

UČINCI GEOPOLITIČKOG RIZIKA NA KRATKOROČNU I DUGOROČNU VOLATILNOST IZRANJAJUĆIH DIONIČKIH TRŽIŠTA

Josip ARNERIĆ

Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb, Hrvatska

UDK: 336.76:327

Izvorni znanstveni rad

Primljeno: 8. siječnja 2026.

U radu se analizira uloga geopolitičkog rizika (GPR) kao egzogene varijable u objašnjavanju volatilnosti srednjoeuropskih dioničkih tržišta u razvoju, s ciljem ispitivanja odražavaju li se razlike u percepciji globalnoga geopolitičkog rizika među investitorima u heterogenim učincima na tržištima koja su plića i manje likvidna, pa stoga osjetljivija na ratove, međunarodne sukobe i političke tenzije. Polazeći od ograničenja standardnih jednofrekventnih GARCH modela, u radu je primijenjen GARCH-MIDAS pristup, koji omogućuje razdvajanje kratkoročne i dugoročne volatilnosti povezane s geopolitičkim šokovima opaženima pri nižim frekvencijama. Komplementarno se rabi i GARCH-X model, kako bi se ispitao neposredan učinak dnevnoga GPR indeksa na kratkoročnu volatilnost. Rezultati pokazuju da je kratkoročni učinak geopolitičkog rizika ograničen ili statistički neznatajan, dok mjesečni GPR djeluje kao snažan pokretač dugoročne volatilnosti na poljskom, češkom i rumunjskom tržištu, slabijeg intenziteta na hrvatskom i bugarskom tržištu, a na mađarskom tržištu djeluje suprotno. Implikacije istraživanja relevantne su institucionalnim investitorima za učinkovitije upravljanje rizikom na raznim investicijskim horizontima, kao i nositeljima ekonomskih politika za pravodobno ublažavanje geopolitičkih šokova na promatranim tržištima.

Ključne riječi: GARCH-MIDAS, GARCH-X, geopolitički rizik, izranjajuća dionička tržišta, volatilnost



Josip Arnerić, Ekonomski fakultet Sveučilišta u Zagrebu, Trg J. F. Kennedyja 6, 10000 Zagreb.
E-mail: jarneric@net.efzg.hr

Geopolitički rizik smatra se jednim od ključnih čimbenika koji utječu na volatilnost tržišta dionica (Zhang i sur., 2023). Događaji poput ratnih sukoba, terorističkih napada i međunarodnih političkih napetosti narušavaju povjerenje investitora te uzrokuju panično ponašanje obilježeno nesigurnošću i neuobičajenim obrascima trgovanja, što u konačnici dovodi do povećane volatilnosti na financijskim tržištima (Salisu i sur., 2022). U tom je kontekstu ključna operacionalizacija geopolitičkog rizika indeksom GPR, koji kvantificira učestalost i intenzitet geopolitičkih prijetnji, eskalacija i realiziranih konflikata u medijskim izvorima, čime se geopolitika pretvara u egzogenu varijablu pogodnu za empirijsko modeliranje volatilnosti i prinoša (Caldara i Iacoviello, 2022). Takav pristup otvorio je prostor mnogim radovima koji terorizam, rat i srodne šokove tretiraju determinantama tržišnog rizika, bilo kroz promjene uvjetne volatilnosti (engl. *conditional volatility*), efekte zaraze (engl. *contagion*) ili prelijevanja volatilnosti (engl. *volatility spillover*), pri čemu se naglašava heterogenost reakcija između raznih zemalja, sektora ili vrsta imovine (Essaddam i Karagianis, 2014; Zhang i sur., 2023; Msomi i Kunjal, 2024). Geopolitički rizik (GPR) klasificira se kao sistemski rizik koji se ne može diverzificirati, a njegovo povećanje uzrokuje odgađanje investicijskih odluka i potiče preraspodjelu kapitala s tržišta višeg rizika prema sigurnijim ulaganjima, čime se dodatno intenzivira volatilnost, osobito u kratkom i srednjem roku u vremenu vojnih sukoba (He, 2023). Empirijska istraživanja dosljedno potvrđuju da rast geopolitičkog rizika dovodi do povećanja volatilnosti (Zhang i sur., 2023), osobito u kratkom roku, zbog trenutačnih i snažnih reakcija tržišta, pri čemu energetski sektor pokazuje veću osjetljivost na geopolitičke šokove od drugih sektora (Umar i sur., 2023; Segnon i sur., 2024). Nasuprot tome, oskudna literatura otkriva da prediktivna sposobnost geopolitičkog rizika u objašnjenju volatilnosti tržišta dionica opada s dužim investicijskim horizontom (Yang i sur., 2021) ili pak ne rezultira značajnim poboljšanjem točnosti prognoza (Segnon i sur., 2024). Unatoč fragmentiranim nalazima, doprinos geopolitičkog rizika dugoročnoj volatilnosti tržišta dionica i dalje je otvoreno istraživačko pitanje. Stoga se u ovom radu GPR indeks uzima kao egzogena varijabla za mjerenje geopolitičke neizvjesnosti u dvjema vremenskim frekvencijama. Na dnevnoj razini GPR se promatra kao kratkoročni (visokofrekventni) čimbenik dnevne volatilnosti uz pomoć GARCH-X pristupa (engl. *Generalized Autoregressive Conditional Heteroscedasticity-X*), pri čemu X označava egzogenu varijablu uključenu u jednadžbu uvjetne varijance. Paralelno, na mjesečnoj razini, utvrđuje se doprinos GPR-a dugoročnoj (niskofrekventnoj) volatilnosti primjenom GARCH-MIDAS pristupa (engl. *Generalized Autoregressive Conditional He-*

teroscedasticity – Mixed Data Sampling). Takav dvostruki metodološki pristup omogućuje razlučivanje učinaka geopolitičkog rizika na kratkoročnu i dugoročnu volatilnost dioničkih prinosa te predstavlja znanstveni doprinos rada, jer prema dostupnoj literaturi kombinirana upotreba modela GARCH-X i GARCH-MIDAS s indeksom GPR dosad nije bila zastupljena na izranjajućim tržištima Europe. Primjerenost GARCH metodologije opravdava se sposobnošću zahvaćanja empirijskih svojstava dnevnih prinosa, uključujući grupiranje volatilnosti, vremenski promjenjivu varijancu (uvjetnu heteroskedastičnost) i njezinu visoku perzistentnost (dugu memoriju). U svim procijenjenim modelima asimetrična reakcija na pozitivne i negativne šokove modelirana je GJR specifikacijom, dok se fenomen teških repova (engl. *heavy tails*) distribucije prinosa adekvatno opisuje primjenom Studentove *t*-distribucije. Obuhvat podataka od početka 2021. do kraja 2025. godine adekvatan je za ovo istraživanje, jer su, nakon pandemij-skog oporavka, snažan rast inflacije, eskalacije geopolitičkih sukoba, energetske šokovi i međunarodne trgovinske sankcije doveli do pojačane osjetljivosti investitora na političke i sigurnosne događaje izazvane ratom u Ukrajini, sankcijama prema Rusiji, energetsom krizom u Europi, trgovinskim napestostima između SAD-a i Kine te sukobima na Bliskom istoku. Za razliku od tradicionalnih GARCH specifikacija, koje često podcjenjuju volatilnost i suočavaju se sa sporim vraćanjem volatilnosti na ravnotežnu razinu (Fang i Han, 2025), one dominiraju literaturom, dok su GARCH-X i GARCH-MIDAS rjeđe zastupljeni, iako omogućuju precizniju identifikaciju reakcija kratkoročne i dugoročne volatilnosti dioničkih tržišta u razvoju (Hansen i sur., 2011) na ratna zbivanja i ekstremne šokove, što je osobito važno u razdoblju značajne geopolitičke nesigurnosti koje se upravo i istražuje, čime ovaj rad pridonosi proširenju postojećega korpusa empirijskih spoznaja. Budući da je osnovni cilj ispitati reagiraju li izranjajuća tržišta podjednako na isti egzogeni geopolitički šok, metodološki je opravdano primijeniti globalni GPR indeks, jer su geopolitički događaji i prijetnje u promatranom razdoblju bili globalno i regionalno medijski zastupljeni, čime se osigurava dosljedno praćenje geopolitičkog rizika kroz vrijeme te usporedivost rezultata među tržištima. Iako Caldara i Iacoviello (2022) nude pokazatelje geopolitičkog rizika specifične za pojedine zemlje (engl. *country-specific GPR*), oni su dostupni samo za dva od šest analiziranih tržišta, i to na mjesečnoj razini. Pritom nije riječ o šokovima identificiranim iz domaćih medijskih izvora, nego o udjelu članaka iz istog, premda ograničenog, korpusa vodećih međunarodnih novina na engleskom jeziku koji se odnose na pojedinu zemlju. Stoga učinci geopolitičkih rizika specifičnih za pojedine zemlje nisu analizirani,

što je ograničenje ovog rada, dok s druge strane globalni GPR indeks omogućuje ispitivanje odražavaju li se razlike u percepciji globalnoga geopolitičkog rizika u heterogenim učincima među tržištima, što je u skladu s nalazima Bondarenko i sur. (2024), koji pokazuju da geopolitički rizik nije univerzalno percipiran.

Ostatak rada strukturiran je kako slijedi. Pregledom literature, u drugom se poglavlju sintetiziraju dosadašnje spoznaje iz prethodnih studija, koje se kritički analiziraju da bi se utvrdio istraživački jaz. U trećem poglavlju opisuju se metodologija istraživanja i podaci, uz obrazloženje njihove primjerenosti. U četvrtom poglavlju iznose se i analiziraju empirijski rezultati, dok se u posljednjem poglavlju donosi zaključak rada.

PRETHODNE STUDIJE

Dosadašnje spoznaje upućuju na zaključak da političke tenzije i geopolitički rizici tijekom ratnih razdoblja, poput sukoba između Rusije i Ukrajine, dovode do ubrzanog rasta ne samo volatilnosti dionica vojno-industrijskoga sektora (Izzeldin i sur., 2023; Liang i sur., 2024; Neto, 2025) nego i volatilnosti dionica robnoga i energetskega sektora, osobito nafte i plina (Liu i sur., 2019; Liu i sur., 2021). Recentna istraživanja pokazuju da geopolitički šokovi utječu i na prelijevanje volatilnosti unutar energetskih tržišta (Liu i sur., 2024; Xie i sur., 2025), koja često reagiraju snažnije od dioničkih tržišta, osobito u kratkom i srednjem roku (Le i sur., 2024). Dokumentirano je i da terorizam u Europi statistički značajno povećava volatilnost tržišta kapitala, posebice kada uključuje bombaške napade (Gurdgiev i sur., 2022; Corbet i sur., 2018; Ahmad i sur. 2022). U Europi je učinak rusko-ukrajinskog rata izraženiji u državama s jačim gospodarskim i energetskekim vezama s Rusijom, pri čemu se razlike među tržištima ne mogu objasniti samo geografskom blizinom (Ahmed i sur., 2023) kao što su Poljska, Češka, i Mađarska, dok npr. Norveška, zahvaljujući vlastitim rezervama nafte i plina, osjeća znatno slabiji utjecaj. Nadalje, obrambena industrija (engl. *defence industry*) zauzima jedinstven položaj, jer može profitirati od povećane vojne potrošnje, za razliku od ostalih sektora. Ovakva sektorska divergencija potvrđena je empirijskom analizom prinosa ETF-ova (engl. *Exchange Traded Funds*) u razdoblju rata između Izraela i Hamasa te je u skladu s nalazima iz ranijih sukoba, pri čemu su izraelske vojne tvrtke profitirale, dok su ostali sektori bilježili negativne učinke (Klomp, 2025).

Empirijske analize rusko-ukrajinskog rata pokazuju da je riječ o događaju s globalnim financijskim implikacijama, pri čemu se povećanje volatilnosti i promjene tržišnih režima ne manifestiraju jednako na svim tržištima, već ovise o izloženosti, strukturi tržišta i investicijskim kanalima (Izzeldin i sur., 2023). Povećan oprez i pažnja investitora tijekom invazije na Ukra-

jinu upućuju na to da tržišne reakcije nisu samo funkcija fundamenta nego i investicijskoga sentimenta te brzine prilagodbe investicijskih očekivanja (Halousková i sur., 2022), što implicira da informacijski signali povezani s ratom djeluju kao egzogeni prediktor koji može poboljšati prognostičku točnost u predviđanju volatilnosti (Liang i sur., 2024).

Posebno bogat segment literature usmjeren je na dionice obrambenih kompanija, gdje geopolitička eskalacija ima dvostruku prirodu: s jedne strane podiže opći rizik i volatilnost, a s druge može povećati očekivanja budućih prihoda zbog rasta vojnih izdataka, pa prinosi ponekad mogu biti pozitivni. Na globalnoj razini, geopolitički rizik utječe i na prinose i na njihovu volatilnost, što se tumači kao refleksija nove utrke u naoružanju (Zhang i sur., 2022). U ratnim i konfliktnim razdobljima mijenjaju se portfeljne alokacije i obrasci potražnje za obrambenim dionicama, s implikacijama za premiju rizika i dinamiku cijena (Klein, 2024), pa čak i ekstremne iznadprosječne prinose (Neto, 2025).

Dio literature dodatno proširuje ovaj okvir uključivanjem drugih izvora nesigurnosti, poput ekonomsko-političke neizvjesnosti i klimatskih rizika, koji se također pokazuju relevantnima u objašnjavanju volatilnosti financijskih tržišta. Klimatska i regulatorna nesigurnost mogu djelovati komplementarno s geopolitičkim rizikom, dodatno pojačavajući volatilnost prinosa, osobito na robnim tržištima fosilnih goriva (Ayinde i Adeyemi, 2023; Prasad i sur., 2025; Lasisi i sur., 2025). Paralelno s geopolitikom i ratom, terorizam se u literaturi isto javlja kao specifičan oblik egzogenog šoka. Komparativne analize razvijenih tržišta i tržišta u razvoju pokazuju da teroristički napadi utječu na burzovne performanse i volatilnost, pri čemu su reakcije često izraženije ondje gdje su tržišta plića i institucionalni amortizeri slabiji (Ahmad i sur., 2022), odnosno ovise o specifičnostima zemlje, poput strukture tržišta i institucionalne razvijenosti (Essaddam i Karagianis, 2014; Corbet i sur., 2018).

U metodološkom smislu, dobar dio literature analizira odnos između geopolitičkog rizika i volatilnosti dioničkih tržišta primjenom standardnih GARCH modela, panel-GARCH modela, VAR-ova (vektorski autoregresijski modeli) te modela u domeni vremenskih frekvencija, poput valne koherencije (engl. *wavelet coherence*), te dosljedno potvrđuje da geopolitički rizik povećava volatilnost dioničkih tržišta, iako pri tom ne razlikuje kratkoročnu i dugoročnu komponentu volatilnosti (Bouras i sur., 2018; Umar i sur., 2023; Zhang i sur., 2023). Stoga se nameće metodološko pitanje: kako integrirati informacije različitih frekvencija i različitih tipova nesigurnosti u jedinstven okvir. U tom se kontekstu ističe GARCH-MIDAS pristup, koji uvjetnu volatilnost dekomponira na kratkoročnu

(tipičnu za GARCH dinamiku dnevnih prinosa) i dugoročnu komponentu, koju objašnjavaju egzogene varijable poput GPR ili EPU indeksa (indeks ekonomsko-političke nesigurnosti), koje su često dostupne samo pri nižim frekvencijama. Upravo zato GARCH-MIDAS uspijeva povezati visokofrekventnu volatilitnost prinosa s niskofrekventnim indeksima nesigurnosti. U kontekstu izranjajućih tržišta, geopolitički rizik uključuje se kao MIDAS varijabla i pokazuje se relevantnim pokretačem dugoročne komponente volatilitnosti dioničkih prinosa, čime se poboljšava prognoziranje volatilitnosti u odnosu na jednofrekventne pristupe (Salisu i sur., 2022), kao i izvan standardnih dioničkih i robnih tržišta (Lu i sur., 2024). GARCH-MIDAS rabi se i za sektorski diferencirane učinke EPU na volatilitnost (Mso-mi i Kunjal, 2024; Nortey i sur., 2024). Na tržištima robe i energije, GARCH-MIDAS primjenjuje se i za povezivanje klimatskih varijabli s volatilnošću roba (Lasisi i sur., 2025) te za povezivanje naftnih šokova ponude i klimatskog rizika (Ayinde i Adeyemi, 2023). Zajednički nazivnik ovih primjena jest da se nesigurnosti tretiraju kao spori faktori koji oblikuju dugoročni rizik, dok se tržišna mikrodinamika i reakcije na vijesti hvataju kratkoročnom GARCH komponentom. Dio literature prelazi okvire univarijatnoga pristupa, ponajprije kada je cilj modelirati međutržišnu povezanost. Primjerice, DCC-MIDAS-X pristup proširuje fokus na korelirane volatilitnosti, omogućujući da geopolitički rizici utječu i na varijancu i na dinamičku uvjetnu korelaciju (engl. *Dynamic Conditional Correlation*) između tržišta, što je važno za diversifikaciju i sistemski rizik (Liu i sur., 2024).

Integrirano gledano, literatura pokazuje da razne nesigurnosti utječu na volatilitnost raznih tipova imovine kroz specifične mehanizme. Geopolitički rizik, rat i konflikti obično povećavaju volatilitnost i intenziviraju korelacije među globalnim tržištima (Izzeldin i sur., 2023), dok obrambeni sektor pritom može ostvariti koristi zbog pozitivnih prinosa, ovisno o očekivanjima vojnih izdataka i ponašanju investitora (Gurdgiev i sur., 2022; Zhang i sur., 2022; Klein, 2024; Neto, 2025; Klomp, 2025; Gheorghe i Panazan, 2024). Terorizam se javlja kao šok koji također povećava volatilitnost, ali je učinak snažno uvjetovan institucionalnim i tržišnim razvojem zemlje (Ahmad i sur., 2022; Corbet i sur., 2018; Essaddam i Karagianis, 2014). Energetska tržišta pokazuju visoku osjetljivost na geopolitiku kroz opskrbe kanale (Liu i sur., 2019; Liu i sur., 2021), a noviji pristupi proširuju fokus na korelacije i efekte prelijevanja volatilitnosti (Liu i sur., 2024; Xie i sur., 2025). Klimatski rizik i klimatsko-politička nesigurnost postaju sve važnije odrednice volatilitnosti roba, često zajedno s geopolitičkim faktorima (Ayinde i Adeyemi, 2023; Lasisi i sur., 2025; Prasad i sur., 2025). U toj se raznolikosti GARCH-MIDAS metodologija ističe kao primjeren

pristup kada je cilj istraživanja razdvojiti kratkoročne tržišne fluktuacije od dugoročnih fluktuacija koje uzrokuju indeksi nesigurnosti (Salisu i sur., 2022; Lu i sur., 2024; Msomi i Kunjal, 2024; Nortey i sur., 2024; Le i sur., 2024). Međutim, nedostatak navedenih studija jest to što se GPR, kao izvor sistemskog rizika, promatra isključivo kao egzogena varijabla u jednadžbi dugoročne volatilnosti, uz obrazloženje da je indeks dostupan samo na nižim frekvencijama (najčešće mjesečna opažanja). Ipak, kako kažu autori Caldara i Iacoviello (2022), globalni indeks GPR dostupan je i na dnevnoj razini, što omogućuje utvrđivanje njegova kratkoročnog utjecaja na volatilnost GARCH-X pristupom, što je osobito važno za izranjajuća tržišta koja su plića i manje likvidna u odnosu na razvijena tržišta, pa se zbog većih špekulativnih mogućnosti i slabije institucionalne razvijenosti geopolitički šokovi na njima snažnije i brže mogu odraziti. Stoga se znanstveni doprinos ogleda u kombiniranoj primjeni modela GARCH-X i GARCH-MIDAS s indeksom GPR na šest europskih izranjajućih financijskih tržišta, uključujući Hrvatsku, Češku, Mađarsku, Poljsku, Rumunjsku i Bugarsku. GARCH-X, kao komplementaran pristup GARCH-MIDAS pristupu, omogućuje provjeru postoji li zaseban kratkoročni kanal djelovanja i u kojoj je mjeri uvjetovan tržišnim karakteristikama. Oba modela nisu izložena problemu preklopljenih informacija, jer se dnevni i mjesečni GPR ne uključuju unutar istoga modela, a ključno je da služe identifikaciji učinaka geopolitičkog rizika na raznim vremenskim horizontima. Kratkoročni učinci GPR-a na volatilnost važni su za svakodnevno upravljanje tržišnim rizikom, prilagodbu kratkoročnih strategija zaštite i donošenje investicijskih odluka u uvjetima naglih i iznenadnih geopolitičkih šokova, dok su dugoročni učinci važni za dugoročno pozicioniranje, stratešku alokaciju imovine i razumijevanje utjecaja geopolitičkog rizika na stabilnost financijskih tržišta.

METODOLOGIJA I PODACI

Standardni GARCH model rabi se za modeliranje i predviđanje uvjetne volatilnosti financijskih vremenskih nizova te polazi od pretpostavke da je volatilnost vremenski promjenjiva i uvjetovana informacija iz prošlosti. Osim fenomena uvjetne heteroskedastičnosti, GARCH model dobro obuhvaća perzistentnost i klasteriranje volatilnosti, jer se razdoblja visoke i niske volatilnosti grupiraju u skupinama. GARCH(p,q) model, koji je razvio Bollerslev (1986), proširenje je ARCH(p) modela, koji je prvi uveo Engle (1982), čime je omogućeno parsimonijsko i učinkovitije modeliranje varijance, odnosno standardne devijacije prinosa (volatilnosti). U empirijskim istraživanjima najčešće se primjenjuje GARCH(1,1) specifikacija, jer

su vremenski pomaci $p = 1$ i $q = 1$ dovoljni za postizanje zadovoljavajuće prilagodbe podacima:

$$\begin{aligned} r_t &= \ln(p_t) - \ln(p_{t-1}) = \Delta \ln p_t \\ r_t &= \mu + \varepsilon_t, \varepsilon_t \sim N(0, \sigma_t^2) \\ \sigma_t^2 &= \omega + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \end{aligned} \quad (1)$$

U zapisu (1) prva formula pokazuje kako se dnevni prinos r_t izračunava kao prva diferencija logaritmiranih cijena, čime se izražava relativna promjena današnje cijene p_t u odnosu na cijenu prethodnog dana p_{t-1} . Uobičajeno je uzimati zaključne cijene (engl. *closing prices*), jer odražavaju vrijednost imovine nakon cjelodnevnoga trgovanja i promatraju se neposredno prije zatvaranja burze, kada su likvidnost i trgovinska aktivnost najveće. U drugoj jednadžbi zapisa (1) opisano je kako je prinos zbroj prosječnoga (očekivanog) prinosa μ i pogreške relacije ε_t (neočekivanog prinosa). Kada je očekivani prinos μ konstantan, neočekivani prinosi ε_t , tzv. inovacijski članovi, nezavisni su i jednako distribuirani centrirani prinosi sa sredinom nula, uz pretpostavku normalne, tj. Gaussove distribucije. Međutim, inovacijski članovi ε_t nemaju konstantnu varijancu, jer je ona uvjetovana informacijama iz prethodnog razdoblja. Zato se uvjetna varijanca σ_t^2 u trećoj jednadžbi zapisa (1) definira kao funkcija prošloga inovacijskog člana (ARCH učinak) i prošle uvjetne varijance (GARCH učinak), pri čemu je zbroj koeficijenata $\alpha + \beta$ manji od jedan, kako bi se osigurala stacionarnost i konvergencija dugoročnoj varijanci. GARCH(1,1) model u zapisu (1) može se modificirati uzimanjem u obzir Studentove t -distribucije inovacija, dodavanjem asimetrije informacija i GPR indeksa kao egzogenog šoka u jednadžbi uvjetne varijance:

$$\begin{aligned} r_t &= \mu + \varepsilon_t, \varepsilon_t \sim t_{df} \\ \sigma_t^2 &= \omega + \alpha \varepsilon_{t-1}^2 + \gamma \varepsilon_{t-1}^2 I(\varepsilon_{t-1} < 0) + \beta \sigma_{t-1}^2 + \lambda GPR_{t-1}^d \end{aligned} \quad (2)$$

Primjena Studentove t -distribucije prikladnija je od normalne distribucije, jer se bolje prilagođava teškim repovima. Težina repova kontrolirana je stupnjevima slobode df (engl. *degrees of freedom*), koji određuju oblik Studentove t -distribucije. Manji stupnjevi slobode upućuju na teže, odnosno izraženije, debele repove i veću vjerojatnost pojave ekstremnih vrijednosti. U jednadžbi uvjetne varijance parametar γ predstavlja asimetrični učinak prošlih informacija na volatilnost, pri čemu je $I(\varepsilon_{t-1} < 0)$ indikator funkcija koja poprima vrijednost 1 ako je šok negativan, a u suprotnom slučaju vrijednost 0. Očekuje se $\gamma > 0$ kao potvrda da loše vijesti više utječu na volatilnost (zbroj koeficijenata $\alpha + \gamma$) nego dobre vijesti (samo koeficijent α). Taj asimetrični učinak informacija naziva se i efektom poluge (engl. *leverage effect*). Efekt poluge znači da negativne vijesti na tržištu kapitala snižavaju cijene dionica,

čime se u kratkom roku povećava financijska poluga poduzeća (omjer duga i kapitala), što posljedično dovodi do veće volatilnosti promatrane dionice. Asimetrična specifikacija GARCH(1,1) modela prema autorima Glosten, Jagannathan i Runkle (1993) u literaturi se označava kraticom GJR i najčešće je zastupljena zbog jednostavne interpretacije, premda postoje i druge specifikacije (primjerice, EGARCH, APARCH i dr.). Nadalje, uključivanje egzogenog šoka kao dodatne eksplanatorne varijable u jednadžbu uvjetne varijance zahtijeva da je indeks geopolitičkog rizika GPR mjerljiv na istoj (dnevnoj) frekvenciji kao i volatilnost. Dnevni indeks GPR s jednim vremenskim pomakom GPR_{t-1}^d uzima se u obzir jer se pretpostavlja da geopolitički šokovi vremenski prethode promjenama volatilnosti. GJR-GARCH model s dodatnom egzogenom varijablom u jednadžbi uvjetne varijance objedinjeno se označava kraticom GJR-GARCH-X. To je upravo model u zapisu (2), u kojem se očekuje pozitivan i statistički značajan koeficijent λ u potvrđivanju utjecaja geopolitičkog rizika na kratkoročnu volatilnost dioničkih prinosa. Kao ulazni podaci uzimaju se centrirani prinosi $(r_t - \mu)$, stoga je potrebno procijeniti ukupno šest parametara, od čega je pet parametara $(\omega, \alpha, \beta, \gamma, \lambda)$ u modelu GJR-GARCH-X:

$$\sigma_t^2 = \omega + \alpha(r_{t-1} - \mu)^2 + \gamma(r_{t-1} - \mu)^2 I((r_{t-1} - \mu)^2 < 0) + \beta\sigma_{t-1}^2 + \lambda GPR_{t-1}^d, \quad (3)$$

i dodatni parametar t -distribucije (df). Za razliku od GJR-GARCH-X modela, GJR-GARCH-MIDAS omogućuje razdvajanje kratkoročne i dugoročne komponente volatilnosti te eksplicitno modelira utjecaj geopolitičkog rizika na dugoročnu volatilnost, pri čemu je GPR mjerljiv na nižoj (mjesečnoj ili kvartalnoj) frekvenciji. Standardni GARCH modeli tretiraju inovacijske članove ε_t kao umnožak standardiziranoga šoka z_t i uvjetne standardne devijacije σ_t , što proizlazi iz pretpostavke da su standardizirani inovacijski članovi nezavisno i jednako distribuirani:

$$\varepsilon_t = z_t \sqrt{\sigma_t^2}, \quad z_t = (r_t - \mu) / \sigma_t \sim i.i.d.(0, \sigma_\varepsilon^2) \quad (4)$$

Ključna karakteristika GARCH-MIDAS modela jest multiplikativna dekompozicija uvjetne varijance na kratkoročnu komponentu (g_t) i dugoročnu komponentu (τ_t), uz uključivanje mjesečnoga GPR indeksa kao MIDAS varijable u jednadžbu dugoročne volatilnosti:

$$\begin{aligned} \varepsilon_t &= r_t - \mu = z_t \sqrt{(g_t \tau_t)} \\ g_t &= (1 - \alpha - \beta - \gamma / 2) + (\alpha + \gamma I(\varepsilon_{t-1} < 0))((\varepsilon_{t-1}^2) / \tau_{t-1}) + \\ &\quad + \beta g_{t-1} \\ \ln(\tau_t) &= \phi + \psi \sum_{j=1}^k w_j GPR_{t-j}^m \end{aligned} \quad (5)$$

Prema autorima Ghysels i sur. (2006), kratkoročna (visokofrekventna) komponenta volatilnosti slijedi standardnu

GJR-GARCH(1,1) specifikaciju, pri čemu normalizacija ε_{t-1}^2 s τ_{t-1} osigurava da kratkoročna GARCH komponenta oscilira oko prosječne vrijednosti 1, dok dugoročna volatilnost ostaje sadržana isključivo u MIDAS komponenti, tj. kratkoročna je komponenta samo privremeno odstupanje od dugoročne komponente. Dugoročna (niskofrekventna) komponenta volatilnosti modelira se uz pomoć MIDAS regresije, pri čemu je egzogena varijabla ponderirani prosjek mjesečnog indeksa geopolitičkog rizika GPR_{t-j}^m s vremenskim pomacima $j = 1, 2, \dots, k$. Log-linearna specifikacija MIDAS regresije osigurava pozitivnost dugoročne varijance, dok se prethodne vrijednosti mjesečnog indeksa geopolitičkog rizika najčešće ponderiraju beta-funkcijom:

$$w_j(\theta_1, \theta_2) = ((j/k)^{\theta_1-1} (1-j/k)^{\theta_2-1}) / \sum_{j=1}^k ((j/k)^{\theta_1-1} (1-j/k)^{\theta_2-1}) \quad (6)$$

Beta-funkcija pridružuje odgovarajući ponder svakoj prethodnoj vrijednosti, ovisno o broju vremenskih pomaka k i parametrima θ_1 i θ_2 . Najčešće se primjenjuje pojednostavljeni oblik beta-funkcije s unaprijed postavljenom vrijednosti drugoga parametra $\theta_2 = 1$. Time ponderi, čiji je zbroj uvijek jedan, ovise isključivo o prvom parametru θ_1 :

$$w_j(\theta_1) = ((j/k)^{\theta_1-1} / \sum_{j=1}^k ((j/k)^{\theta_1-1}); w_j \geq 0; \sum_{j=1}^k w_j = 1; \theta_1 \geq 1 \quad (7)$$

U specifičnom slučaju, kada je $\theta_1 = 1$, svim prethodnim vrijednostima GPR_{t-j}^m pridružuje se jednak ponder $1/k$. Što je vrijednost parametra θ_1 veća, veće se težine dodjeljuju novijim opažanjima, a manje starijim. Uz pojednostavljeni oblik beta-funkcije, GJR-GARCH-MIDAS zahtijeva procjenu sedam parametara, uključujući i stupnjeve slobode ($\alpha, \beta, \gamma, \phi, \psi, \theta_1$ i df), primjenom metode kvazi-najveće vjerodostojnosti QMLE (engl. *Quasi-Maximum Likelihood Estimates*), jer ona daje konzistentne i asimptotski normalne procjene. Pozitivan i statistički značajan koeficijent ψ potvrđuje doprinos geopolitičkog rizika dugoročnoj volatilnosti dioničkih prinosa. Zaključno, GARCH-MIDAS model promatra volatilnost kao rezultat interakcije kratkoročnih (brzih) tržišnih šokova i dugoročne razine rizika, što ga čini pogodnim za analizu volatilnosti na raznim vremenskim horizontima u uvjetima nesigurnosti (Salisu i sur., 2022, Prasad i sur., 2025), a glavna mu je prednost povezivanje visokofrekventne (dnevne) volatilnosti s niskofrekventnim (mjesečnim) indeksom geopolitičkog rizika. U navedenim modelima GPR indeks tretira se kao egzogena varijabla konstruirana izvan tržišnih podataka (vanjski šok) i time se konceptualno razlikuje od inovacija u jednadžbi prinosa. Uključivanjem GPR-a u jednadžbu varijance nastoji se iz neobjašnjenog ostatka izdvojiti ekonomski interpretabilna komponenta, što je poduprto uključivanjem vremenskoga pomaka (GPR prethodi vo-

latilnosti). Jesu li i u kojoj mjeri GPR informacije već ugrađene u inovacijske članove (neobjašnjeni ostatak), varijablu ne čini redundantnom, nego upravo zbog statističke (ne)značajnosti proizlazi da ona ne dodaje ili dodaje informaciju o uvjetnoj volatilnosti povrhu onoga što je već sadržano u prošlim inovacijama i prošloj varijanci. Stoga se procjenjuju GARCH modeli bez GPR indeksa i s GPR indeksom, kako bi se, na temelju informacijskih kriterija (AIC i BIC) te statističke značajnosti, utvrdilo pridonosi li eksplicitno uključivanje GPR indeksa objašnjenju volatilnosti.

Podaci u empirijskoj analizi dnevni su prinosi šest burzovnih indeksa referentnih europskih izranjajućih tržišta (hrvatski CROBEX, poljski WIG20, bugarski SOFIX, češki PX, mađarski BUX i rumunjski BET indeks) od 4. siječnja 2021. do 28. studenoga 2025. godine. Iako odabrana tržišta pripadaju skupini izranjajućih tržišta, među njima su razlike u veličini (široko/usko) i likvidnosti (duboko/plitko). U posljednjoj dostupnoj, 2024. godini, najveći udio tržišne kapitalizacije u BDP-u zabilježen je u Hrvatskoj (29,92 %), zatim u Poljskoj (21,50 %) i Mađarskoj (18,65 %), dok su niže vrijednosti zabilježene u Rumunjskoj (12,39 %), Češkoj (9,98 %) i osobito Bugarskoj (7,42 %). Istodobno, likvidnost tržišta, mjerena udjelom vrijednosti protrgovanih dionica u BDP-u, bila je najizraženija u Poljskoj (8,84 %) i Mađarskoj (3,31 %), zatim u Češkoj (1,04 %) i Rumunjskoj (0,79 %), dok su Hrvatska (0,30 %) i Bugarska (0,16 %) bile na samom dnu prema likvidnosti (World Bank, 2026), što dodatno potvrđuje heterogenost tržišne aktivnosti promatranih burzi. Hrvatska pritom predstavlja izdvojen slučaj, jer je riječ o tržištu koje je po veličini razmjerno široko, ali po aktivnosti i likvidnosti plitko.

Deskriptivna statistika centriranih prinosa, sa sredinom nula, i dijagnostički testovi normalnosti, nezavisnosti i homoskedastičnosti prikazani su u Tablici 1. U promatranom razdoblju broj radnih dana nije jednak na nacionalnim tržištima (broj opažanja varira od 1214 do 1235). Svi dionički indeksi dosljedno upućuju na ljevostranu asimetriju (engl. *skewness*), što znači da su ekstremni negativni prinosi izraženiji od pozitivnih. Mjere zaobljenosti (engl. *kurtosis*) sve su veće od 3, što upućuje na postojanje teških repova. Posljedično, rezultati Jarque-Bera testova potvrđuju da se za sve indekse nulta hipoteza o normalnosti distribucije prinosa odbacuje. Najmanji dnevni prinosi zabilježeni su na rumunjskom (-11,11 %) i poljskom tržištu (-10,9 %), dok su pozitivni prinosi heterogeni među tržištima (u rasponu od 3,8 % do 8,4 %). Standardne devijacije prinosa također se razlikuju među tržištima: najnižu volatilnost pokazuje hrvatski CROBEX (0,6 %), a najvišu poljski WIG20 (1,4 %).


	CROBEX	WIG	SOFIX	PX	BUX	BET
Broj dana	1222	1231	1214	1235	1231	1229
Minimum	-0,066	-0,109	-0,062	-0,059	-0,111	-0,054
Maksimum	0,038	0,084	0,052	0,050	0,061	0,068
St. devijacija	0,006	0,014	0,007	0,009	0,012	0,009
Zaobljenost	18,700	7,490	12,395	9,276	14,865	9,562
Asimetrija	-1,223	-0,151	-0,230	-0,612	-1,203	-0,147
Jarque-Bera	12855,1***	1038,3***	4473,9***	2103,9***	7518,7***	2209,4***
Ljung-Box	4,901	8,423	2,796	7,022	4,449	6,204
ARCH	166,1***	172,3***	190,9***	314,1***	525,4***	306,3***

 **TABLICA 1**
 Deskriptivna statistika i
 dijagnostički testovi
 centriranih prinosa
 referentnih dioničkih
 indeksa

*** $p < 0,01$

Ljung-Box testovi ne upućuju na sustavnu autokorelaciju u prinosima, što znači da su prinosi nezavisni, dok ARCH testovi snažno potvrđuju autokoreliranost kvadriranih prinosa i prisutnost uvjetne heteroskedastičnosti. Svi dijagnostički testovi provedeni su sa 5 vremenskih pomaka, što odgovara petodnevnom radnom tjednu. Budući da prinosi nisu autokorelirani, ali pokazuju vremenski promjenjivu volatilitnost (značajnost ARCH efekata), ispunjeni su ključni preduvjeti za primjenu GARCH metodologije. Niskofrekventna (mesečna) opažanja GPR-a obuhvaćaju dodatnih 12 mjeseci prije prvog opažanja, kako bi se izračunala vrijednost MIDAS varijable kao ponderirani prosjek GPR-a s dvanaest vremenskih pomaka ($k = 12$). Dinamika dnevnoga i mjesečnoga GPR indeksa vizualizirana je na Slici 1. U siječnju 2020. povišene vrijednosti GPR-a povezane su s eskalacijom napetosti između SAD-a i Irana nakon američkog ubojstva Qassem Soleimanija 3. siječnja 2020. u Bagdadu. Najizraženiji skok u ožujku 2022. proizlazi iz ruske invazije na Ukrajinu i predstavlja najveći geopolitički šok u promatranom razdoblju. Novi snažan porast u listopadu 2023. povezan je s izbijanjem rata između Izraela i Hamasa te rizikom regionalne eskalacije na Bliskom istoku. Skokovi u lipnju 2025. povezani su s izravnim izraelskim napadima na Iran.

Usporedba dnevnoga i mjesečnoga GPR indeksa pokazuje da je dnevni indeks znatno šumovitiji, s izraženim kratkotrajnim ekstremima. Iako šumovi dominiraju dnevnim GPR indeksom, on ipak sadrži informacije koje nisu jednako izražene u mjesečnom indeksu. Šiljci uočljivi na mjesečnoj razini vidljivi su i u dnevnim podacima, no obrnuto ne vrijedi; primjerice, šiljak zabilježen u dnevnom GPR indeksu 14. travnja 2024. godine, povezan s iranskim napadom na Izrael, nije jasno uočljiv na mjesečnoj razini (Slika 1). Stoga se mjesečni GPR indeks razlikuje od dnevnoga po manjem intenzitetu, ali i manjem šumu.



SLIKA 1
Dinamika indeksa geo-političkog rizika na mjesečnoj i dnevnoj razini

EMPIRIJSKI REZULTATI I RASPRAVA

Tri su modela procijenjena za svako dioničko tržište pojedinačno: standardni GARCH(1,1) model bez egzogene varijable u jednadžbi uvjetne varijance, GARCH(1,1)-X model s dnevnim GPR indeksom kao egzogenom varijablom i GARCH(1,1)-MIDAS s mjesečnim GPR indeksom kao egzogenom MIDAS varijablom. Sva tri modela koriste se GJR specifikacijom i pretpostavljaju Studentovu t -distribuciju, pa se mogu konzistentno uspoređivati radi utvrđivanja pridonosi li globalni GPR podjednako objašnjenju volatilnosti dioničkih prinosa na promatranim tržištima i je li taj doprinos kratkoročan (parametar λ) i/ili dugoročan (parametar ψ). Dodatno, parametar θ_1 služi za otkrivanje utječu li više novije ili starije vrijednosti GPR indeksa na dugoročnu volatilnost, pri čemu je smisleno uzeti u obzir dvanaest vremenskih pomaka ($k = 12$) jednoga godišnjeg ciklusa za formiranje MIDAS varijable.

Rezultati Tablice 2 potvrđuju visoku perzistentnost volatilnosti na oba tržišta, mjerenu zbrojem parametara α i β , pri čemu je ona sustavno veća kod WIG20 indeksa (u rasponu od 0,9413 do 0,9585) nego kod CROBEX-a u svim specifikacijama (u rasponu od 0,8347 do 0,8625). Štoviše, GARCH-MIDAS modeli konzistentno pokazuju manju perzistentnost, jer eksplicitno razdvajaju kratkoročnu i dugoročnu komponentu volatilnosti, čime se reducira pretjerana perzistencija u kratkoročnoj dinamici. Pozitivne vrijednosti parametra γ upućuju na asimetrične

● TABLICA 2
Rezultati hrvatskoga
CROBEX i poljskoga
WIG20 dioničkog
indeksa

učinke volatilnosti, koji nisu statistički značajni za hrvatsko dioničko tržište, dok su značajni i snažnije izraženi na poljskom tržištu. Ti su učinci najizraženiji u GARCH-MIDAS modelima, pa se komparacijom istovjetnih parametara zaključuje da će negativne vijesti od prethodnoga dana povećati današnju volatilnost više od pozitivnih vijesti za 7,16 % na hrvatskom dioničkom tržištu, odnosno za 13,99 % na poljskom dioničkom tržištu. Procijenjeni stupnjevi slobode potvrđuju prisutnost teških repova u oba indeksa, izraženijih kod CROBEX-a zbog niže vrijednosti ($df \approx 4$). GPR indeks, kroz GJR-GARCH-X i osobito GJR-GARCH-MIDAS modele, statistički značajno pridonosi objašnjenju volatilnosti na oba tržišta, tj. usporedbom informacijskih kriterija evidentno je da modeli s GPR-om ostvaruju niže AIC i BIC vrijednosti, što potvrđuje bolju prilagodbu podacima.

Parametar	CROBEX indeks			WIG20 indeks		
	GJR-GARCH	GJR-GARCH-X	GJR-GARCH-MIDAS ($k = 12$)	GJR-GARCH	GJR-GARCH-X	GJR-GARCH-MIDAS ($k = 12$)
ω	0,0001*** (0,0000)	0,0000 (0,0000)		0,0001*** (0,0000)	0,0000 (0,0000)	
α	0,1722*** (0,0364)	0,1649** (0,0664)	0,1750*** (0,0532)	0,0000 (0,0067)	0,0001 (0,0094)	0,0001 (0,0124)
β	0,6669*** (0,0317)	0,6766*** (0,0496)	0,6239*** (0,1291)	0,8996*** (0,0102)	0,8888*** (0,0064)	0,8713*** (0,0561)
γ	0,0468 (0,0603)	0,0471 (0,0598)	0,0716 (0,0858)	0,1178*** (0,0241)	0,1234*** (0,0223)	0,1399*** (0,0513)
df	4,0030*** (0,3714)	4,0188*** (0,5536)	3,9333*** (0,1291)	12,9758*** (3,8380)	13,2520*** (4,1264)	13,0219*** (0,8141)
λ		0,0091** (0,0029)			0,0202*** (0,0065)	
ϕ			-11,8954*** (1,2499)			-11,3242*** (0,9767)
ψ			0,3693*** (0,1507)			0,5938*** (0,2054)
θ_I			68,5908*** (2,6143)			1,0010*** (0,3147)
Opažanja	1222	1222	1222	1231	1231	1231
Perzistentnost	0,8625	0,8651	0,8347	0,9585	0,9507	0,9413
AIC	-7,6847	-7,6833	-8,8276	-5,7746	-5,7749	-6,9180
BIC	-7,6638	-7,6583	-8,7984	-5,7538	-5,7499	-6,8890
Ljung-Box	3,4551*	3,4544*	3,4540*	3,2399	3,1797	3,1064
ARCH	0,4894	0,4901	0,4915	1,6670	1,9270	2,007
Predznak test	0,7521	0,7520	0,6903	1,3990	1,3690	1,2498
Nyblom test	0,0876	1,1226	1,2168	0,1222	0,1149	0,2551

Napomena: Svi su modeli iste GARCH(1,1) specifikacije (u zagradama su standardne pogreške procijenjenih parametara).

* $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$

Pozitivan i statistički značajan, ali vrlo slab utjecaj dnevnoga GPR-a na kratkoročnu volatilitnost hrvatskoga tržišta, iznosi 0,0091 %, a poljskoga tržišta 0,0202 % (parametri uz GPR varijable interpretiraju se kao postoci, premda prinosi nisu množeni sa 100 % zbog logaritamske transformacije GPR indeksa prilikom parametarskih procjena).

Parametar	SOFIX indeks			PX indeks		
	GJR-GARCH	GJR-GARCH-X	GJR-GARCH-MIDAS ($k = 12$)	GJR-GARCH	GJR-GARCH-X	GJR-GARCH-MIDAS ($k = 12$)
ω	0,0000*** (0,0000)	0,0000*** (0,0000)		0,0000*** (0,0000)	0,0000*** (0,0000)	
α	0,1839*** (0,0383)	0,1834*** (0,0592)	0,1572*** (0,0572)	0,0527*** (0,0111)	0,0527*** (0,0125)	0,0514*** (0,0100)
β	0,6827*** (0,0321)	0,6833*** (0,0507)	0,6186*** (0,0971)	0,8106*** (0,0207)	0,8106*** (0,0212)	0,8103*** (0,0561)
γ	-0,0045 (0,0577)	-0,0040 (0,0605)	0,0122 (0,0657)	0,1609*** (0,0409)	0,1609*** (0,0412)	0,1657** (0,0688)
df	4,7165*** (0,5320)	4,7156*** (0,5370)	4,9775*** (0,9315)	5,0677*** (0,6960)	5,0670*** (0,7219)	5,0305*** (0,9826)
λ		0,0000 (0,0000)			0,0000 (0,0000)	
ϕ			-3,8915** (1,5436)			-8,3588*** (0,8811)
ψ			0,0283 (0,3588)			0,2379** (0,1078)
θ_1			1,0010 (1,7103)			21,8580*** (4,2808)
Opažanja	1214	1214	1214	1235	1235	1235
Perzistentnost	0,8643	0,8647	0,7819	0,9437	0,9437	0,9445
AIC	-7,2924	-7,2908	-8,4468	-6,9868	-6,9852	-8,1287
BIC	-7,2714	-7,2656	-8,4177	-6,9661	-6,9603	-8,0997
Ljung-Box	1,3346	1,3340	1,3341	2,8461*	2,8460*	2,8455*
ARCH	0,8648	0,8656	0,8655	0,2636	0,2632	0,2633
Predznak test	1,2873	1,2860	1,2858	0,0121	0,0119	0,1157
Nyblom test	0,2886	0,4516	0,7223	0,6437	0,6431	0,8651

■ TABLICA 3
Rezultati bugarskoga
SOFIX i češkoga PX
dioničkog indeksa

Napomena: Svi su modeli iste GARCH(1,1) specifikacije (u zagradama su standardne pogreške procijenjenih parametara).
* $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$

Pozitivan utjecaj mjesečnoga GPR na dugoročnu volatilitnost veći je od kratkoročnog utjecaja i izraženiji na poljskom tržištu (0,5938 % prema 0,3693 %). Zanimljivo, vrlo visok i značajan $\theta_1 \approx 69$ pokazuje da dugoročna volatilitnost CROBEX-a reagira isključivo na recentne geopolitičke napetosti, dok procijenjena vrijednost istoimenoga parametra blizu 1 implicira gotovo ravnomjerno raspoređene pondere i utjecaj GPR-a na

WIG20 kroz više mjeseci. To sugerira da se geopolitički rizik na poljskom tržištu prenosi na volatilnost sporije, ali trajnije.

Procjene kratkoročnih GARCH parametara za SOFIX upućuju na relativno snažnu reakciju volatilnosti na nove šokove (približno 18,3 %), pri čemu se uvođenjem MIDAS specifikacije smanjuju i α i β , što dovodi do pada ukupne perzistentnosti s oko 0,86 na 0,78 (Tablica 3). Parametar asimetrije za SOFIX nije statistički značajan ni u jednoj specifikaciji, što upućuje na izostanak efekta asimetrije unatoč niskim stupnjevima slobode. GARCH-X i GARCH-MIDAS sugeriraju pozitivne, ali statistički neznačajne, utjecaje geopolitičkog rizika na kratkoročnu i dugoročnu volatilnost bugarskoga dioničkog tržišta. Kod PX indeksa rezultati su znatno drukčiji. GARCH-MIDAS model ostvaruje znatno bolju prilagodbu, uz znatno niže informacijske kriterije AIC i BIC. Za razliku od SOFIX-a, kratkoročni parametri PX indeksa ostaju stabilni u svim modelima, a perzistentnost volatilnosti zadržava se na visokoj razini od oko 0,94, što upućuje na snažno ukorijenjenu inerciju. Asimetrija volatilnosti evidentno je prisutna (parametar γ je pozitivan i statistički značajan u svim specifikacijama). Iako MIDAS parametri upućuju na stabilnu i smisleno definiranu dugoročnu komponentu volatilnosti, vođenu mjesečnim GPR indeksom, taj učinak izostaje u kratkoročnoj volatilnosti.

Volatilnost BUX indeksa obilježena je izrazito visokom perzistentnošću (Tablica 4), uz vrlo nisku osjetljivost na nove šokove (3 %). BET indeks pokazuje znatno nižu perzistentnost u GJR-GARCH modelu, koja se dodatno smanjuje na oko 86 % u MIDAS specifikaciji, te snažniju reakciju na nove informacije (12 %). Asimetrični učinci prisutni su kod oba indeksa, ali su značajni samo za rumunjsko tržište (16 %). Uključivanje GPR-a ne donosi vidljivo poboljšanje kratkoročne volatilnosti ni za jedan indeks, dok GARCH-MIDAS za BET indeks značajno poboljšava rezultate (utjecaj na dugoročnu volatilnost iznosi 0,2379 % s dugoročnim djelovanjem $\theta_1 \approx 9,93$). Nasuprot tome, empirijski rezultati za BUX indeks pokazuju da GPR nema statistički značajan učinak u kratkoročnoj (GARCH-X) specifikaciji, dok je u GARCH-MIDAS modelu dugoročna komponenta statistički značajna, ali negativnoga predznaka (Tablica 4), što sugerira da su globalni geopolitički šokovi u Mađarskoj percipirani drugačije te su povezani sa smanjenjem volatilnosti u dugom roku.

Takav rezultat može biti povezan sa specifičnim energetske položajem Mađarske, koja i dalje ostvaruje pristup jeftinijoj sirovoj ruskoj nafti preko Družba sustava (zbog izuzeća Mađarske od dijela embarga EU-a na rusku sirovu naftu 2022. godine), ali i s visokom koncentriranošću BUX indeksa, u kojem nekoliko dionica, među njima i MOL s udjelom od 20 %, u velikoj mjeri određuju dinamiku tržišne volatilnosti.

Parametar	BUX indeks			BET indeks		
	GJR-GARCH	GJR-GARCH-X	GJR-GARCH-MIDAS ($k = 12$)	GJR-GARCH	GJR-GARCH-X	GJR-GARCH-MIDAS ($k = 12$)
ω	0,0000*** (0,0000)	0,0000*** (0,0000)		0,0000*** (0,0000)	0,0000 (0,0000)	
α	0,0301*** (0,0086)	0,0301*** (0,0049)	0,0289 (0,0387)	0,1241*** (0,0256)	0,1212*** (0,0134)	0,1246*** (0,0405)
β	0,8538*** (0,0177)	0,8539*** (0,0155)	0,8494*** (0,0812)	0,6696*** (0,0313)	0,6687*** (0,0163)	0,6567*** (0,0800)
γ	0,1388*** (0,0327)	0,1388*** (0,0334)	0,1401** (0,0569)	0,1599*** (0,0589)	0,1568*** (0,0589)	0,1617** (0,0710)
df	8,9178*** (1,8584)	8,9162*** (1,8460)	8,8782* (4,5776)	5,4374*** (0,7090)	5,4844*** (0,8531)	5,4526*** (0,8848)
λ		0,0000 (0,0000)			0,0000*** (0,0000)	
ϕ			-5,7122*** (1,3105)			-11,1658*** (1,1922)
ψ			-0,7092** (0,2802)			0,3554 (0,2331)
θ_I			1,0010 (3,7962)			9,9307*** (0,0832)
Opažanja	1231	1231	1231	1229	1229	1229
Perzistentnost	0,9533	0,9533	0,9483	0,8737	0,8683	0,8621
AIC	-6,3489	-6,3473	-7,492	-6,8848	-6,8841	-8,027
BIC	-6,3282	-6,3224	-7,463	-6,864	-6,8591	-8,998
Ljung-Box	0,8739	0,0931	0,1255	1,6352	1,4990	1,4782
ARCH	3,7800	3,7770	3,7769	0,5141	0,5563	0,5644
Predznak test	0,0298	0,0299	0,0290	1,2964	1,3117	1,3286
Nyblom test	0,8810	0,9669	1,1536	0,0738	0,2463	1,4801

■ TABLICA 4
Rezultati mađarskoga
BUX i rumunjskoga
BET dioničkog indeksa

Napomena: Svi su modeli iste GARCH(1,1) specifikacije (u zagradama su standardne pogreške procijenjenih parametara).
* $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$

Posljedično, procijenjeni dugoročni učinak GPR indeksa može odstupati, i po predznaku i po intenzitetu, od učinaka zabilježenih na ostalim tržištima. Naime, u promatranom razdoblju cijene dionica MOL-a kontinuirano su rasle, što je pridonijelo smanjenju ukupne volatilnosti BUX indeksa, unatoč rastu globalnoga GPR indeksa. Štoviše, MOL-ov rafinerijski segment ostvarivao je profitabilne ishode zbog mogućnosti preradbe nafte Urals po povoljnijim ulaznim cijenama. Rezultat o izostanku kratkoročnog učinka GPR-a u objašnjavanju varijacija 10-dnevnoga kumulativnog iznadprosječnog prinosa (engl. *cumulative abnormal returns*) BUX indeksa nakon kriznih događaja (Nagy i Erdős, 2025) djelomično je konzistentan s interpretacijom da globalni GPR indeks ne daje robustan kratkoročni signal za mađarsko tržište. Pritom se autori nisu koristili GARCH metodologijom ni volatilnošću kao zavisnom va-

rijablom, a uzorkom nije obuhvaćeno razdoblje od 2022. nadalje, u kojem su se geopolitičke prijetnje i napetosti znatno pojačale.

U fazi nakon procjene svih modela provedeni su ARCH test, Ljung-Box test, test predznaka (engl. *sign bias test*) i Nyblom test na razini signifikantnosti od 5 %, koji nisu dijagnosticirali preostalu autokorelaciju u standardiziranim rezidualima ni u njihovim kvadratima, ni na prisutnost heteroskedastičnosti, asimetrije volatilnosti ili nestabilnosti parametara. To znači da su modeli ispravno specificirani, jer dobro inkorporiraju navedena svojstva. Neodbacivanjem nulte hipoteze Nyblom testa potvrđena je stabilnost parametara, zbog čega nije bilo potrebe za eksplicitnim modeliranjem režimske promjenjivosti. Ona je pritom implicitno obuhvaćena kroz vremenski promjenjivu volatilnost, pri čemu se normalna i stresna tržišna stanja odražavaju u grupiranim razdobljima niske i visoke volatilnosti, što GARCH modeli adekvatno zahvaćaju. U modelima u kojima je GPR indeks statistički značajan, njegov doprinos objašnjavanju kratkoročne i dugoročne volatilnosti potvrđen je i nižim vrijednostima AIC i BIC kriterija, što upućuje na bolju prilagodbu modela podacima unatoč penalizaciji zbog dodatnoga parametra.

ZAKLJUČAK

Rani empirijski radovi, usmjereni na specifične oblike geopolitičkih prijetnji – poput terorizma i oružanih sukoba – pokazuju da takvi događaji narušavaju povjerenje investitora i povećavaju volatilnosti prinosa dionica, pri čemu su učinci izraženiji u institucionalno slabije razvijenim zemljama. Razvoj sveobuhvatnih mjera geopolitičkog rizika, osobito GPR indeksa, omogućio je sustavnije analize, koje potvrđuju da su geopolitičke prijetnje i događaji izvor sistematskog rizik i povećavaju volatilnost tržišta kapitala kroz kanal investicijskog sentimenta. U ovom radu uspoređeni su standardni GJR-GARCH, GJR-GARCH-X i GJR-GARCH-MIDAS modeli kako bi se ispitalo djeluje li globalni geopolitički rizik na volatilnost dioničkih prinosa kratkoročno i/ili dugoročno na više srednjoeuropskih izranjajućih tržišta te odražavaju li se razlike u percepciji globalnoga geopolitičkog rizika u heterogenim učincima među njima. Rezultati konzistentno pokazuju da je volatilnost na svim promatranim tržištima visoko perzistentna, ali i da GARCH-MIDAS modeli sustavno smanjuju perzistentnost u odnosu na standardne GARCH specifikacije, čime potvrđuju važnost razdvajanja kratkoročne i dugoročne komponente volatilnosti. Pritom se učinak geopolitičkog rizika na kratkoročnu volatilnost pokazao ograničenim ili neznačajnim, dok je njegov dugoročni učinak znatno izraženiji, ali heterogen među zemljama. Nalazi

upućuju na to da kratkoročni učinci ovise o likvidnosti tržišta, dok su dugoročni učinci više uvjetovani veličinom tržišta te kombinacijom veličine i tržišne dubine. Manje likvidna tržišta – poput Rumunjske, Češke i Bugarske – gotovo ne pokazuju kratkoročne učinke, s izuzetkom hrvatskoga tržišta, gdje relativno velika tržišna kapitalizacija omogućuje pozitivnu, premda umjerenu, reakciju kratkoročne volatilnosti na globalni geopolitički rizik unatoč niskoj likvidnosti. Dugoročno, snažne reakcije bilježe veća i likvidnija tržišta, poput Poljske i Mađarske, iako različita predznaka, dok su blaži, ali i dalje statistički signifikantni dugoročni pozitivni učinci, prisutni na hrvatskom i na češkom tržištu. Na rumunjskom tržištu dugoročni učinak pak nije signifikantan, a usko i plitko tržište Bugarske ne pokazuje signifikantne ni dugoročne ni kratkoročne učinke. Mađarsko je tržište specifično među širim tržištima, jer geopolitički rizik dugoročno smanjuje volatilnost zbog visoke koncentracije energetskoga sektora u tržišnom indeksu, čije cijene rastu unatoč povećanom geopolitičkom riziku. Ističu se i razlike u dinamici prijenosa: dok se geopolitički rizik na hrvatskom tržištu reflektira isključivo kroz recentne događaje, na poljskom i rumunjskom tržištu njegov se utjecaj akumulira sporije, ali djeluje dugotrajnije. Asimetrični učinci volatilnosti prisutni su na likvidnijim tržištima (Poljska, Češka, Rumunjska), dok su slabiji ili izostaju na manjim tržištima, što upućuje na strukturne razlike u reakciji na negativne šokove. Rezultati potvrđuju da GPR djeluje primarno kao dugoročni faktor volatilnosti te da je GJR-GARCH-MIDAS metodološki i empirijski superioran model naspram standardnih GARCH modela, jer omogućuje precizniju identifikaciju izvora volatilnosti i otkriva značajne razlike u načinu na koji se geopolitički rizik prenosi na financijska tržišta.

Za institucionalne investitore rezultati impliciraju da kratkoročne prilagodbe portfelja temeljene na dnevnim geopolitičkim vijestima možda nisu optimalne, osobito na manje likvidnim tržištima. Izraženiji i trajniji utjecaj GPR-a na dugoročnu volatilnost sugerira da geopolitičke šokove valja uzeti u obzir u okviru dugoročnijega praćenja rizika i investicijskog odlučivanja. Na tržištima na kojima se GPR prenosi sporije, ali postojanije, poput Poljske i Rumunjske, može se očekivati produženo razdoblje povišene volatilnosti, što upućuje na potrebu prilagodbe horizonta upravljanja rizikom. Za nositelje ekonomskih politika rezultati prije svega upućuju na važnost praćenja geopolitičkih izvora volatilnosti i jačanja otpornosti financijskoga sustava u uvjetima povećane geopolitičke neizvjesnosti.

Ograničenja ovog rada proizlaze iz nemogućnosti upotrebe intradnevnihi podataka, što može smanjiti učinkovitost analize kratkoročnih učinaka, te iz upotrebe globalnoga GPR in-

dekse, koji može prikriti geopolitičke rizike specifične za pojedine zemlje. Navedena ograničenja istodobno upućuju na smjernice za buduća istraživanja, koja bi omogućila precizniju identifikaciju lokalnih i kratkoročnih učinaka geopolitičkog rizika na tržišnu volatilnost.

LITERATURA

Ahmad, T., Hussain, S., Akbar, M. i Rehman, A. U. (2022). Impact of terrorism on stock market: Evidence from developed and developing markets. *International Journal of Disaster Risk Reduction*, 70, 102786. <https://doi.org/10.1016/j.ijdr.2022.102786>

Ahmed, S., Hasan, M. M. i Kamal, M. R. (2023). Russia-Ukraine crisis: The effects on the European stock market. *European Financial Management*, 29(4), 1078–1118. <https://doi.org/10.1111/eufm.12386>

Ayinde, T. O. i Adeyemi, F. A. (2023). Global evidence of oil supply shocks and climate risk: A GARCH-MIDAS approach. *Energy Research Letters*, 4(2). <https://doi.org/10.46557/001c.73221>

Bollerslev, T. (1986). Generalized autoregressive conditional heteroscedasticity. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)

Bondarenko, O., Talavera, O. i Zholud, O. (2024). Geopolitical risk perceptions. *Journal of International Economics*, 147, 104005. <https://doi.org/10.1016/j.jinteco.2024.104005>

Bouras, C., Christou, C., Gupta, R. i Suleman, T. (2018). Geopolitical risks, returns, and volatility in emerging stock markets: Evidence from a Panel GARCH Model. *Emerging Markets Finance and Trade*, 55(8), 1841–1856. <https://doi.org/10.1080/1540496x.2018.1507906>

Caldara, D. i Iacoviello, M. (2022). Measuring geopolitical risk. *American Economic Review*, 112(4), 1194–1225. <https://doi.org/10.1257/aer.20191823>

Corbet, S., Gurdgiev, C. i Meegan, A. (2018). Long-term stock market volatility and the influence of terrorist attacks in Europe. *Quarterly Review of Economics and Finance*, 68, 118–131. <https://doi.org/10.1016/j.qref.2017.11.012>

Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987–1007. <https://doi.org/10.2307/1912773>

Essaddam, N. i Karagianis, J. M. (2014). Terrorism, country attributes, and the volatility of stock returns. *Research in International Business and Finance*, 31, 87–100. <https://doi.org/10.1016/j.ribaf.2013.11.001>

Fang, Z. i Han, J.-Y. (2025). Realized GARCH model in volatility forecasting and option pricing. *Computational Economics*, 66(5), 3637–3657. <https://doi.org/10.1007/s10614-024-10826-8>

Gheorghe, C. i Panazan, O. (2024). Investigating the effect of geopolitical risk on defense companies' stock returns. *Heliyon*, 10(24), e40974. <https://doi.org/10.1016/j.heliyon.2024.e40974>

Ghysels, E., Santa-Clara, P. i Valkanov, R. (2006). Predicting volatility: Getting the most out of return data sampled at different frequencies. *Journal of Econometrics*, 131(1-2), 59–95. <https://doi.org/10.1016/j.jeconom.2005.01.009>

Glosten, L. R., Jagannathan, R. i Runkle, D. E. (1993). Relationship between the expected value and the volatility of the nominal excess return on stocks. *The Journal of Finance*, 48(5), 1779–1801. <https://doi.org/10.1111/j.1540-6261.1993.tb05128.x>

Gurdgiev, C., Henrichsen, A. i Mulhair, A. (2022). The budgets of wars: Analysis of the U.S. defense stocks in the post-Cold War era. *International Review of Economics and Finance*, 82, 335–346. <https://doi.org/10.1016/j.iref.2022.06.023>

Halousková, M., Stašek, D. i Horváth, M. (2022). The role of investor attention in global asset price variation during the invasion of Ukraine. *Finance Research Letters*, 50, 103292. <https://doi.org/10.1016/j.frl.2022.103292>

He, Z. (2023). Geopolitical risks and investor sentiment: Causality and TVP-VAR analysis. *North American Journal of Economics and Finance*, 67, 101947. <https://doi.org/10.1016/j.najef.2023.101947>

Izzeldin, M., Muradoğlu, Y. G., Pappas, V., Petropoulou, A. i Sivaprasad, S. (2023). The impact of the Russian-Ukrainian war on global financial markets. *International Review of Financial Analysis*, 87, 102598. <https://doi.org/10.1016/j.irfa.2023.102598>

Klein, T. (2024). Investor behavior in times of conflict: A natural experiment on the interplay of geopolitical risk and defense stocks. *Journal of Economic Behavior & Organization*, 222, 294–313. <https://doi.org/10.1016/j.jebo.2024.04.020>

Klomp, J. (2025). The impact of the Hamas-Israel conflict on the U.S. defense industry stock market return. *Plos One*, 20(2), e0314677. <https://doi.org/10.1371/journal.pone.0314677>

Lasisi, L. A., Ngwu, F. N., Taliat, M. K., Olaniran, A. O. i Nnamdi, K. C. (2025). Modelling commodity market volatility with climate policy uncertainty: A GARCH-MIDAS approach. *SN Business and Economics*, 5, article no 29. <https://doi.org/10.1007/s43546-025-00792-0>

Le, Y., Wen, J., Wu, Y., Liu, J. i Zhu, Y. (2024). Investigating factors influencing oil volatility: A GARCH-MIDAS model analysis. *Frontiers in Energy Research*, 12, 1392905. <https://doi.org/10.3389/fenrg.2024.1392905>

Liang, C., Wang, L. i Duong, D. (2024). More attention and better volatility forecast accuracy: How does war attention affect stock volatility predictability? *Journal of Economic Behavior and Organization*, 218, 1–19. <https://doi.org/10.1016/j.jebo.2023.12.009>

Liu, H., Yang, P., He, Y., Oxley, L. i Guo, P. (2024). Exploring the influence of geopolitical risks on the natural resource price volatility and correlation: Evidence from DCC-MIDAS-X model. *Energy Economics*, 129, 107204. <https://doi.org/10.1016/j.eneco.2023.107204>

Liu, J., Ma, F., Tang, Y. i Zhang, Y. (2019). Geopolitical risk and oil volatility: A new insight. *Energy Economics*, 84, 104548. <https://doi.org/10.1016/j.eneco.2019.104548>

Liu, Y., Han, L. i Xu, Y. (2021). The impact of geopolitical uncertainty on energy volatility. *International Review of Financial Analysis*, 75, 101743. <https://doi.org/10.1016/j.irfa.2021.101743>

Lu, H., Gao, Q., Xiao, L. i Dhesi, G. (2024). Forecasting EUA futures volatility with geopolitical risk: Evidence from GARCH-MIDAS models. *Review of Managerial Science*, 18(7), 1917–1943. <https://doi.org/10.1007/s11846-023-00722-0>

- Msomi, S. i Kunjal, D. (2024). Industry-specific effects of economic policy uncertainty on stock market volatility: A GARCH-MIDAS approach. *Quantitative Finance and Economics*, 8(3), 532–545. <https://doi.org/10.3934/qfe.2024020>
- Nagy, A. Z. i Erdős, S. (2025). International crises, geopolitical risks and the Hungarian stock market. *Financial and Economic Review*, 24(4), 118–145. <https://doi.org/10.33893/FER.24.4.118>
- Neto, D. (2025). Buy when there's blood in the streets: How geopolitical adverse events can push defense stock returns to the extreme. *European Journal of Political Economy*, 90, 102771. <https://doi.org/10.1016/j.ejpoleco.2025.102771>
- Nortey, E. N., Agbeli, R., Debrah, G., Ansah-Narh, T. i Agyemang, E. F. (2024). A GARCH-MIDAS approach to modelling stock returns. *Communications for Statistical Applications and Methods*, 31(5), 535–556. <https://doi.org/10.29220/csam.2024.31.5.535>
- Prasad, S. S., Puri, V. i Bakhshi, P. (2025). Do climate change and geopolitical risk influence volatility? Empirical evidence from leading economies. *Journal of Environmental Management*, 394, 127471. <https://doi.org/10.1016/j.jenvman.2025.127471>
- Salisu, A. A., Ogbonna, A. E., Lasisi, L. i Olaniran, A. (2022). Geopolitical risk and stock market volatility in emerging markets: A GARCH-MIDAS approach. *North American Journal of Economics and Finance*, 62, 101755. <https://doi.org/10.1016/j.najef.2022.101755>
- Segnon, M., Gupta, R. i Wilfling, B. (2024). Forecasting stock market volatility with regime-switching GARCH-MIDAS: The role of geopolitical risks. *International Journal of Forecasting*, 40(1), 29–43. <https://doi.org/10.1016/j.ijforecast.2022.11.007>
- Umar, Z., Bossman, A., Choi, S.-Y. i Vo, X. V. (2023). Are short stocks susceptible to geopolitical shocks? Time-Frequency evidence from the Russian-Ukrainian conflict. *Finance Research Letters*, 52, 103388. <https://doi.org/10.1016/j.frl.2022.103388>
- World Bank (2026). *World Development Indicators*. World Bank. <https://data.worldbank.org/> [pristupljeno 16. 3. 2026.]
- Xie, Q., Bi, Y., Xi, Y. i Xu, X. (2025). The impact of geopolitical risk on higher-order moment risk spillovers in global energy markets. *Energy Economics*, 144, 108292. <https://doi.org/10.1016/j.eneco.2025.108292>
- Yang, M., Zhang, Q., Yi, A. i Peng, P. (2021). Geopolitical risk and stock market volatility in emerging economies: Evidence from GARCH-MIDAS model. *Discrete Dynamics in Nature and Society*, 1159358. <https://doi.org/10.1155/2021/1159358>
- Zhang, Y., He, J., He, M. i Li, S. (2023). Geopolitical risk and stock market volatility: A global perspective. *Finance Research Letters*, 53, 103620. <https://doi.org/10.1016/j.frl.2022.103620>
- Zhang, Z., Bouri, E., Klein, T. i Jalkh, N. (2022). Geopolitical risk and the returns and volatility of global defense companies: A new race to arms? *International Review of Financial Analysis*, 83, 102327. <https://doi.org/10.1016/j.irfa.2022.102327>

Effects of Geopolitical Risk on Short- and Long-Term Volatility in Emerging Stock Markets

Josip ARNERIĆ

University of Zagreb, Faculty of Economics and Business,
Zagreb, Croatia

This paper examines the role of geopolitical risk (GPR) as an exogenous variable in explaining volatility in emerging Central European stock markets, aiming to assess whether differences in investors' perceptions of global geopolitical risk are reflected in heterogeneous effects across markets that are shallower and less liquid, and therefore more sensitive to wars, international conflicts, and political tensions. To address the limitations of standard single-frequency GARCH models, the study employs a GARCH-MIDAS framework that separates short-run volatility from long-run volatility, the latter being associated with geopolitical shocks observed at lower frequencies. Complementarily, a GARCH-X specification is used to examine the contemporaneous impact of daily GPR on short-term volatility. The results indicate that the short-run effect of geopolitical risk is limited or statistically insignificant, while monthly GPR is a strong driver of long-run volatility in the Polish, Czech, and Romanian markets, with weaker intensity in the Croatian and Bulgarian markets, and an opposite effect identified in the Hungarian market. The findings have important implications for institutional investors in improving risk management across different investment horizons, as well as for policymakers in designing timely responses to mitigate the impact of geopolitical shocks on these markets.

Keywords: GARCH-MIDAS, GARCH-X, geopolitical risk, emerging stock markets, volatility



Međunarodna licenca / International License:
Imenovanje-Nekomercijalno / Attribution-NonCommercial