopada do travnja zabilježeno djelovanje Oborina ($\geq 10 \text{ mm}$), Olujnog vjetra i Hladnih dana ($T_{min} < 0 \text{ }^\circ\text{C}$), dok je za mjesece od svibnja do rujna zabilježeno djelovanje Oborina ($\geq 10 \text{ mm}$), Olujnog vjetra i Vrućih dana ($T_{max} \geq 30 \text{ }^\circ\text{C}$). Vremenski uvjeti ne uključuju postojanje jasnih međusobnih korelacija prilikom njihovih pojava [1]. Time vremenske neprilike predstavljaju nezavisne skupine jer svaka pojedina vremenska neprilika nije nužno i uvjet pojave neke druge vremenske neprilike.

U Tablici 1. prikazan je pregled broja dana sa zabilježenim djelovanjem pojedine vremenske neprilike za mjesec siječanj za vremensko razdoblje od 25 godina (od 1992. do 2016. g.) na području grada Rijeke.

Tablica 1. Pregled broja dana sa zabilježenim djelovanjem vremenskih neprilika za mjesec siječanj

Rijeka	Pregled broja dana			
Siječanj	Oborine ≥ 10 mm	Olujni vjetar	Hladni dani $T_{\min} < 0 \text{ }^{\circ}\text{C}$	Vrući dani $T_{\max} \geq 30 \text{ }^{\circ}\text{C}$
1992.	1	1	6	0
1993.	0	3	8	0
1994.	4	1	1	0
1995.	6	3	9	0
1996.	5	1	6	0
1997.	8	1	0	0
1998.	2	4	5	0
1999.	4	2	2	0
2000.	0	1	9	0
2001.	7	5	4	0
2002.	1	1	8	0
2003.	4	7	8	0
2004.	5	3	10	0
2005.	1	7	7	0
2006.	3	3	10	0
2007.	5	1	1	0
2008.	6	0	1	0
2009.	7	1	9	0
2010.	8	0	8	0
2011.	2	4	5	0
2012.	2	0	8	0
2013.	6	3	2	0
2014.	8	2	1	0
2015.	4	1	1	0
2016.	6	1	6	0
UKUPNO	105	56	135	0

Shapiro Wilk test je test koji provjerava slijede li podaci normalnu distribuciju. U dodatku Excela, Real Statistics-u, ovisno o definiranoj razini značajnosti α , informacija o normalnoj distribuciji podataka je u obliku potvrde ili negacije „normalnosti“ podataka (normal: yes/no). Testiramo distribucije podataka pojedinih nezavisnih skupina vremenskih neprilika, primjenom Shapiro-Wilk testa u Real Statistics-u na razini značajnosti od 5 % ($\alpha = 0,05$), a za mjesec siječanj. Razina značajnosti od 5 % znači da za 5 % slučajeva imamo pogrešku prve vrste, odnosno da za 5 % slučajeva

odbacujemo nultu hipotezu, iako je istinita. Provođenjem Shapiro-Wilk testa za svaku pojedinu skupinu dobivamo rezultate da nije zadovoljen uvjet normalne distribucije podataka svih skupina vremenskih neprilika (Tablice 2.-4.). S obzirom na ukupan broj podataka u svakoj skupini i rezultatima da sve skupine nemaju normalnu distribuciju podataka, možemo zaključiti da je prikladno koristiti neparametrijski Kruskal-Wallis-ov test kako bi testirali postoje li statistički značajne razlike među skupinama vremenskih neprilika.

Tablica 2. Primjena Shapiro-Wilk testa u Real Statistics-u za mjesec siječanj za Oborine (≥ 10 mm)

Shapiro-Wilk Test

<i>Oborine ≥ 10 mm</i>	
W-stat	0,939668981
p-value	0,145446539
alpha	0,05
normal	yes

Tablica 3. Primjena Shapiro-Wilk testa u Real Statistics-u za mjesec siječanj za Olujni vjetar

Shapiro-Wilk Test

<i>Olujni vjetar</i>	
W-stat	0,847414836
p-value	0,001573667
alpha	0,05
normal	no

Tablica 4. Primjena Shapiro-Wilk testa u Real Statistics-u za mjesec siječanj za Hladne dane ($T_{min} < 0$ °C)

Shapiro-Wilk Test

<i>Hladni dani $T_{min} < 0$ °C</i>	
W-stat	0,890471223
p-value	0,011446066
alpha	0,05
normal	no

Prije primjene Kruskal-Wallis-ovog testa postavljamo nultu hipotezu da sve skupine vremenskih neprilika imaju distribuciju istog oblika (10). Alternativna hipoteza je da sve skupine vremenskih neprilika nemaju

distribuciju istog oblika (11), odnosno da postoji statistički značajna razlika među skupinama. Primjenom Kruskal-Wallis-ovog testa u Real Statistics-u, na razini značajnosti od 5 % ($\alpha = 0,05$) i postavljenim hipotezama (10 i 11), dobivamo rezultate da treba odbaciti nultu hipotezu, odnosno da postoji značajna razlika među skupinama vremenskih neprilika (podaci iz Tablice 5.: $p = 0,0011946 < 0,05$ ili *sig: yes*).

$$H_0: \mu_1 = \mu_2 = \mu_3 \tag{10}$$

$$H_1: \mu_1 \neq \mu_2 \quad \text{ili} \quad \mu_1 \neq \mu_3 \quad \text{ili} \quad \mu_2 \neq \mu_3 \tag{11}$$

Tablica 5. Primjena Kruskal-Wallis-ovog testa u Real Statistics-u za testiranje različitosti među skupinama vremenskih neprilika

Kruskal-Wallis Test

	Oborine ≥ 10 mm	Olujni vjetar	Hladni dani $T_{min} < 0$ °C	
median	4	1	6	
rank sum	1014	643,5	1192,5	
count	25	25	25	75
r^2/n	41127,84	16563,69	56882,25	114573,78
H-stat				13,207958
H-ties				13,459925
df				2
p-value				0,0011946
alpha				0,05
sig				yes

Kako bi ustanovili koje se točno skupine vremenskih neprilika razlikuju, uspoređujemo svake dvije međusobno koristeći Mann-Whitney-jev test u Real Statistics-u i postavljamo nulte hipoteze da dvije međusobno uspoređivane skupine imaju distribuciju istog oblika (12). Alternativne hipoteze su da dvije međusobno uspoređivane skupine nemaju distribuciju istog oblika (13). S obzirom na broj skupina, provodimo tri *post hoc* testa (odnosno ukupno imamo tri para hipoteza m) pa je korigirana razina značajnosti (14) korištenjem Bonferroni-jeve korekcije (6).

$$H_0: \mu_1 = \mu_2 \tag{12}$$

$$H_1: \mu_1 \neq \mu_2 \tag{13}$$

$$\alpha' = \frac{\alpha}{m} = \frac{0,05}{3} = 0,01667 \tag{14}$$

Tablica 6. Primjena Mann-Whitney-jeva testa u Real Statistics-u za mjesec siječanj međusobno uspoređujući Oborine (≥ 10 mm) i Olujni vjetar

Mann-Whitney Test for Two Independent Samples

	Oborine ≥ 10 mm	Olujni vjetar
count	25	25
median	4	1
rank sum	778	497
U	172	453

	one tail	two tail
alpha	0,01667	
U	172	
mean	312,5	
std dev	50,9313764	ties
z-score	2,758613843	
effect r	0,390126911	
U-crit	204,1198225	190,5750495
p-value	0,002902354	0,005804708
sig (norm)	yes	yes

Tablica 7. Primjena Mann-Whitney-jeva testa u Real Statistics-u za mjesec siječanj međusobno uspoređujući Oborine (≥ 10 mm) i Hladne dane ($T_{min} < 0$ °C)

Mann-Whitney Test for Two Independent Samples

	Oborine ≥ 10 mm	Hladni dani $T_{min} < 0$ °C
count	25	25
median	4	6
rank sum	561	714
U	389	236

	one tail	two tail
alpha	0,01667	
U	236	
mean	312,5	
std dev	51,17496997	ties
z-score	1,49487142	
effect r	0,211406744	
U-crit	203,6014639	189,9919093
p-value	0,067474001	0,134948003
sig (norm)	no	no

Tablica 8. Primjena Mann-Whitney-jeva testa u Real Statistics-u za mjesec siječanj međusobno uspoređujući Olujni vjetar i Hladne dane ($T_{\min} < 0\text{ }^{\circ}\text{C}$)

Mann-Whitney Test for Two Independent Samples

	Olujni vjetar	Hladni dani $T_{\min} < 0\text{ }^{\circ}\text{C}$
count	25	25
median	1	6
rank sum	471,5	803,5
U	478,5	146,5

	one tail	two tail
alpha	0,01667	
U	146,5	
mean	312,5	
std dev	50,75199805	ties
z-score	3,270807187	
effect r	0,462561988	
U-crit	204,5015333	191,0044645
p-value	0,000536205	0,00107241
sig (norm)	yes	yes

Tablice 6.-8. prikazuju međusobne usporedbe vremenskih neprilika, primjenom Mann-Whitney-jeva testa, s korigiranom razinom značajnosti ($\alpha' = 0,01667$) i postavljenim hipotezama (12 i 13). Razmatrajući kritično područje dvostranog testa - *two tail* (zbog odnosa jednakosti, odnosno nejednakosti postavljenih hipoteza), zaključujemo da su statistički značajne razlike između Oborina ($\geq 10\text{ mm}$) i Olujnog vjetra (podaci iz Tablice 6. pod *two tail*: $p = 0,005804708 < 0,01667$ ili *sig (norm): yes*) te statistički značajne razlike između Olujnog vjetra i Hladnih dana ($T_{\min} < 0\text{ }^{\circ}\text{C}$) (podaci iz Tablice 8. pod *two tail*: $p = 0,00107241 < 0,01667$ ili *sig (norm): yes*).

S obzirom na podatke o broju dana s djelovanjem pojedine vremenske neprilike, za vremensko razdoblje od 25 godina te međusobno uspoređujući svake dvije vremenske neprilike i razmatrajući kritično područje dvostranog testa, uz sumiranje svih podataka o broju dana u mjesecu s djelovanjem pojedine vremenske neprilike kroz 25 godina za mjesec siječanj, zaključujemo da će Oborine ($\geq 10\text{ mm}$) i Hladni dani ($T_{\min} < 0\text{ }^{\circ}\text{C}$), u odnosu na Olujni vjetar, značajno češće ometati izvođenje radova na gradilištu, odnosno Olujni vjetar će, u odnosu na sve tri testirane skupine, najmanje ometati izvođenje radova na gradilištu u mjesecu siječnju.

Tablica 9. Sumarni zaključci s obzirom na vremenske neprilike

ZAKLJUČCI	
MJESECI	MEĐUSOBNE USPOREDBE IZMEĐU OBORINA (≥ 10 mm), OLUJNOG VJETRA I HLADNIH DANA ($T_{\min} < 0$ °C)
Siječanj	Oborine (≥ 10 mm) i Hladni dani ($T_{\min} < 0$ °C) će značajno češće od Olujnog vjetra ometati izvođenje radova. Olujni vjetar će najmanje ometati izvođenje radova.
Veljača Prosinac	Oborine (≥ 10 mm) će značajno češće od Olujnog vjetra ometati izvođenje radova. Olujni vjetar će značajno manje od Oborina (≥ 10 mm) ometati izvođenje radova. Statistički značajne razlike nema između djelovanja Oborina (≥ 10 mm) i Hladnih dana ($T_{\min} < 0$ °C) te između djelovanja Olujnog vjetra i Hladnih dana ($T_{\min} < 0$ °C).
Ožujak Travanj Studeni	Oborine (≥ 10 mm) će najviše ometati izvođenje radova. Hladni dani ($T_{\min} < 0$ °C) i Olujni vjetar će značajno manje od Oborina (≥ 10 mm) ometati izvođenje radova.
Listopad	Oborine (≥ 10 mm) će značajno češće od Olujnog vjetra, dok će Olujni vjetar značajno češće od Hladnih dana ($T_{\min} < 0$ °C), ometati izvođenje radova. Oborine (≥ 10 mm) će najviše ometati izvođenje radova. Hladni dani ($T_{\min} < 0$ °C) će najmanje ometati izvođenje radova.
MJESECI	MEĐUSOBNE USPOREDBE IZMEĐU OBORINA (≥ 10 mm), OLUJNOG VJETRA I VRUĆIH DANA ($T_{\max} \geq 30$ °C)
Svibanj Rujan	Oborine (≥ 10 mm) će najviše ometati izvođenje radova. Olujni vjetar i Vrući dani ($T_{\max} \geq 30$ °C) će značajno manje od Oborina (≥ 10 mm) ometati izvođenje radova.
Lipanj Srpanj Kolovoz	Vrući dani ($T_{\max} \geq 30$ °C) će značajno češće od Oborina (≥ 10 mm), dok će Oborine (≥ 10 mm) značajno češće od Olujnog vjetra, ometati izvođenje radova. Vrući dani ($T_{\max} \geq 30$ °C) će najviše ometati izvođenje radova. Olujni vjetar će najmanje ometati izvođenje radova.

Tablica 9. prikazuje sumarne zaključke primjenom Kruskal-Wallis-ovog i Mann-Whitney-jevog testa za mjesece (od listopada do travnja) karakteristične sa zabilježenim djelovanjima Oborina (≥ 10 mm), Olujnog vjetra i Hladnih dana ($T_{\min} < 0$ °C) te sumarne zaključke za mjesece (od svibnja do rujna) karakteristične sa zabilježenim djelovanjima Oborina (≥ 10 mm), Olujnog vjetra i Vrućih dana ($T_{\max} \geq 30$ °C).

2.2. Intervalna procjena očekivanja u skupini s normalnom distribucijom podataka

Intervalna procjena očekivanja označava primjenu odgovarajućih statističkih testova koji, ovisno o veličini skupine te ovisno o poznatoj ili nepoznatoj vrijednosti varijance, kao i razini pouzdanosti ($1 - \alpha$), određuje raspon intervala s vjerodostojnom procjenom podataka unutar dobivenog intervala. Primjena intervalne procjene očekivanja prikladna je za testiranje male skupine ($n \leq 30$) s normalom distribucijom podataka, kao i za testiranje velike skupine ($n > 30$) s podacima koji tada ne trebaju imati normalnu distribuciju.

Izraz za intervalnu procjenu očekivanja u maloj skupini ($n \leq 30$) s normalnom distribucijom podataka i nepoznatom varijancom je (15), gdje je \bar{x} aritmetička sredina, $t_{\frac{\alpha}{2}}(n-1) \frac{\hat{s}}{\sqrt{n}}$ širina intervala, a \hat{s} standardna devijacija [6]. Vrijednosti kvantila $t_{\frac{\alpha}{2}}(n-1)$ tražimo među kvantilima Studentove ili t-distribucije s $(n-1)$ stupnjeva slobode (df) [6, 8].

$$\left(\bar{x} - t_{\frac{\alpha}{2}}(n-1) \frac{\hat{s}}{\sqrt{n}}, \bar{x} + t_{\frac{\alpha}{2}}(n-1) \frac{\hat{s}}{\sqrt{n}} \right) \quad (15)$$

2.2.1. Primjena intervalne procjene očekivanja u skupini s normalnom distribucijom podataka

Prethodno je istaknuto da vremenske neprilike predstavljaju nezavisne skupine jer svaka pojedina vremenska neprilika nije nužno i uvjet pojave neke druge vremenske neprilike. Međutim, u svrhu realne analize problematike mogućih dana zastoja pri radu gradilišta zbog vremenskih neprilika, možemo primijeniti princip uključivanja-isključivanja [9]. Princip uključivanja-isključivanja predstavlja matematičko očekivanje broja dana u mjesecu s barem jednom vremenskom neprilikom. Primjenom principa uključivanja-isključivanja, odnosno primjenom matematičkog očekivanja broja dana u mjesecu s barem jednom vremenskom neprilikom, ujedno dobivamo i matematičko očekivanje broja onih dana kada vremenske neprilike dovode do zastoja pri radu gradilišta. Prethodno razmatrajući dobivene podatke iz DMHZ-a i, na temelju tih podataka, strukturirajući tri karakteristične skupine vremenskih neprilika za svaki pojedini mjesec,

izraz primjene principa uključivanja-isključivanja, odnosno izraz za matematičko očekivanje broja dana u mjesecu s barem jednom vremenskom neprilikom, tada bi glasilo (16), gdje je d broj dana u mjesecu, a broj dana sa zabilježenim djelovanjem oborinama (≥ 10 mm), b broj dana sa zabilježenim djelovanjem olujnog vjetra i c broj dana sa zabilježenim djelovanjem hladnih dana ($T_{\min} < 0$ °C), odnosno vrućih dana ($T_{\max} \geq 30$ °C), ovisno o pojedinom mjesecu. Nadalje, izrazi $\frac{a}{d} \cdot b$, $\frac{a}{d} \cdot c$, $\frac{b}{d} \cdot c$, predstavljaju matematičko očekivanje broja dana u mjesecu koji imaju zabilježeno djelovanje, redom, oborina (≥ 10 mm) i olujnog vjetra, zatim oborina (≥ 10 mm) i hladnih ($T_{\min} < 0$ °C), odnosno vrućih dana ($T_{\max} \geq 30$ °C) te naposljetku, olujnog vjetra i hladnih ($T_{\min} < 0$ °C), odnosno vrućih dana ($T_{\max} \geq 30$ °C). Izraz $\frac{a}{d} \cdot \frac{b}{d} \cdot c$ predstavlja matematičko očekivanje broja dana sa zabilježenim djelovanjem i oborina (≥ 10 mm) i olujnog vjetra te hladnih ($T_{\min} < 0$ °C), odnosno vrućih dana ($T_{\max} \geq 30$ °C), odnosno broj dana u mjesecu sa zabilježenim djelovanjem svih triju karakterističnih skupina vremenskih neprilika, ovisno o pojedinom mjesecu.

$$a + b + c - \frac{a}{d} \cdot b - \frac{a}{d} \cdot c - \frac{b}{d} \cdot c + \frac{a}{d} \cdot \frac{b}{d} \cdot c \quad (16)$$

Tablica 10. prikazuje primjenu principa uključivanja-isključivanja kroz izraz (16) za mjesec siječanj koji broji 31 dan (d) i zabilježeno djelovanje Oborina (≥ 10 mm) (a), Olujnog vjetra (b) i Hladnih dana ($T_{\min} < 0$ °C) (c). Primjenom principa uključivanja-isključivanja, odnosno primjenom matematičkog očekivanja broja dana u mjesecu siječnju s barem jednom vremenskom neprilikom, ujedno dobivamo i matematičko očekivanje broja onih dana u mjesecu siječnju kada vremenske neprilike dovode do zastoja pri radu gradilišta za vremensko razdoblje od 25 godina (od 1992. do 2016.). Tako dobivenoj skupini testiramo distribuciju podataka u svrhu odgovarajuće daljnje primjene statističkih testova.

Testiranjem distribucije podataka skupine s matematički očekivanim brojevima dana zastoja pri radu gradilišta za mjesec siječanj za vremensko razdoblje od 25 godina, primjenom Shapiro-Wilk testa u Real Statistics-u, na razini značajnosti od 5 % ($\alpha = 0,05$), dobivamo rezultate da je zadovoljen uvjet normalne distribucije podataka. (Tablica 11.). S obzirom da je za dobivenu skupinu zadovoljen uvjet normalne distribucije podataka, možemo zaključiti da je prikladno koristiti intervalnu procjenu očekivanja u maloj skupini ($n \leq 30$) s normalnom distribucijom podataka i nepoznatom varijancom.

Tablica 10. Broj mogućih dana zastoja pri radu gradilišta za mjesec siječanj, ovisno o pojedinoj godini

Rijeka	Pregled broja dana				Matematičko očekivanje broja dana zastoja pri radu gradilišta zbog vremenskih neprilika
Siječanj	Oborine ≥ 10 mm	Olujni vjetar	Hladni dani $T_{\min} < 0$ °C	Vrući dani $T_{\max} \geq 30$ °C	
1992.	1	1	6	0	7,59
1993.	0	3	8	0	10,23
1994.	4	1	1	0	5,71
1995.	6	3	9	0	14,98
1996.	5	1	6	0	10,71
1997.	8	1	0	0	8,74
1998.	2	4	5	0	9,82
1999.	4	2	2	0	7,37
2000.	0	1	9	0	9,71
2001.	7	5	4	0	13,47
2002.	1	1	8	0	9,46
2003.	4	7	8	0	15,49
2004.	5	3	10	0	15,09
2005.	1	7	7	0	13,02
2006.	3	3	10	0	13,87
2007.	5	1	1	0	6,65
2008.	6	0	1	0	6,81
2009.	7	1	9	0	14,52
2010.	8	0	8	0	13,94
2011.	2	4	5	0	9,82
2012.	2	0	8	0	9,48
2013.	6	3	2	0	9,88
2014.	8	2	1	0	10,18
2015.	4	1	1	0	5,71
2016.	6	1	6	0	11,49

Tablica 11. Primjena Shapiro-Wilk testa u Real Statistics-u za skupinu s matematički očekivanim brojevima dana zastoja pri radu gradilišta za mjesec siječanj

Shapiro-Wilk Test

<i>Matematičko očekivanje broja dana zastoja pri radu gradilišta zbog vremenskih neprilika</i>	
W-stat	0,938140034
p-value	0,134076634
alpha	0,05
normal	yes

Izračunom standardne devijacije (naredba u Excel-u: „*stdev.s*“) te s obzirom na broj podataka u skupini (naredba u Excel-u: „*count*“, odnosno za vremensko razdoblje od 25 godina) i razinom pouzdanosti od 95 % ($1 - \alpha = 0,05$), možemo dobiti vrijednost širine intervala (naredba u Excel-u „*confidence.t*“) za testiranu skupinu s matematički očekivanim brojevima dana zastoja pri radu gradilišta. Razina pouzdanosti od 95 % znači da za 95 % slučajeva imamo odgovarajuću intervalnu procjenu, dok je za 5 % slučajeva intervalna procjena pogrešna. Prema dobivenoj vrijednosti širine intervala dobivamo interval tako da za donju vrijednost intervala od aritmetičke sredine (naredba u Excel-u „*average*“) oduzmemo širinu intervala, a za gornju vrijednost intervala aritmetičkoj sredini dodamo vrijednost širine interval (Tablica 12.). Interval s vrijednostima od 9,30 do 11,80 označava vjerodostojnu statističku procjenu skupine s matematički očekivanim brojevima dana zastoja pri radu gradilišta za mjesec siječanj. Odnosno, interpretacija tog intervala naglašava da je 95 % sigurno da matematičko očekivanje broja onih dana kada vremenske neprilike dovode do zastoja pri radu gradilišta leži u intervalu od 9,30 do 11,80.

Tablica 12. Primjena intervalne procjene očekivanja u skupini s normalnom distribucijom podataka u Excel-u za mjesec siječanj

Aritmetička sredina (Mean)	10,55
Standardna devijacija (Standard Deviation)	3,036613631
Broj uzorka (Count)	25
Širina intervala	1,253452501
Interval	< 9,30 11,80 >

U Tablici 13. prikazani su mjesečni intervali s matematički očekivanim danima zastoja zbog vremenskih neprilika pri radu gradilišta. Budući da za mjesec lipanj na temelju postavljenih pretpostavki nije dobivena skupina s

normalnom distribucijom podataka, kao mjerodavna veličina uzet će se medijan testirane skupine. Ljetni mjeseci na području grada Rijeke imaju najveći broj matematički očekivanih dana zastoja zbog velikog broja dana s izrazito visokim vrućinama, dok proljetni mjeseci imaju najmanji broj matematički očekivanih dana zastoja pri radu gradilišta zbog vremenskih neprilika.

Tablica 13. Mjesečni intervali s matematički očekivanim danima zastoja

ZAKLJUČCI			
MJESEČNI INTERVALI S MATEMATIČKI OČEKIVANIM DANIMA ZASTOJA PRI RADU GRADILIŠTA ZBOG VREMENSKIH NEPRILIKA [dani]			
Siječanj	$\langle 9,30 - 11,80 \rangle$	Srpanj	$\langle 14,23 - 19,33 \rangle$
Veljača	$\langle 7,67 - 11,33 \rangle$	Kolovoz	$\langle 14,09 - 19,15 \rangle$
Ožujak	$\langle 4,31 - 6,81 \rangle$	Rujan	$\langle 6,05 - 8,01 \rangle$
Travanj	$\langle 2,91 - 4,87 \rangle$	Listopad	$\langle 4,97 - 7,40 \rangle$
Svibanj	$\langle 3,22 - 5,29 \rangle$	Studeni	$\langle 6,61 - 8,94 \rangle$
Lipanj	Podaci nemaju normalnu distribuciju! Medijan ima vrijednost 7,6.	Prosinac	$\langle 7,19 - 10,86 \rangle$

Dobiveni mjesečni intervali s matematički očekivanim danima zastoja pri radu gradilišta zbog vremenskih neprilika rezultati su primjene matematičke i statističke obrade podataka te imaju kvantitativnu i izvjesnu vrijednost. Također, pokazatelj su potrebnih rezervi koje je potrebno uzeti u obzir prilikom, ponajprije i najvažnije, definiranja vremenskog roka za građenje i, unutar tog roka, ključnih međurokova građenja. Prilikom definiranja vremenskog roka za građenje, mjesečni intervali bi služili kao nadodana gruba vremenska rezerva za očekivane zastoje pri radu gradilišta zbog vremenskih neprilika, ovisno o mjesecima kroz koje se planira izvođenje radova. Detaljiziranjem vremenskog plana prilikom izrade ponude za građenje te daljnjim detaljiziranjem plana prilikom samog građenja, potrebno je ažuriranje i nadograđivanje vremenskog plana, primjerice, na mjesečnoj bazi. Mjesečni intervali s matematički očekivanim danima zastoja pri radu gradilišta zbog vremenskih neprilika posebno pogoduju mjesečnom ažuriranju vremenskog plana gdje bi se, unutar jednog mjeseca, moglo odgovarajuće isplanirati izvršenje svih onih aktivnosti, čija uspješna realizacija u značajnoj mjeri ovisi upravo o povoljnim vremenskim uvjetima. Vremenski plan je podloga za praćenje i kontrolu izvođenja radova [10]. Na temelju praćenja i kontrole plana mogu

se pravovremeno donijeti ispravne odluke i odgovarajuće korektivne mjere. Vremensko planiranje podrazumijeva kontinuirano ažuriranje, detaljiziranje i poboljšanje vremenskog plana te praćenje i kontrolu izvršenja planiranih aktivnosti u svrhu smanjivanja neizvjesnosti prilikom izvođenja radova na gradilištu. Pri tome, mjesečni intervali s matematički očekivanim danima zastoja zbog vremenskih neprilika mogu imati značajnu ulogu.

3. Zaključak

Kontinuirani i zadovoljavajući tijek izvođenja radova na gradilištu u zavisnom je odnosu s vremenskim utjecajima. Zanemarivanje vremenskog utjecaja jedan je od uzroka prekoračenja vremenskog roka za građenje. S tim u vezi, rad daje rezultate statističke obrade podataka pri testiranju različitosti utjecaja vremenskih neprilika prilikom građenja te statističku intervalnu kvantifikaciju matematički očekivanih dana zastoja pri radu gradilišta zbog nepovoljnih vremenskih uvjeta na području grada Rijeke. Detaljna statistička obrada prikazana je samo za mjesec siječanj, dok su statistički rezultati za ostale mjesece prikazani kroz sumarne zaključke. Dobiveni mjesečni intervali, prikazani u radu, s matematički očekivanim danima zastoja pri radu gradilišta zbog vremenskih neprilika, predstavljaju vrijedan ulazni parametar u svrhu preciznije izrade vremenskog plana i definiranja roka za građenje na području grada Rijeke. Precizniji vremenski plan i rok za građenje rezultirao bi smanjenjem sadašnje problematike zastoja, kašnjenja i gubitaka na gradilištu kao i smanjenjem rada radnika pri nepovoljnim uvjetima i/ili prekovremenim radnim satima.

Literatura

- [1] Ballesteros-Pérez, P., Rojas-Céspedes, Y.A., Hughes, W., Kabiri, S., Pellicer, E., Mora-Melià, D. and del Campo-Hitschfeld, M.L. (2017.) Weather-Wise: A Weather-Aware Planning Tool for Improving Construction Productivity and Dealing with Claims. *Automation in Construction*, 84, str. 81-95.
- [2] Radujković, M. (1999.) Izvor prekoračenja rokova i proračuna građevinskih projekata. *Građevinar*, 51(2), str. 159-165.
- [3] Moselhi, O., Gong, D. and El-Rayes, K. (1997.) Estimating Weather Impact on the Duration of Construction Activities. *Canadian Journal of Civil Engineering*, 24(3), str. 359-366.
- [4] Wackerly, D.D., Mendenhall, W. III and Scheaffer, R.L., (2008.) *Mathematical Statistics with Applications*. Seventh Edition. Belmont, CA, USA: Thomson Learning, Inc.
- [5] Thompson, C.M. (1941.) Table of Percentage Points of the χ^2 Distribution. *Biometrika*, 32(2), str. 187-191.

- [6] Filipin, A. (ak. g. 2017./2018.) Nastavni materijali na kolegiju Primijenjena statistika, poslijediplomski doktorski studij, Građevinski fakultet, Sveučilište u Zagrebu.
- [7] Walpole, R.E. (1968.) Introduction to Statistics. New York: Macmillan.
- [8] Merrington, M. (1942.) Table of Percentage Points of the t-Distribution. Biometrika, 32(3-4), str. 300-300.
- [9] Lipschutz, S., Lipson, M. (2000.) Probability. Schaum's Outlines. Second Edition. New York: McGraw-Hill.
- [10] Radujković, M. i suradnici (2012.) Planiranje i kontrola projekata. Zagreb: Sveučilište u Zagrebu, Građevinski fakultet.