Prethodno priopćenje
UDK: 331.31”329.7”:004.738.5
004.738.5:339.37(497.5)
Datum primitka članka u uredništvo: 14. 1. 2026.
Datum slanja članka na recenziju: 3. 2. 2026.
Datum prihvaćanja članka za objavu: 23. 6. 2026.

Doc. dr. sc. Ivana Lolić *

UTJECAJ NERADNE NEDJELJE NA POPULARNOST INTERNETSKOG PRETRAŽIVANJA MALOPRODAJNIH LANACA U HRVATSKOJ

THE IMPACT OF SUNDAY TRADING RESTRICTIONS ON THE POPULARITY OF ONLINE SEARCH FOR RETAIL CHAINS IN CROATIA

SAŽETAK: U radu se analizira utjecaj uvođenja neradne nedjelje na dinamiku *online* interesa za najveće maloprodajne lance u Hrvatskoj, mjerenog pomoću podataka s platforme Google Trends. Regulacija je uvedena izmjenama Zakona o trgovini iz 2023. godine te je ograničila rad trgovina na najviše 16 nedjelja godišnje, čime je potaknuto intenzivnije informiranje potrošača o radnom vremenu i dostupnosti prodajnih mjesta. Kako bi se procijenila promjena u popularnosti pretraživanja nakon stupanja zakona na snagu, primjenjuje se model regresijskog diskontinuiteta u vremenu. Rezultati upućuju na statistički značajan porast popularnosti pretraživanja neposredno nakon uvođenja regulacije, pri čemu je učinak najizraženiji za vodeće lance Konzum i Lidl. U kasnijim se razdobljima intenzitet učinka smanjuje i stabilizira, što sugerira postupnu prilagodbu potrošača novim pravilima. Nalazi potvrđuju da Google Trends može poslužiti kao koristan komplementaran pokazatelj kratkoročnih reakcija potrošača na regulatorne promjene te doprinijeti razumijevanju ponašanja potrošača u digitalnom okruženju.

KLJUČNE RIJEČI: Google Trends, neradna nedjelja, regulacija, maloprodaja, digitalna ekonomija

JEL KLASIFIKACIJA: L81, K23, D12

ABSTRACT: This paper analyzes the impact of Sunday trading restrictions on the online interest dynamics in the largest retail chains in Croatia, measured using Google Trends data. The regulation was introduced through amendments to the Trade Act in 2023 and limited store operations to a maximum of 16 Sundays per year, thereby encouraging consumers to seek information about opening hours. To assess the policy effect, we apply a

* Doc. dr. sc. Ivana Lolić, Faculty of Economics and Business, University of Zagreb, Zagreb, Croatia, Trg J. F. Kennedyja 6, 10 000 Zagreb, Croatia, e-mail: ilolic@efzg.hr; ORCID: 0000-0003-3112-7699

regression discontinuity in time design. The results indicate a significant increase in search popularity immediately following the introduction of the regulation, with the strongest effect observed for the leading chains Konzum and Lidl. In later periods, the magnitude of the effect declines and stabilizes, suggesting a gradual consumer adjustment to the changes. The findings confirm that Google Trends can serve as a useful complementary indicator of short-term consumer responses to regulatory changes and can contribute to an understanding of consumer behavior.

KEY WORDS: Google Trends, Sunday trading restrictions, regulation, retail, digital economy

JEL CLASSIFICATION: L81, K23, D12

1. UVOD

Uvođenje politike koja ograničava rad trgovina može značajno utjecati na cijeli trgovinski sektor te na ponašanje potrošača. U Hrvatskoj je pitanje regulacije rada nedjeljom već dulje vrijeme jedna od važnijih tema u raspravama o maloprodaji. Javno mnijenje pritom je podijeljeno: dio građana podržava zabranu rada nedjeljom zbog očekivanih društvenih koristi, poput bolje ravnoteže između poslovnog i privatnog života, dok drugi upozoravaju na moguće negativne ekonomske posljedice. No osim ekonomskih učinaka, ograničenje rada nedjeljom mijenja organizaciju poslovanja maloprodajnih lanaca te utječe na promjene ponašanja potrošača.

Promjene Zakona o trgovini (ZoT; Narodne novine, 2023), koje su stupile na snagu 1. srpnja 2023., uvele su ograničenja na rad nedjeljom i državnim praznicima. Nije, međutim, uvedena potpuna zabrana: svakom je trgovcu omogućeno da samostalno odabere 16 radnih nedjelja tijekom godine. Svaka trgovina pritom mora javno objaviti raspored radnih i neradnih nedjelja, te ih može raspoređivati među svojim poslovnicama. Potrošači u Hrvatskoj nisu se odmah prilagodili novom režimu rada, pa su tijekom prvih mjeseci nakon uvođenja zabrane gužve u trgovinama bile česte. Mediji su izvještavali o gužvama, praznim policama te dugim redovima kupaca koji čekaju na ulazak u trgovinu (Index.hr, 2023 i tportal, 2024). S vremenom, takve vijesti postale su rijetkost. Prema anketi agencije Valicon (Ja trgovac, 2024), provedene u veljači 2024. godine, većina potrošača se do tada priviknula na novi režim rada te su kupovinu nedjeljom prerasporedili na druge dane u tjednu. Rezultati ankete pokazali su i da većini ispitanika odgovara novi način organizacije rada iz čega se može zaključiti da su se potrošači donekle priviknuli na novu regulaciju.

Proces prilagodbe u velikoj je mjeri obilježila potraga za otvorenim trgovinama i pokušaji kompenziranja neradne nedjelje. U početnom razdoblju nije postojao centralizirani izvor informacija koji bi olakšao pronalazak otvorenih prodajnih mjesta te su potrošači morali pojedinačno provjeravati trgovine ili njihove internetske stranice. Pojačanu pretragu takvih pretraživanja na Googleovoj tražilici moguće je pratiti pomoću platforme Google Trends (GT). Budući da se korisnici u Hrvatskoj najčešće informiraju putem interneta, povećano zanimanje za trgovine koje rade trebao bi biti jedan od očekivanih rezultata, dok bi povratak na razdoblje prije zakonske izmjene bio pokazatelj prilagodbe na novi režim rada.

Cilj ovog rada jest istražiti kako je uvođenje neradne nedjelje utjecalo na popularnost pretraživanja najvećih maloprodajnih lanaca u Hrvatskoj. Korištenjem podataka s platforme Google Trends nastoji se prikazati promjene u obrascima potrošačkog interesa te procijeniti u kojoj mjeri analiza internetskih pretraživanja može poslužiti kao dodatni alat za razumijevanje učinaka regulatornih mjera na maloprodajno tržište.

2. PREGLED LITERATURE

Maloprodaja je iznimno važan i dinamičan sektor hrvatskog gospodarstva, koji je posljednjih godina bilježio snažan rast. Prema podacima za 2024. godinu, realni promet u maloprodaji porastao za 7,7 % na godišnjoj razini te su vodeći maloprodavači kontinuirano jačali svoje tržišne pozicije ostvarivši rast prihoda, marži i dobiti za 2023. godinu (Anić, 2025). Takvi pokazatelji navode na zaključak da uvođenje neradne nedjelje nije imalo negativan učinak na maloprodajni sektor. Međutim, financijski pokazatelji predstavljaju samo jedan aspekt učinaka nove regulative. Promjene u ponašanju potrošača i obrascima potražnje također su važan dio razumijevanja prihvaćanja ove zakonske mjere.

Jedna od važnijih novosti u izmjenama ZoT-a jest to što se trgovcima omogućuje rad tijekom 16 nedjelja u godini (Narodne novine, 2023). Raspored tih nedjelja nije ničim uvjetovan niti propisan, pa ih trgovci mogu rasporediti među svojim poslovnicama. Pri odabiru su se uglavnom odlučivali za one nedjelje koje uobičajeno donose veći promet, no unatoč tome, nisu mogli poslovati u istom opsegu kao prije zakonskih izmjena. Uvođenje mogućnosti izbora stvorilo je određenu informacijsku neizvjesnost, posebno izraženu u početnoj fazi primjene nove regulative. U tom su razdoblju potrošači intenzivno tražili informacije o tome koje su trgovine otvorene i u kojim terminima posluju, kao i o tome jesu li pojedini lanci odlučili iskoristiti mogućnost rada nedjeljom.

Promjene u interesu potrošača za trgovinama koje rade nedjeljom moguće je pratiti i kvantitativno, korištenjem platforme Google Trends. Riječ je o alatu koji omogućuje analizu popularnosti pretraživanja pojmova na Googleovoj tražilici te pruža uvid u promjene interesa korisnika tijekom vremena. Pretpostavlja se da korisnici koji traže informacije o otvorenim trgovinama najčešće pretražuju nazive najvećih maloprodajnih lanaca, poput „Konzum“ ili „Lidl“, kao i izraze koji se odnose na radno vrijeme, primjerice „Konzum radno vrijeme“. Pojačan interes za takvim pojmovima vidljiv je u podacima s platforme Google Trends, čija analiza omogućuje dodatni uvid u dinamiku prilagodbe potrošača u Hrvatskoj na novu zakonsku regulativu o neradnoj nedjelji.

Empirijska istraživanja dosljedno pokazuju da uvođenje ili najava nove politike, propisa ili sudske odluke potiču pojačano informiranje javnosti vidljivo kroz rast učestalosti pretraga putem Googlea. Autori Bento i sur. (2020) dokumentiraju trenutačni skok u pretragama nakon prvih lokalnih vijesti i zakonskih odredbi vezanih uz COVID-19 na panelu američkih saveznih država. Ghosh i sur. (2021) analiziraju naglu promjenu politika koje reguliraju konzumaciju alkohola u Indiji tijekom „lockdowna“ i pokazuju da Google Trends pruža brzu povratnu informaciju kreatorima politika o reakcijama stanovništva: pretrage snažno reagiraju na najave i primjenu mjera (npr. zabrane prodaje alkohola). Slično tome, u području regulacije e-cigareta, Boakye i sur. (2022) prate najave Američke agencije za hranu i lijekove te provedbu regulacija te nalaze statistički značajno povećanje *online* pretraga

za specifične marke (npr. „Puff Bar“) odmah nakon najave izmjene regulative, s različitim intenzitetom u fazama najave, djelomičnog izuzeća i naknadnog pooštravanja. Zajednički nazivnik ovih radova jest da intervencijski signal (najava, donošenje, implementacija) uzrokuje skok u potrazi za informacijama te da je Google Trends koristan alat za praćenje reakcija javnosti.

3. PODACI I METODA

3.1. Podaci Google Trendsa

GT je platforma koja prikazuje popularnost pretraživanja na internetskoj tražilici Google. Za zadani upit [riječ][1] analizira se učestalost pretraživanja za odabranu geografsku lokaciju i vremenski raspon. Primjerice, za upit *[trgovina], Hrvatska i posljednjih 5 godina*, GT prikazuje učestalost pretraživanja u Hrvatskoj u zadnjih pet godina. Sam postupak izračuna za pojam [riječ] provodi se po sljedećim koracima. Prvo se precizira period {**1**, ..., *T*} i lokacija *g* te zatim GT napravi reprezentativan slučajan uzorak svih pretraživanja za zadani period i lokaciju. Za svaku vremensku točku *t* računa proporciju upita koji sadrže pojam [riječ] u odnosu na ukupan broj upita (izabranih u uzorak), u oznaci p_t. GT ne prikazuje proporcije (iz čega bi bilo jasno koliko je pojam popularan), već se podaci dodatno transformiraju. Sljedeći je korak određivanje maksimalne proporcije $p_M = \max(p_1, p_2, \ldots, p_T)$ te se indeks volumena pretraživanja (engl. *Search Volume Index,* SVI) računa prema formuli:

$$SVI_t = \frac{p_t}{p_{\mathrm{M}}} \cdot 100. \tag{1}$$

Indeks SVI poprima vrijednosti između 0 i 100, 100 označava maksimalnu popularnost za promatrano razdoblje, dok 0 ukazuje na zanemarivu popularnost. Indeks se prikazuje bez decimalnog dijela. Prikazivanje u obliku (baznog) indeksa zamagljuje koliko je upit [riječ] popularan u odnosu na druge pojmove koji se pretražuju (što bi bilo vidljivo iz dinamike p_t), no analizom indeksa SVI i dalje je moguće pratiti njegovu dinamiku kroz vrijeme.

Ovakav način izračuna indeksa SVI vrlo je brz i jednostavan, no rezultira tehničkim posebnostima koje je potrebno uzeti u obzir.[2] Autori Cebrián i Domenech (2024) sumiraju nekonzistentnosti podataka GT-a te navode pokušaje ublažavanja i adresiranja tih poteškoća. Najznačajniji problem proizlazi iz računanja podataka na temelju slučajnog uzorka. Praktična posljedica jest jako brz izračun (jer se pristupa uzorku), no prilikom svakog preuzimanja podataka vrijednosti indeksa se razlikuju. Za pojmove koji nisu jako učestali ta razlika može biti jako velika, dok su za općenitije pojmove razlike znatno manje. Ostale nekonzistentnosti proizlaze iz skaliranja s maksimumom (koji može biti netipična vrijednost), Googleove promjene metodologije prikupljanja podataka, te problem učestalog preuzimanja s internetske stranice (GT višestruke upite shvaća kao nedozvoljeno korištenje stranice te vraća podatke s blokovima nula[3]). Ovaj se problem najčešće adresira tako da se

[1] Tekst upisan u tražilicu platforme GT označava se unutar uglatih zagrada […].

[2] Za metodološke aspekte obrade podataka GT-a pogledati u Lolić i sur. (2024).

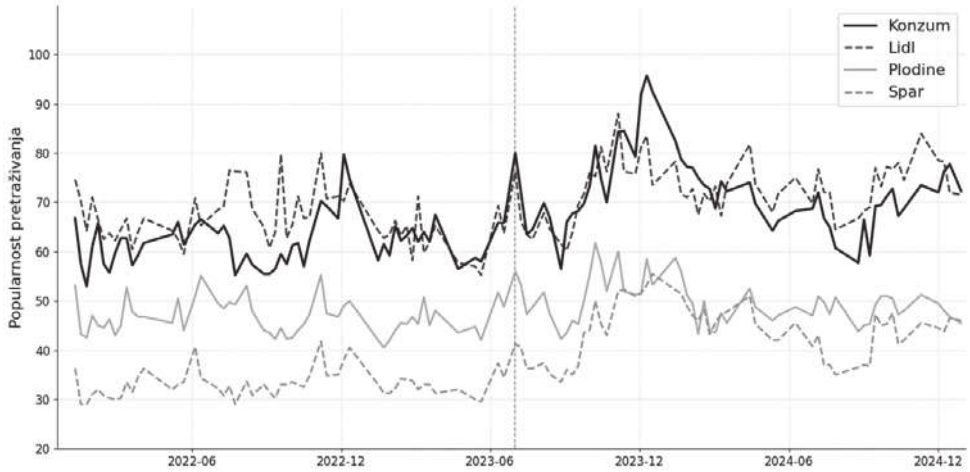
[3] U slučaju da Google počne prikazivati nule ili čudne podatke, potrebno je pauzirati preuzimanja.

tijekom nekoliko dana preuzmu podaci za iste pojmove te analiziraju sličnosti između upita. Ako se preuzimanja iz nekoliko dana značajno razlikuju, onda se takav pojam ne bi trebao dalje koristiti (prerijedak je i podaci nisu pouzdani). Također, ako neko preuzimanje znatno odstupa od ostalih, također se ne bi trebalo koristiti. Za finalni izbor, obično se koristi aritmetička sredina pojedinačnih upita[4].

3.2. Popularnost pretraživanja maloprodajnih lanaca na Googleovoj tražilici

Fokus ovog istraživanja jest popularnost pretraživanja četiriju maloprodajnih lanaca s najvećim tržišnim udjelom. Agencija za zaštitu tržišnog natjecanja (AZTN) kontinuirano prati i objavljuje podatke o tržišnim udjelima maloprodajnih lanaca. Prema podacima za 2024. godinu (AZTN, 2025) najveće tržišne udjele imaju redom Konzum, Lidl, Plodine i Spar[5]. Podaci su prikupljeni s platforme Google Trends za period 2. 1. 2022 – 29. 12. 2024. te promatrani na tjednoj frekvenciji, što čini ukupno $T = 157$ podataka. Izmjene ZoT-a nastupile su 1. 7. 2023., što odgovara $t_0 = 79$ točki u podacima. Indeksi SVI za pojedinačne lance preuzeti su sa stranice Google Trends iz pet preuzimanja te uprosječeni. Grafički je prikaz podataka na Slici 1.

Slika 1. Popularnost pretraživanja maloprodajnih lanaca s najvećim tržišnim udjelom



Dodatak: Vertikalna linija označava početak implementacije izmjena ZoT-a.

Prema Slici 1 može se zaključiti da Konzum i Lidl imaju najveće vrijednosti SVI, što je donekle u skladu s njihovom tržišnom pozicijom[6]. Dinamika indeksa SVI ukazuje

[4] Za više detalja pogledati u Hölzl i sur. (2025), Liu (2024), te Lolić i sur. (2024).

[5] Korišteni su upiti za pojam (engl. *search term*): [konzum], [lidl],[plodine] i [spar + interspar]. Oznaka plus je logički ILI, upit [spar + interspar] uključuje sve upite za pojmom [spar] ili [interspar]. Podaci su preuzeti iz zajedničkog upita te međusobno usporedivi. Detalje o formuliranju upita pogledati u Lolić i sur. (2024).

[6] Prema podacima AZTN (2025) Konzum ima tržišni udio u rasponu [20-30] %, a Lidl [10-20] %.

na relativno ujednačeno ponašanje (bez trenda rasta ili pada) za sve lance u periodu koji prethodi izmjeni ZoT-a u srpnju 2023. godine (lijevo od vertikalne linije). Također, nakon primjene ZoT-a, ne uočavaju se velike promjene u dinamici indeksa SVI sve do rujna 2023. godine. Jedan od razloga jest način implementacije ZoT-a. Naime, maloprodavači su mogli odabrati 16 radnih nedjelja tijekom godine, a s obzirom na to da turistička sezona generira značajne prihode u maloprodaji, mnogi su trgovci odabrali radne nedjelje tijekom srpnja i kolovoza. Zamjetne promjene u obrascima pretraživanja pojavljuju se tek nakon završetka sezone, kada zatvorene trgovine (nedjeljom) počinju značajnije utjecati na uobičajene navike kupaca. Takvo ponašanje moguće je vidjeti pomoću dinamike indeksa SVI na Slici 1., ali i prema obavijestima u medijima o gužvama i praznim policama (npr. Index.hr, 2023). Zaključno, Slika 1. ukazuje i na blago povećanje indeksa SVI te da se vrijednost postupno stabilizira i vraća na period prije izmjena ZoT-a.

3.3. Model regresijskog diskontinuiteta u vremenu

Ispitivanje uzročne veze između uvođenja neradne nedjelje i povećanja vrijednosti SVI istražuje se pomoću modela regresijskog diskontinuiteta u vremenu (engl. *Regression Discontinuity in Time*, RDiT). RDiT je poseban slučaj modela regresijskog diskontinuiteta (engl. *Regression Discontinuity*, RD) te jedan od važnijih kvazi-eksperimentalnih pristupa u empirijskim istraživanjima javnih politika. Dizajn RD sadrži varijablu praga (engl. *running variable*) koja razdvaja jedinice u skupine pod primjenom neke politike (engl. *treatment group*) i one na kojima nije primijenjena politika. Varijabla praga za model RDiT je vrijeme, odnosno postoji jasno definirana vremenska točka (prag) u t_v koja razdvaja vrijeme na razdoblje neposredno prije (1, 2, ..., $t_0 - 1$) i neposredno poslije primjene nove politike ($t_0, t_0 + 1, ..., T$). Metodom RDiT uobičajeno se promatraju podaci visoke frekvencije poput tjednih i dnevnih za relativno kraće razdoblje. Cilj je ovakvog pristupa pratiti varijablu dovoljno često i za kraće razdoblje kako bi se mogao izolirati efekt politike. Budući da se u vrlo kratkom vremenskom intervalu oko datuma intervencije ostali uvjeti obično značajno ne mijenjaju, razlika u vrijednostima zavisne varijable može se interpretirati kao kauzalni učinak same mjere.

RDiT se opisuje sljedećom jednadžbom[7]:

$$y_t = y_0 + y_1 \, Policy + f(t) + \varepsilon_t. \quad t = 1, \ldots T \tag{2}$$

gdje je y_i zavisna varijabla, *Policy* je indikator varijabla (poprima vrijednost 1 za $t \geq t_0$ i 0 inače), $f(t)$ je polinom, $\varepsilon_t \sim IID(O, \sigma^2)$ greške, te y_0 i y_1 parametri. Prije procjene parametara za jednadžbu (2), potrebno je zadati stupanj i oblik polinoma. Prema raspravi Hausman i Rapson (2018), za $f(t)$ ispituje se globalni polinom (engl. *global polynomial*) i zasebni polinomi (engl. *separate polynomial*). Razlika između navedenih pristupa je u tome da globalni polinom pretpostavlja isti polinom za cijelo razdoblje, dok zasebni polinomi dozvoljavaju promjenu polinomijalne strukture nakon početka primjene nove politike. Funkcijski oblik za globalni polinom stupnja k je sljedeći:

[7] U model je moguće dodati kontrolne varijable i varijable pomaka, detaljnije u Hausman i Rapson (2018).

$$f(t) = \beta_1(t - t_0) + \beta_2(t - t_0)^2 + \ldots + \beta_k(t - t_0)^k \tag{3}$$

$$f(t) = \begin{cases} \beta_1(t - t_0) + \beta_2(t - t_0)^2 + \cdots + \beta_k(t - t_0)^k & t < t_0 \\ \alpha_1(t - t_0) + \alpha_2(t - t_0)^2 + \cdots + \alpha_p(t - t_0)^p & t \geq t_0 \end{cases} \tag{4}$$

U oba slučaja polinomi ne sadrže konstantni član jer je on već uključen u jednadžbi (2). Općenito, stupanj polinoma može se odabrati prema odluci istraživača ili fiksiranjem maksimalnog stupnja, nakon čega se odabire stupanj polinoma za koji je vrijednost informacijskog kriterija najmanja (npr. Akaikeov ili Bayesov kriterij). No, prema simulacijama u Gelman i Imbens (2018), visok stupanj polinoma može dovesti do nestabilnih procjena parametara čija se vrijednost jako mijenja pri malim promjenama uzorka (npr. mala skraćivanja perioda). Autori preporučuju korištenje polinoma do stupnja dva te procjene modela za različite specifikacije.

Analiza učinka uvođenja neradne nedjelje svodi se na analizu parametra y_1. Parametar y_1 mjeri promjenu u razini intenziteta pretraživanja na GT nakon stupanja izmjena ZoT-a na snagu u odnosu na period prije uvođenja zakonske promjene. Značajan parametar ukazuje da je uvođene neradne nedjelje uzrokovalo povećanje pretraživanja maloprodajnih lanaca. Kako bi se dodatno istražila dinamika prihvaćanja i prilagodbe na ZoT, dodatno će se promotriti slučaj modela s efektom u fazama: *policy* efekt podijeljen u tri dijela po šest mjeseci. Dakle, umjesto y_1 *Policy*$_1$ dodaju se tri *dummy* varijable odnosno y_1 *Phase*1 + y_2 *Phase*2 + y_3 *Phase*3. Na taj način može se istražiti je li efekt iščezao s vremenom.

Kako bi se precizno izolirao efekt izmjene ZoT-a na SVI varijable dodaje se i sezonska komponenta. Procjenjivanje u koracima (prvo desezoniranje pa RDiT) može dovesti do precjenjivanja parametara iz prvog koraka odnosno sezonskih parametara (Lovell, 1963), tako da će sezonski indikatori biti uključeni odmah u jednadžbu (2). S obzirom na to da su korišteni tjedni podaci, u jednadžbu se dodaje *m* Fourierovih parova:

$$s_t = \sum_{j=1}^{m} a_j \, sin\left(\frac{2\pi jt}{52}\right) + b_j \, cos\left(\frac{2\pi jt}{52}\right), \;\; t = 1, \ldots T \tag{5}$$

uz α_j i β_j odgovarajuće parametre. Broj parova određuje se pomoću Bayesova informacijskog kriterija (BIC). Pri procjeni se koriste robusne standardne pogreške kako je uobičajeno u RDiT literaturi (Hausman i Rapson, 2018).

U konkretnoj primjeni u ovom radu, varijabla praga je tjedan promatranja, a prag t_0 odgovara tjednu u kojem su stupile na snagu izmjene ZoT-a (1. 7. 2023.). Zavisna varijabla y_t je tjedna vrijednost indeksa SVI pojedinog maloprodajnog lanca, a indikator *Policy* poprima vrijednost 1 za sva razdoblja od t_0 nadalje. Specifikacija također uključuje vremenski pomak zavisne varijable (y_{t-1}) radi modeliranja autoregresivnog karaktera indeksa SVI. Identifikacijska pretpostavka modela jest da bi se ostali relevantni faktori, koji nisu povezani s uvođenjem neradne nedjelje, glatko mijenjali oko praga t_0, dok promjena u razini zavisne varijable točno u trenutku stupanja regulacije na snagu može se pripisati učinku same politike. Polinom *f*(*t*) ima ulogu kontrole za osnovni vremenski trend pretraživanja, čime se osigurava da se procijenjeni skok kod praga ne pripiše postojećoj dinamici. Stupanj polinoma odabire se prema BIC-u uz gornju granicu od dva, u skladu s preporukom Gelman i Imbens (2018). Dodatno se procjenjuje i specifikacija s tri uzastopne *dummy* varijable

(Phase1, Phase2 i Phase3), koje pokrivaju razdoblja od po šest mjeseci nakon uvođenja regulacije, čime se omogućuje praćenje dinamike učinka tijekom vremena. Detaljniji metodološki aspekti pristupa RDiT, uključujući rasprave o izboru stupnja polinoma, prijetnjama identifikaciji i izboru optimalne širine prozora, izneseni su u Hausman i Rapson (2018).

4. REZULTATI

Dinamika popularnosti pretraživanja (SVI) istražuje se i pomoću modela RDiT. Analiziraju se dva pristupa: (G) globalni polinom i (S) zasebni polinom. Globalnim polinomom procjenjuje se jedan zajednički polinom za cijelo razdoblje (jednadžba 3), dok pristup pomoću zasebnog polinoma omogućava promjenu polinomijalne strukture nakon izmjena ZoT-a (jednadžba 4). Globalni i zasebni polinom promatraju se na dva načina. Referentni model (engl. *baseline*) je model s prosječnim efektom s procjenom prema jednadžbi (2), te model s efektom u fazama: *policy* efekt podijeljen u tri dijela po šest mjeseci. Rezultati su prikazani u Tablici 1. i 2.

Parametar uz varijablu *Policy* prikazuje procijenjenu promjenu u razini indeksa SVI nakon uvođenja izmjena ZoT-a. Svi lanci pokazuju statistički značajan pozitivan učinak, što upućuje na povećan interes potrošača u razdoblju neposredno nakon uvođenja ograničenja rada nedjeljom. Najizraženiji učinak zabilježen je kod Konzuma i Lidla, što je u skladu s njihovim tržišnim pozicijama. Razlike između specifikacije globalnog i zasebnog polinoma su male, što sugerira da je rezultat stabilan na promjenu polinomijalne strukture.

Tablica 1. RDiT procjene modela s prosječnim efektom za četiri maloprodajna lanca

Lanac	**Konzum**		**Lidl**		**Plodine**		**Spar**	
Model	(G)	(S)	(G)	(S)	(G)	(S)	(G)	(S)
Policy	5.40	5.16	3.42	3.8	2.65	2.67	3.33	3.37
p-vr.	<.01	<.01	0.037	0.013	<.01	<.01	<.01	<.01
Policy · t		-0.07		0.05		-0.02		-0.02
p-vr.		<.01		0.042		0.184		0.274
y_{t-1}	0.59	0.61	0.5	0.46	0.56	0.56	0.73	0.73
p-vr.	<.01	<.01	<.01	<.01	<.01	<.01	<.01	<.01
k	2	1	1	1	1	1	1	1
T	156	156	156	156	156	156	156	156
BIC	877.46	878.48	907.43	908.91	791.27	794.75	738.23	742.00

Bilješka: Stupci tablice prikazuju procjene modela za svaki maloprodajni lanac u dvije specifikacije: (G) globalni i (S) zasebni polinom. Svaki stupac procijenjen je prema jednadžbi (2) uz dodan pomak zavisne varijable (y_{t-1}) te sezonsku komponentu koja se sastoji od maksimalno triju Fourierovih parova. Optimalan red polinoma (k) i broj članova trigonometrijskih funkcija odabran je pomoću kriterija BIC. Broj podataka označen je s T. Korištene su standardne pogreške HAC.

Tablica 2. prikazuje rezultate modela u kojem se učinak politike promatra u tri faze nakon uvođenja ZoT-a. Dobiveni rezultati ukazuju da je u prvim mjesecima nakon uvođenja izmjena zakona došlo do najvećeg povećanja popularnosti pretraživanja, dok se u kasnijim razdobljima taj učinak postupno smanjuje i stabilizira. Kod većine lanaca učinak je statistički značajan u prvoj fazi, ali gubi na snazi u drugoj i trećoj, što upućuje na proces prilagodbe potrošača novom režimu rada. Ovi nalazi sugeriraju da je povećano informiranje bilo kratkotrajan fenomen, dominantno prisutan u početnom razdoblju nakon zakonskih izmjena. Iznimka ovom ponašanju je lanac Lidl, čija popularnost pretraživanja nastavlja dalje rasti.

Tablica 2. RDiT procjene modela s efektom u fazama za četiri maloprodajna lanca

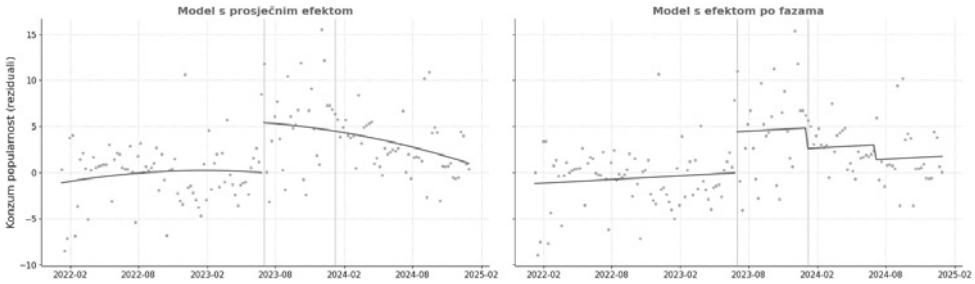
Lanac	**Konzum**		**Lidl**		**Plodine**		**Spar**	
Model	(G)	(S)	(G)	(S)	(G)	(S)	(G)	(S)
Policy 1	4.44	4.46	3.25	2.35	2.73	3.26	3.09	2.84
p-vr.	<.01	<.01	0.048	0.22	<.01	<.01	<.01	<.01
Policy 2	2.2	2.27	7.96	4.74	1.57	3.26	3.14	2.26
p-vr.	0.182	0.394	<.01	0.135	0.102	0.144	0.014	0.194
Policy 3	0.58	0.69	5.92	0.18	1.77	4.57	1.79	0.3
p-vr.	0.769	0.862	<.01	0.975	0.144	0.175	0.192	0.911
Policy · *t*		0		0.1		-0.05		0.02
p-vr.		0.974		0.253		0.373		0.521
y_{t-1}	0.61	0.61	0.40	0.37	0.56	0.55	0.70	0.70
p-vr.	<.01	<.01	<.01	<.01	<.01	<.01	<.01	<.01
k	1	1	1	1	1	1	1	1
T	156	156	156	156	156	156	156	156
BIC	882.25	887.29	908.28	911.32	799.77	803.96	745.29	749.97

Bilješka: Stupci tablice prikazuju procjene modela za svaki maloprodajni lanac u dvije specifikacije: (G) globalni i (S) zasebni polinom. Svaki stupac procijenjen je prema jednadžbi (2) uz dodan pomak zavisne varijable (y_{t-1}) te sezonsku komponentu koja se sastoji od maksimalno triju Fourierovih parova. Optimalan red polinoma (k) i broj članova trigonometrijskih funkcija odabran je pomoću kriterija BIC. Broj podataka označen je s T. Korištene su standardne pogreške HAC.

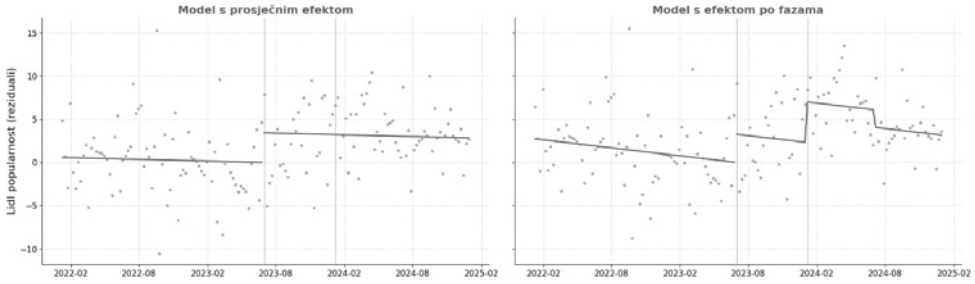
Slika 2. prikazuje reziduale modela RDiT za globalni polinom po maloprodajnim lancima za obje specifikacije (prosječni efekt i efekt po fazama). Dinamika procijenjenog polinoma te *policy* efekta ukazuje na smanjenje popularnosti pretraživanja indeksa SVI. Također, vidljivo je stepeničasto smanjenje u modelu koji efekt promatra u fazama. Iznimka u ponašanju je popularnost pretraživanja lanca Lidl.

Slika 2. Reziduali modela RDiT za globalni polinom s procijenjenim utjecajem izmjene ZoT-a

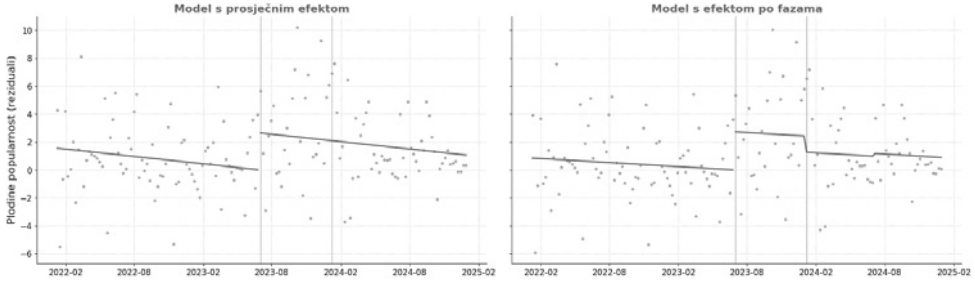
(a) Konzum



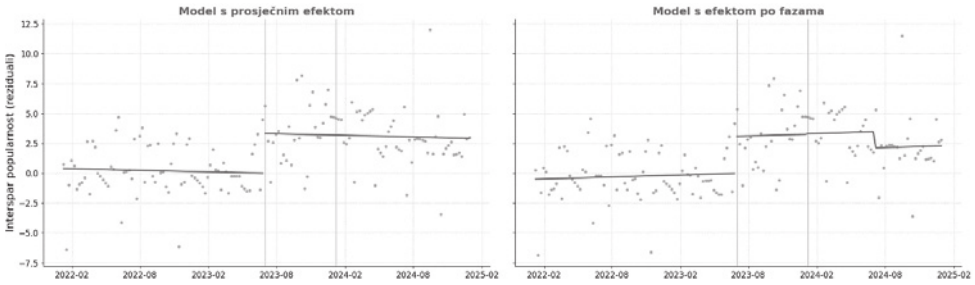
(b) Lidl



(c) Plodine



(d) Interspar



5. ZAKLJUČAK

Rezultati provedenog istraživanja pokazuju da je uvođenje neradne nedjelje u Hrvatskoj imalo mjerljiv, ali vremenski ograničen učinak na internetske pretrage povezane s najvećim maloprodajnim lancima. Analiza podataka Google Trendsa otkriva povećan interes potrošača neposredno nakon stupanja zakonske odredbe na snagu, što je vjerojatno odraz traženja informacija o radnim trgovinama i novom režimu rada. S vremenom, intenzitet pretraživanja smanjuje se, što sugerira da su se potrošači prilagodili novom rasporedu. Ovi rezultati potvrđuju korisnost platforme Google Trends kao dopunskog izvora podataka za praćenje reakcija potrošača na regulatorne promjene.

Dobiveni nalazi mogu se promatrati i u širem kontekstu promjena kupovnih navika potrošača nakon uvođenja neradne nedjelje. Smanjenje intenziteta pretraživanja tijekom vremena, zajedno s rezultatima ankete agencije Valicon iz veljače 2024. godine (Ja trgovac, 2024), upućuje na to da su potrošači postupno preraspodijelili kupovinu na ostale dane u tjednu, čime su smanjili potrebu za informiranjem o radnim trgovinama nedjeljom. Takav obrazac prilagodbe u skladu je i s makroekonomskim pokazateljima maloprodajnog sektora: prema podacima za 2024. godinu, realni promet u maloprodaji porastao je za 7,7 % na godišnjoj razini (Anić, 2025), što sugerira da se ukupni promet uspješno prelio na ostale dane u tjednu. Ipak, kvantitativna potvrda prelijevanja prometa po danima u tjednu zahtijevala bi dodatne podatke o dnevnim transakcijama u maloprodaji, što ostaje smjer za buduća istraživanja.

LITERATURA

1. Agencija za zaštitu tržišnog natjecanja. (2025). Istraživanje tržišta tiska za 2024. godinu. Zagreb: Agencija za zaštitu tržišnog natjecanja. Dostupno na: https://www.aztn.hr/ea/wp-content/uploads//2025/07/Trziste-tiska-RH-2024-rezultati-istrazivanja.pdf
2. Cebrián, E. i Domenech, J. (2024). Addressing google trends inconsistencies. *Technological Forecasting and Social Change*, 202, 123318, Dostupno na: https://doi.org/10.1016/j.techfore.2024.123318
3. Hölzl, J., Keusch, F. i Sajons, C. (2025). The (mis)use of Google Trends data in the social sciences: A systematic review, critique, and recommendations. *Social Science Research*, 118, 103099. https://doi.org/10.1016/j.ssresearch.2024.103099
4. Liu, K. (2024). The measurement errors of Google Trends data. Discover Data, 4(1). https://doi.org/10.1007/s44248-024-00013-3
5. Lolić, I., Matošec, M. i Sorić, P. (2024). DIY Google Trends indicators in social sciences: A methodological note. Technology in Society, 77, 102477. https://doi.org/10.1016/j.techsoc.2024.102477
6. Narodne novine (2023). Zakon o izmjenama i dopunama Zakona o trgovini. NN 33/2023.
7. Bento, A. I., Nguyen, T., Wing, C., Lozano-Rojas, F., Ahn, Y.-Y. i Simon, K. (2020). Evidence from internet search data shows information-seeking responses to news of local COVID-19 cases. Proceedings of the National Academy of Sciences, 117(21), 11220–11222. https://doi.org/10.1073/pnas.2005335117

8. Ghosh, A., Krishnan, N. C., Choudhury, S. i Basu, A. (2021). Can google trends search inform us about the population response and public health impact of abrupt change in alcohol policy? A case study from India during the covid-19 pandemic. International Journal of Drug Policy, 87, 102984. https://doi.org/10.1016/j.drugpo.2020.102984
9. Gelman, A., & Imbens, G. (2018). Why high-order polynomials should not be used in regression discontinuity designs. Journal of Business & Economic Statistics, 36(3), 447–456. https://doi.org/10.1080/07350015.2017.1366909
10. Boakye, E., Dzaye, O., Erhabor, J., Osuji, N., Obisesan, O., Osei, A. D., ... i Blaha, M. J. (2022). Impact of the Food and Drug Administration enforcement policy on flavored e-cigarettes on the online popularity of disposable e-cigarettes: analyses of Google search query data. BMC Public Health, 22(1), 1937. https://doi.org/10.1186/s12889-022-14367-3
11. Tportal.hr (2024). Gužve nedjeljom u trgovinama – komocija kupaca ili loš zakon? https://www.tportal.hr/biznis/clanak/guzve-nedjeljom-u-trgovinama-komocija-kupaca-ili-los-zakon-20240109

POTPORA

Ovaj članak financiran je sredstvima Europske unije – NextGenerationEU u okviru Poziva IIP-581-2025.

DODATAK A. Odabir indikatora na platformi Google Trends moguće je koristiti na dva osnovna načina, putem opcija *Trending Now* i *Explore*. Opcija *Trending Now* prikazuje trenutačno najpopularnije pretraživane pojmove za odabranu državu i razdoblje, dok *Explore* omogućuje detaljniji prikaz povijesne dinamike pretraživanja za odabrani pojam, uz mogućnost usporedbe više pojmova tijekom duljeg razdoblja.

Opcija *Explore* prikazuje dinamiku pretraživanja za pojam napisan točno na taj način. Na primjer, ako korisnik upiše pojam [trgovina], te označi za razdoblje zadnjih pet godina i državu Hrvatsku, GT prikazuje popularnost pretraživanja za pojmom trgovina u zadnjih pet godina u Hrvatskoj. No, ako korisnik prilikom unosa pojma pogriješi, primjerice upiše [tgovina], Google Trends će prikazati rezultate samo za tu pogrešno napisanu riječ. Sustav neće automatski uključiti pojmove sličnog značenja, druge padeže ili pravopisne varijante pojma trgovina. Takav doslovan način pretraživanja, bez obuhvata padežnih oblika i sinonima, naziva se pretraživanje Pojma (engl. *Term*).

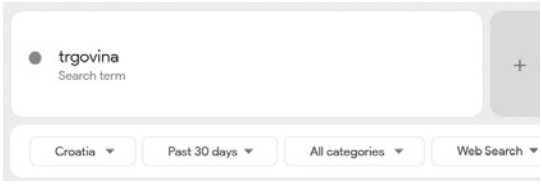
Platforma GT omogućuje preuzimanje podataka za tri tipa indikatora: Pojam, Tema (engl. *Topic*) i Kategorija (engl. *Category*). Opcija Pojam prikazuje popularnost točno unesenog izraza, bez obuhvata varijacija ili sinonima. Opcija Tema prikazuje popularnost šire teme, uključujući sve oblike riječi, tipfelere i pojmove sličnog značenja koje Google automatski klasificira pomoću svog algoritma. Tema opcije prikazuju se u padajućem izborniku nakon unosa pojma, kako je prikazano na Slici 1. panel (b). Opcija Kategorija omogućuje fokusiranje analize na određeno područje interesa (npr. maloprodaja, turizam, financije), čime se filtriraju nerelevantni rezultati. Platforma GT sve upite klasificira i agregira prema hijerarhijskom sustavu kategorija. Rezultatima za opciju Kategorije mo-

guće je pristupiti tako da se ostavi polje za pojam prazno i odabere kategorija, kako je prikazano na Slici 1. (c).

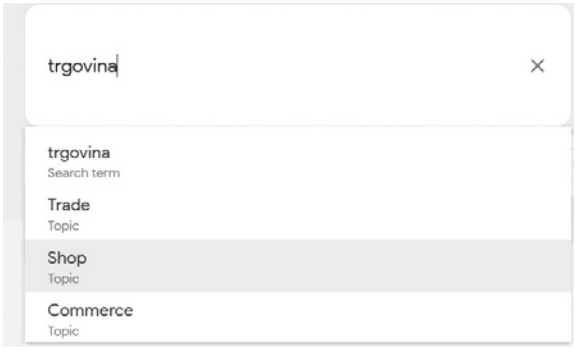
Primjerice, Pojam [trgovina] prikazuje popularnost te riječi doslovno kako je unesena, dok odabir Teme [Shop] iz padajućeg izbornika prikazuje ukupnu popularnost pretraživanja povezanih s pojmom trgovina, uključujući padežne oblike i sinonime poput dućan ili prodavaonica. Budući da je Google Trends izvorno razvijen na engleskom jeziku, najpreciznij odabir Teme moguć je kada je sučelje postavljeno na engleski jezik. Na taj način moguće je jasnije razlikovati značenja koja u hrvatskom jeziku dijeli riječ trgovina – primjerice *commerce* (trgovina kao djelatnost) i *shop* (trgovina kao objekt u kojem se prodaja odvija).

Slika 1. Usporedni prikaz odabira Pojma, Teme te Kategorije za pojam [trgovina]

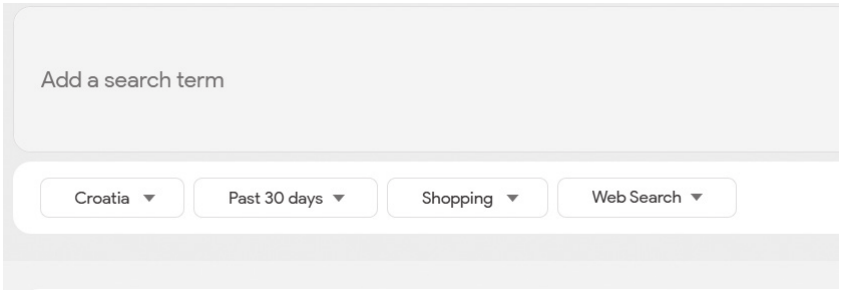
(a) Pretraživanje Pojma



(b) Pretraživanje Teme



(c) Pretraživanje Kategorije



Izvor: Google Trends