

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

ZAKLJUČNA STROKOVNA NALOGA VISOKE POSLOVNE ŠOLE
**NAPOVEDOVANJE ŠTEVILA PRVIČ REGISTRIRANIH OSEBNIH
VOZIL V SLOVENIJI**

Ljubljana, junij 2025

ANA PODPESKAR

IZJAVA O AVTORSTVU

Podpisana Ana Podpeskar, študentka Univerze v Ljubljani Ekonomske fakultete, avtorica predloženega dela z naslovom Napovedovanje števila prvič registriranih osebnih vozil v Sloveniji, pripravljene v sodelovanju z mentorico red. prof. dr. Liljano Ferbar Tratar

IZJAVLJAM

1. da sem predloženo delo pripravila samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo pisnih del UL EF, kar pomeni, da sem poskrbela, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo pisnih del UL EF;
4. da se zavedam, da je plagiatstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatstvo lahko predstavljalo za moj status na Univerzi v Ljubljani Ekonomski fakulteti v skladu z relevantnim pravilnikom;
6. da sem pridobila vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označila;
7. da sem pri pripravi predloženega dela ravnala v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobila soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi;
11. da sem preverila verodostojnost informacij, ki izhajajo iz zapisov na podlagi uporabe orodij umetne inteligence.

V Ljubljani, dne 17. 06. 2025

Podpis študentke: 

POVZETEK

Napovedovanje števila prvih registracij osebnih avtomobilov ima pomembno vlogo pri spremljanju tržnih gibanj in oblikovanju prometne ter okoljske politike. V nalogi je obravnavana časovna vrsta registracij v Sloveniji med letoma 2015 in 2024, s posebnim poudarkom na vplivu pandemije in izločitvi leta 2020. Uporabljene so bile metode eksponentnega glajenja, med katerimi je aditivna Holt-Wintersova metoda izkazala najvišjo natančnost napovedovanja, medtem ko se je multiplikativna Holt-Wintersova metoda zaradi svoje prilagodljivosti pokazala kot pomembna dopolnitev za bolj nestabilna obdobja. Rezultati prispevajo k zanesljivejšemu napovedovanju in podpori strateškemu odločanju.

KLJUČNE BESEDE: Slovenija, osebni avtomobili, registracije, napovedovanje, časovne vrste, eksponentno glajenje, napake napovedovanja, ekonomska predvidevanja, trajnostna mobilnost

CILJI TRAJNOSTNEGA RAZVOJA



ABSTRACT

Accurate forecasting of the number of first-time passenger car registrations is crucial for monitoring market trends and shaping transport and environmental policies. This thesis analyses registration data from Slovenia between 2015 and 2024, focusing on the impact of the 2020 pandemic and excluding this year from the analysis. Advanced exponential smoothing methods were employed, with Additive Holt-Winters method emerging as the most accurate approach overall, while Additive Extended Holt-Winters method proved valuable due to its adaptability during more volatile periods. The findings support more reliable forecasting and improved strategic planning.

KEY WORDS: Slovenia, passenger cars, registrations, forecasting, time series, exponential smoothing, forecast errors, economic forecasting, sustainable mobility

SUSTAINABLE DEVELOPMENT GOALS



KAZALO

1	UVOD	4
2	PRVA REGISTRACIJA NAVADNIH OSEBNIH AVTOMOBILOV FIZIČNIH OSEB	5
2.1	Pravna in statistična definicija pojmov	5
2.2	Vloga registracij pri spremljanju gospodarskih gibanj	6
2.3	Dejavniki, ki vplivajo na število registracij	6
3	TRENTNO STANJE AVTOMOBILSKE INDUSTRIJE V SLOVENIJI IN EVROPI.....	7
3.1	Pregled razmer na avtomobilskem trgu po letu 2020.....	7
3.2	Izzivi v dobavnih verigah in pomanjkanje komponent	8
3.3	Vpliv dejavnikov na registracije.....	9
3.4	Vpliv pandemije koronavirusne bolezni 2019 na trg osebnih avtomobilov ...	9
4	NAPOVEDOVANJE Z METODAMI ČASOVNIH VRST	10
4.1	Namen, uporabnost in vrste napovedovanja	10
4.2	Pregled metod napovedovanja.....	11
4.2.1	Enostavno eksponentno glajenje	11
4.2.2	Holtova metoda	12
4.2.3	Aditivna Holt-Wintersova metoda	13
4.2.4	Multiplikativna Holt-Wintersova metoda.....	14
4.2.5	Razširjena aditivna Holt-Wintersova metoda.....	15
4.3	Merjenje natančnosti napovedi	16
5	NAPOVEDOVANJE REGISTRACIJ OSEBNIH AVTOMOBILOV	19
5.1	Predstavitev in analiza podatkovne baze.....	19
5.2	Rezultati posameznih metod napovedovanja	21
5.2.1	Metoda enostavnega eksponentnega glajenja.....	21
5.2.2	Holtova metoda	23
5.2.3	Aditivna Holt-Wintersova metoda	24
5.2.4	Multiplikativna Holt-Wintersova metoda.....	25
5.2.5	Razširjena aditivna Holt-Wintersova metoda.....	26
5.3	Primerjava metod glede na napake napovedovanja.....	27
5.4	Učinek izločitve leta 2020 na kakovost napovedi	29

5.4.1	Predstavitev in analiza podatkovne baze brez leta 2020	29
5.4.2	Rezultati aditivne Holt-Wintersovove metode in multiplikativne Holt-Wintersove metode.....	31
5.4.2.1	<i>Aditivna Holt-Wintersova metoda</i>	32
5.4.2.2	<i>Razširjena aditivna Holt-Wintersova metoda</i>	33
5.4.3	Primerjava aditivne Holt-Wintersove metode in razširjene aditivne Holt-Wintersove metode.....	34
6	SKLEP	35
	SEZNAM KLJUČNE LITERATURE	36
	LITERATURA IN VIRI	37
	PRILOGA	39

KAZALO TABEL

Tabela 1: Vrednosti izračunov metode enostavnega eksponentnega glajenja	22
Tabela 2: Vrednosti izračunov Holtove metode.....	23
Tabela 3: Vrednosti izračunov aditivne Holt-Wintersove metode.....	24
Tabela 4: Vrednosti izračunov multiplikativne Holt-Wintersove metode	25
Tabela 5: Vrednosti izračunov razširjene aditivne Holt-Wintersove metode	26
Tabela 6: Zbirna tabela napak za učno množico	28
Tabela 7: Zbirna tabela napak za testno množico	28
Tabela 8: Vrednosti izračunov aditivne Holt-Wintersove metode brez 2020	32
Tabela 9: Vrednosti izračunov razširjene aditivne Holt-Wintersove metode brez 2020	33
Tabela 10: Zbirna tabela napak za učno množico brez upoštevanja leta 2020	34
Tabela 11: Zbirna tabela napak za testno množico brez upoštevanja leta 2020	35

KAZALO SLIK

Slika 1: Prikaz mesečnega števila prvič registriranih navadnih osebnih avtomobilov fizičnih oseb v Sloveniji za obdobje 2015–2024	20
Slika 2: Prikaz sezonskosti za obdobje 2015–2024	20
Slika 3: Graf analize avtokorelacijske funkcije.....	21
Slika 4: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z metodo enostavnega eksponentnega glajenja	22
Slika 5: Primerjava dejanskih vrednosti in vrednosti, pridobljenih s Holtovo metodo.....	23
Slika 6: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z aditivno Holt-Wintersovo metodo	25

Slika 7: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z multiplikativno Holt-Wintersovo metodo	26
Slika 8: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z razširjeno aditivno Holt-Wintersovo metodo	27
Slika 9: Prikaz mesečnega števila prvič registriranih navadnih osebnih avtomobilov fizičnih oseb v Sloveniji za obdobje 2015–2024 brez 2020	29
Slika 10: Prikaz sezonskosti za obdobje 2015–2024 brez 2020	30
Slika 11: Graf analize avtokorelacijske funkcije brez 2020	31
Slika 12: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z aditivno Holt-Wintersovo metodo, brez 2020	33
Slika 13: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z razširjeno aditivno Holt-Wintersove metode, brez 2020	34

KAZALO PRILOG

Priloga 1: Izračun napovedi razširjene aditivne Holt-Wintersove metode z minimizacijo povprečne odstotne napake	1
---	---

SEZNAM KRATIC

angl. – angleško

ACF – (angl. Autocorrelation function); analiza avtokorelacijske funkcije

AHW – (angl. Additive Holt-Winters method); aditivna Holt-Wintersova metoda

BDP – bruto domači proizvod

COVID-19 – (angl. coronavirus disease 2019); koronavirusna bolezen 2019

EHW – (angl. Additive Extended Holt-Winters method); razširjena aditivna Holt-Wintersova metoda

EU – Evropska unija

MAE – (angl. mean absolute error); povprečna absolutna napaka

MAPE – (angl. mean absolute percentage error); povprečna odstotna napaka

MHW – (angl. Multiplicative Holt-Winters method); multiplikativna Holt-Wintersova metoda

MSE – (angl. mean squared error); povprečna kvadratna napaka

SES – (angl. Simple exponential smoothing); enostavno eksponentno glajenje

SURS – Statistični urad Republike Slovenije

ZDA – Združene države Amerike

1 UVOD

Registracije osebnih avtomobilov predstavljajo eno izmed ključnih kategorij uradnih statističnih podatkov, saj omogočajo spremljanje dinamike avtomobilskega trga, vedenja potrošnikov in odzivnosti gospodinjstev na širše gospodarske razmere. Poseben pomen ima kategorija prvih registracij navadnih osebnih avtomobilov fizičnih oseb, ki neposredno odraža zasebno mobilnost in trg novega lastništva. Število registracij ni zgolj tehnični podatek. V njem se odražajo cikli gospodarske rasti, odziv na cenovne spremembe, dostopnost financiranja ter vplivi okoljskih in zakonodajnih ukrepov (Klein in drugi, 2021; ACEA, 2025).

Slovenija kot del evropskega trga vozil kaže podobne sezonske in trendne vzorce kot druge članice Evropske unije (v nadaljevanju EU). Značilna so sezonska nihanja s poudarjenimi vrhovi v spomladanskih in jesenskih mesecih ter dolgoročnimi trendi, povezanimi z gospodarskimi cikli, davčno politiko in tehnološkim razvojem. Dolgoročni trend naraščanja motorizacije je bil prekinjen z letom 2020, ko je pandemija koronavirusne bolezni 2019 (angl. coronavirus disease 2019, v nadaljevanju COVID-19) povzročila izrazit prelom v obsegu prodaje in povpraševanja (Frieske in Stieler, 2022).

V teh razmerah je postalo napovedovanje registracij vozil še pomembnejše, hkrati pa tudi zahtevnejše. Natančne napovedi so ključne za strateško načrtovanje tako pri uvoznikih in prodajalcih kot pri državnih organih, ki na podlagi registracij oblikujejo davčne ukrepe, okoljske spodbude in prometne politike. Izbira zanesljivih statističnih metod napovedovanja, ki upoštevajo sezonske vzorce, dolgoročne trende in nenadne spremembe, je prav zato ključna za učinkovito odločanje.

Namen naloge je oceniti natančnost napovedovanja različnih metod časovnih vrst pri napovedovanju mesečnega števila prvih registracij navadnih osebnih avtomobilov fizičnih oseb v Sloveniji za obdobje 2015–2024. Poudarek je na metodah eksponentnega glajenja: enostavnem eksponentnem glajenju, Holtovi metodi, aditivni Holt-Wintersovi metodi, multiplikativni Holt-Wintersovi metodi ter razširjeni aditivni Holt-Wintersovi metodi. Te metode so primerne za časovne vrste z izraženo sezonskostjo in trendom ter zahtevajo manj kompleksnih predpostavk.

Za merjenje natančnosti napovedi bodo uporabljeni trije kazalniki: povprečna kvadratna napaka, povprečna absolutna napaka in povprečna odstotna napaka. Uporabljena bo tudi Theilova U-statistika, ki omogoča primerjavo uspešnosti metod glede na naivno metodo (Hyndman in Athanasopoulos, 2018).

Analiza bo izvedena ločeno za učno množico (2017–2023) in testno množico (2024), s čimer bo preverjena sposobnost metod za napovedovanje še nevidenih podatkov. Posebnost naloge je dodatna analiza, v kateri je leto 2020 izključeno, kar omogoča vpogled v vpliv izrednih dogodkov na kakovost napovedi in robustnost posameznih metod.

Raziskava s svojo praktičnostjo prispeva k boljšemu razumevanju in napovedovanju dogajanj na trgu v pogojih nestabilnosti. Rezultati bodo prispevali k boljši izbiri metod napovedovanja v podjetjih in institucijah ter k splošnemu razumevanju, kako različne metode obvladujejo kompleksne podatkovne strukture. Cilj naloge je prepoznati metodo, ki združuje natančnost, stabilnost in prilagodljivost, tako v stabilnih kot netipičnih razmerah, ter s tem prispevati k učinkovitejšemu napovedovanju registracij vozil v Sloveniji.

2 PRVA REGISTRACIJA NAVADNIH OSEBNIH AVTOMOBILOV FIZIČNIH OSEB

Registracija vozila je pomemben administrativni postopek, ki omogoča zakonito uporabo vozila v cestnem prometu. Z vidika analize trga vozil in mobilnosti prebivalstva je število prvih registracij eden izmed ključnih kazalnikov, saj odraža dejanski vstop vozil v nacionalni prometni sistem. Podatki o registracijah omogočajo vpogled v dinamiko povpraševanja po osebnih vozilih, kar je povezano tako z gospodarskimi cikli kot s spremembami potrošniških navad in tehnološkim razvojem v avtomobilski industriji (ACEA, 2025; Klein in drugi, 2021).

V Sloveniji beležimo dolgoročen trend povečevanja motorizacije vse do leta 2019, ko je bil prekinjen s pojavom pandemije COVID-19. Pandemija je leta 2020 povzročila precejšen padec števila registracij, predvsem zaradi začasnih zaprtij avtomobilskih salonov, motenj v dobavnih verigah in splošne negotovosti glede gospodarske prihodnosti (KPMG Slovenija, brez datuma; Frieske in Stieler, 2022).

Podatki o prvi registraciji so razdeljeni na nove registracije (ko vozilo prihaja neposredno iz proizvodnje) ter rabljene registracije, kar pomeni, da vozilo predhodno še ni bilo registrirano v Sloveniji, vendar je lahko že bilo v uporabi v tujini (SURs, brez datuma). V praksi to pomeni, da med prvo registracijo štejemo tudi uvoz rabljenih vozil.

2.1 Pravna in statistična definicija pojmov

Prva registracija osebnega avtomobila pomeni, da je bilo vozilo prvič evidentirano v registracijskem sistemu Republike Slovenije in predhodno še ni bilo registrirano v nobeni evidenci slovenskih oblasti (SURs, brez datuma). Pojem »prva registracija« zajema tako nova vozila kot tudi rabljena vozila, ki so bila predhodno registrirana v tujini, a so zdaj prvič vključena v slovenski prometni sistem (Ministrstvo za javno upravo, brez datuma).

Navadni osebni avtomobili so motorna vozila, zasnovana primarno za prevoz oseb. Definicija vključuje vozila kategorije M1, ki imajo poleg sedeža za voznika največ osem dodatnih sedežev (ACEA, 2025). Ta definicija sledi standardom Evropske unije in je ključna za pravno in statistično kategorizacijo vozil. Registracije fizičnih oseb zajemajo le tista vozila, ki so registrirana na posameznike za zasebno uporabo, kar izključuje vozila,

registrirana na podjetja, pravne osebe, samostojne podjetnike, občine ali druge javne institucije (Ministrstvo za javno upravo, brez datuma).

Podatki o registracijah se zbirajo preko registracijskih organizacij, ki imajo pooblastilo za izvajanje postopkov registracije. Ti podatki se nato konsolidirajo in objavljajo preko Statističnega urada Republike Slovenije ter Portala odprtih podatkov Slovenije (SURS, brez datuma; Ministrstvo za javno upravo, brez datuma). Pravna in statistična podlaga omogočata natančno spremljanje trenda motorizacije in s tem tudi vpogled v razvoj mobilnosti slovenskega prebivalstva.

Pomeni teh definicij se dodatno kažejo v možnosti sledenja trendom prenove voznega parka, kar ima pomembne posledice za okoljsko trajnost, varnost v cestnem prometu ter za širše gospodarsko okolje (Fronteli in Pacheco Paladini, 2023). Uvedba jasnih kategorij je torej ključna za enotno obravnavo podatkov ter omogoča primerljivost z evropskimi statistikami.

2.2 Vloga registracij pri spremljanju gospodarskih gibanj

Podatki o prvi registraciji osebnih avtomobilov fizičnih oseb veljajo za pomemben gospodarski kazalnik. Povečanje števila registracij navadno kaže na večje zaupanje potrošnikov in izboljšane gospodarske razmere, medtem ko upad registracij pogosto odraža gospodarsko negotovost ali zmanjšanje razpoložljivega dohodka prebivalstva (Klein in drugi, 2021).

Registracije novih ali rabljenih vozil neposredno vplivajo tudi na povezanost avtomobilskega sektorja z drugimi gospodarskimi dejavnostmi, kot so zavarovalništvo, registracijski centri, avtomobilski servisi in trgovci z vozili. To pomeni, da gibanje števila registracij vpliva na številne dele gospodarstva, kar se je zelo jasno pokazalo v obdobju pandemije COVID-19. V letu 2020 je bil zaznan drastičen upad števila registracij, kar je bila posledica tako gospodarske negotovosti kot tudi dejanskih omejitev gibanja in začasnih zaprtij avtomobilskih salonov (KPMG Slovenija, brez datuma; ACEA, 2021).

Poleg spremljanja gospodarskih ciklov imajo podatki o registracijah pomembno vlogo pri ocenjevanju uspešnosti različnih politik, denimo subvencij za električna vozila. Eko sklad Republike Slovenije že več let izvaja programe spodbud za nakup okolju prijaznejših vozil, kar vpliva na rast deleža električnih in hibridnih vozil v skupnih registracijah (Eko sklad, 2023). Registracije niso zgolj številka, ampak so pomemben indikator splošnega gospodarskega zdravja ter orodje za ocenjevanje učinkov okoljskih in prometnih politik.

2.3 Dejavniki, ki vplivajo na število registracij

Na število prvih registracij navadnih osebnih avtomobilov fizičnih oseb vpliva širok nabor dejavnikov. Med najpomembnejšimi so makroekonomski dejavniki, kot so rast bruto domačega proizvoda (v nadaljevanju BDP), stopnja zaposlenosti, razpoložljivi dohodek

gospodinjstev in splošno potrošniško zaupanje (Klein in drugi, 2021). Višja rast BDP in večje zaupanje prebivalstva običajno spodbujata nakupe avtomobilov, medtem ko negotove gospodarske razmere povzročajo upad registracij.

Pomemben vpliv imajo tudi cenovni dejavniki, kot so cene vozil, cene goriva in dostopnost financiranja prek leasingov in kreditov. Po podatkih Office for National Statistics (2024) lahko spremembe cen vozil pomembno vplivajo na povpraševanje, saj višje cene pogosto povzročijo upad registracij, še posebej med gospodinjstvi z nižjimi dohodki.

Strukturni dejavniki vključujejo demografske spremembe, urbanizacijo in razvoj prometne infrastrukture. V urbanih območjih z dobro razvito javno prometno mrežo je lahko povpraševanje po osebnih vozilih manjše, medtem ko v podeželskih regijah avtomobil ostaja nepogrešljivo prevozno sredstvo (SURS, brez datuma).

Poseben dejavnik, ki je v zadnjih letih močno vplival na število registracij, je bil tehnološki napredek v avtomobilski industriji, zlasti razvoj električnih vozil. Pomembne so tudi okoljske politike, ki vključujejo omejitve za starejša vozila z visokimi emisijami ter spodbude za nakup okolju prijaznejših vozil (Frieske in Stieler, 2022; ACEA, 2025).

Na število prvič registriranih navadnih osebnih avtomobilov pa ima velik vpliv tudi stanje v globalnih dobavnih verigah. Polprevodniška kriza, ki je nastala kot posledica pandemije COVID-19, je močno prizadela avtomobilsko industrijo in povzročila zamude pri dobavi novih vozil, kar je posredno vplivalo na dinamiko registracij (Frieske in Stieler, 2022).

3 TRENUTNO STANJE AVTOMOBILSKE INDUSTRIJE V SLOVENIJI IN EVROPI

Avtomobilska industrija je ena izmed ključnih gospodarskih panog v Evropi, saj neposredno in posredno zaposluje milijone ljudi ter predstavlja pomemben delež BDP (ACEA, 2021). V Sloveniji ima avtomobilski trg sicer manjšo vlogo kot v večjih evropskih državah, vendar je kljub temu pomemben del nacionalnega gospodarstva. Dogajanje na evropskem trgu pomembno vpliva tudi na slovenski trg, saj je večina novih vozil uvoženih in so gibanja odvisna od razmer v dobavnih verigah in proizvodnji (Klein in drugi, 2021).

V zadnjih letih, predvsem po letu 2020, se je avtomobilska industrija znašla pod velikim pritiskom zaradi kombinacije različnih dejavnikov npr. pandemije COVID-19, motenj v dobavnih verigah, pomanjkanja ključnih komponent ter prestrukturiranja v smer elektrifikacije in trajnosti (Frieske in Stieler, 2022).

3.1 Pregled razmer na avtomobilskem trgu po letu 2020

Po letu 2020 je evropski avtomobilski trg doživel velike spremembe. Leto 2020 je bilo zaradi pandemije eno najbolj turbulentnih v zadnjih desetletjih; število novih registracij je upadlo

za približno 24 %, kar predstavlja najnižjo raven v zadnjih 20 letih (ACEA, 2021). V Sloveniji je bil upad nekoliko manjši, vendar še vedno občuten, saj se je avtomobilski trg skrčil zaradi zaprtij prodajnih salonov in negotovosti med kupci (KPMG Slovenija, brez datuma).

V obdobju 2021–2023 so se razmere postopoma stabilizirale, vendar okrevanje ni bilo linearno. Prodaja je bila še vedno pod vplivom globalnih motenj in sprememb v strukturi povpraševanja. Še posebej je bilo zaznano povečano zanimanje za okolju prijaznejša vozila, kar je delno rezultat politik EU, ki spodbujajo prehod na električna vozila (ACEA, 2025).

Slovenski avtomobilski trg je v tem obdobju sledil evropskim trendom. Leta 2024 je po podatkih Avto-moto zveze Slovenije prodaja sicer rahlo okrevala, a je na trgu opazen trend zmanjševanja registracij nekaterih blagovnih znamk, na primer Tesle, ki je beležila največji padec (Avto-moto zveza Slovenije, 2025).

3.2 Izzivi v dobavnih verigah in pomanjkanje komponent

Po letu 2020 se je avtomobilska industrija soočila z večstopenjskimi izzivi v dobavnih verigah, ki so močno vplivali na proizvodnjo in razpoložljivost vozil. Eden največjih izzivov je bilo pomanjkanje ključnih komponent, zlasti polprevodnikov, ki so bistveni za proizvodnjo modernih vozil. Zaradi povečanega povpraševanja po elektronskih napravah med pandemijo COVID-19 in motenj v proizvodnji proizvajalci avtomobilov niso imeli dovolj čipov, kar je povzročilo zamude pri proizvodnji in posledično vplivalo na število dobavljenih in registriranih vozil (Frieske in Stieler, 2022).

Dobavne verige so bile prizadete tudi zaradi logističnih težav, pomanjkanja delovne sile in strožjih okoljskih predpisov. To je vplivalo na celotno avtomobilsko industrijo, od proizvajalcev originalne opreme do trgovcev in servisnih centrov (KPMG Slovenija, brez datuma). Avto-moto zveza Slovenije (2025) je poročala, da so se ti problemi nadaljevali še v leto 2024, kar je povzročilo daljše čakalne dobe za nova vozila in vplivalo na odločitve kupcev, ki so se pogosto preusmerili na trg rabljenih vozil.

Dodatno kompleksnost je v zadnjem času povzročila zaostritev trgovinskih odnosov med ZDA in Kitajsko, ki je privedla do uvedbe visokih tarif na avtomobilske dele in surovine. V začetku leta 2025 je ameriška administracija uvedla 145 % uvozne dajatve na kitajska električna vozila in komponente, vključno z baterijami in redkimi surovinami, kar je vplivalo na globalne stroške proizvodnje. Kitajska je odgovorila s 125 % povračilnimi tarifami na izbrane ameriške proizvode, kar je dodatno poglobilo negotovost na svetovnem trgu (China Briefing, 2025).

Slovenija ni neposredna uvoznica kitajskih avtomobilskih komponent v velikih količinah, vendar vseeno globalni pritiski prek evropskega trga vplivajo tudi na nas. Višje cene komponent, podaljšani roki dobave in negotovost v dobavi električnih vozil se posledično

odražajo tudi v domačih registracijah, saj potrošniki čakajo dlje časa in se soočajo z višjimi cenami novih vozil (Avto-moto zveza Slovenije, 2025).

3.3 Vpliv dejavnikov na registracije

Na število registracij vozil po letu 2020 so vplivali številni dejavniki. Poleg omenjenih motenj v dobavnih verigah so bili ključni:

- spremembe v potrošniških navadah, saj so se ljudje v obdobju pandemije bolj osredotočili na varčevanje, kar je vplivalo na povpraševanje po novih vozilih (Klein in drugi, 2021);
- okrepitev okoljskih politik, ki spodbujajo nakup električnih in hibridnih vozil ter uvajajo strožje standarde za emisije, kar je vplivalo na strukturo registracij (ACEA, 2025);
- cenovna gibanja – povečanje cen vozil zaradi višjih proizvodnih stroškov in omejene ponudbe je vplivalo na odločanje potrošnikov (Office for National Statistics, 2024).

V Sloveniji je dodatni dejavnik predstavljala omejena dostopnost novih modelov določenih blagovnih znamk, kar je preusmerilo del povpraševanja v druge segmente (Avto-moto zveza Slovenije, 2025).

3.4 Vpliv pandemije koronavirusne bolezni 2019 na trg osebnih avtomobilov

Pandemija COVID-19 je pomenila prelomnico za svetovno avtomobilsko industrijo. Po poročanju ACEA (2021) je pandemija povzročila najhujšo krizo avtomobilskega trga v Evropi v zadnjih desetletjih, pri čemer so bile vse države članice EU prizadete v različnih stopnjah. V Sloveniji je bil vpliv pandemije viden predvsem v letu 2020, ko se je število prvih registracij zmanjšalo za več kot 20 % glede na leto 2019 (KPMG Slovenija, brez datuma).

Frieske in Stieler (2022) poudarjata, da je pandemija poleg neposrednega vpliva na povpraševanje sprožila tudi daljnosežne posledice za dobavne verige, kar je dolgoročno vplivalo na razpoložljivost vozil na trgu. Vpliv pandemije na avtomobilski sektor je bil globalen: proizvodnja se je zmanjšala, povpraševanje je upadlo, številne tovarne so bile prisiljene v začasno zaprtje, hkrati pa se je pojavilo pomanjkanje ključnih komponent (Statista, brez datuma).

Med pandemijo so bile uvedene tudi novosti v poslovnih modelih, kot so digitalna prodaja in dostava vozil na dom, kar je nekoliko omililo posledice zaprtja fizičnih salonov (Klein in drugi, 2021), vendar pa so bile te spremembe predvsem kratkoročne rešitve in niso nadomestile splošnega upada povpraševanja. Okrevanje po pandemiji je bilo postopno, a so posledice, kot so višje cene in omejena razpoložljivost vozil, trajale še več let po začetku krize (Avto-moto zveza Slovenije, 2025).

4 NAPOVEDOVANJE Z METODAMI ČASOVNIH VRST

Napovedovanje časovnih vrst je ena od ključnih statistik in analitičnih metod, ki omogoča napovedovanje prihodnjih vrednosti na podlagi že znanih zgodovinskih podatkov. V kontekstu spremljanja trga avtomobilov, zlasti registracij navadnih osebnih avtomobilov fizičnih oseb v Sloveniji, ima napovedovanje poseben pomen, saj pomaga napovedati povpraševanje, načrtovati kapacitete in sprejemati strateške odločitve (Hyndman in Athanasopoulos, 2018; Ferbar Tratar in drugi, 2016).

Registracije vozil so značilen primer časovne vrste z izrazitimi sezonskimi vzorci in dolgoročnimi trendi, ki jih je treba natančno modelirati za pridobitev ustreznih napovedi (Fronteli in Pacheco Paladini, 2023).

4.1 Namen, uporabnost in vrste napovedovanja

Namen napovedovanja v tej raziskavi je podati realistično, podatkovno utemeljeno oceno prihodnjih gibanj števila prvič registriranih navadnih osebnih avtomobilov fizičnih oseb v Sloveniji. Takšna napovedovanja imajo pomembno vlogo pri strateškem in operativnem odločanju v različnih sektorjih. V kontekstu avtomobilskega trga pomagajo trgovcem pri boljši pripravi na sezonska nihanja v povpraševanju, učinkovitejšem planiranju zalog in doseganju prodajnih ciljev.

Za vlado in lokalne skupnosti so ti podatki ključni za spremljanje mobilnosti prebivalstva, načrtovanje prometne infrastrukture ter ocenjevanje napredka pri doseganju trajnostnih ciljev. Na podlagi gibanja registracij lahko oblasti tudi pravočasno prilagajajo davčne politike, uvedejo ali ukinejo subvencije ter spremljajo vpliv zakonodajnih ukrepov. Finančne institucije in zavarovalnice se pri razvoju produktov, kot so avtomobilski krediti, leasingi ali avtomobilska zavarovanja, zanašajo na natančne napovedi prihodnjih registracij, saj jim te omogočajo ustrezno oceno tveganj in potenciala trga.

Napovedi so koristne tudi za vrednotenje učinkovitosti okoljevarstvenih politik, zlasti tistih, ki vključujejo spodbude za nakup električnih in hibridnih vozil. Gibanje registracij lahko služi kot kazalnik uspešnosti teh ukrepov in pripomore k nadaljnjemu razvoju nacionalnih strategij za zmanjšanje emisij iz prometa (ACEA, 2025; da Veiga in drugi, 2016).

Metode časovnih vrst so pri takšni vrsti podatkov še posebej primerne, saj omogočajo zaznavanje in modeliranje sezonskih ter dolgoročnih vzorcev. Pri podatkih o registracijah vozil je značilno, da se določeni vzorci, kot je povečano število registracij v spomladanskih in jesenskih mesecih, ponavljajo skozi leta. Ravno zato so napovedi, ki upoštevajo te redne cikle, bistveno bolj uporabne in natančne (Hyndman in Athanasopoulos, 2018).

4.2 Pregled metod napovedovanja

Napovedovanje časovnih vrst vključuje širok nabor metod, ki se razlikujejo glede na kompleksnost, prilagodljivost in primernost za določene značilnosti podatkov. V določanju najustrežnejše metode so uporabljene metode eksponentnega glajenja, saj so posebej primerne za podatke, pri katerih se pojavljajo trendi in sezonski vzorci, kot je to značilno za registracije osebnih avtomobilov. Prednost teh metod je v tem, da omogočajo sprotno prilagajanje napovedi glede na spremembe v podatkih, hkrati pa zahtevajo relativno malo podatkovnih predpostavk.

4.2.1 Enostavno eksponentno glajenje

Enostavno eksponentno glajenje (angl. Simple exponential smoothing, v nadaljevanju SES) je osnovna metoda napovedovanja časovnih vrst, ki predpostavlja, da v podatkih ni prisotnih trendnih ali sezonskih komponent. Deluje tako, da izračunava napovedi na podlagi glajenja preteklih vrednosti in napovedi, pri čemer novejša opazovanja dobijo večjo težo. Metoda uporabi parameter glajenja α , katerega vrednost je med 0 in 1 in določa, kako hitro se model odziva na spremembe v podatkih (Hyndman in Athanasopoulos, 2018).

Matematično je metoda opisana z naslednjo enačbo (1):

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (1)$$

kjer je:

- F_{t+1} – napoved za naslednjo periodo ($t+1$),
- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- F_t – napoved za trenutno periodo t ,
- α – parameter glajenja, $\alpha \in [0,1]$.

Večja kot je vrednost α , večji vpliv ima zadnja vrednost na novo napoved. Pri $\alpha = 1$ napoved vedno sledi zadnji vrednosti vrste, pri $\alpha = 0$ pa se sploh ne spreminja.

Metoda SES ustvarja napovedi, ki se stabilizirajo na določeni ravni in se ne spreminjajo, razen če pride do spremembe v novem podatku glede na stare podatke. Zaradi svoje enostavne zasnove je metoda primerna predvsem za časovne vrste, kjer so vrednosti konstantne ali se naključno spreminjajo okoli povprečne vrednosti. Zaradi svoje robustnosti in minimalnih predpostavk se SES pogosto uporablja kot referenčni model v primerjalnih analizah. Čeprav ni primerna za vrste z izrazitim trendom ali sezonskimi vplivi, se pogosto uporablja kot izhodišče za bolj kompleksne metode, kot so Holtove ali Holt-Wintersove različice (Winters, 1960; Davalos, 2024).

4.2.2 Holtova metoda

Holtova metoda (poznana tudi kot metoda dvojnega eksponentnega glajenja) uvaja komponento za trend in s tem omogoča napovedovanje časovnih vrst, kjer se nivo vrste spreminja linearno skozi čas (Holt, 2004; Hyndman in Athanasopoulos, 2018). Gre za nadgradnjo metode SES, ki modelira tako raven (nivo) kot tudi smer gibanja (trend).

Glavne značilnosti Holtove metode (Ferbar Tratar, 2015):

- uporablja dva ločena parametra: α za glajenje ravni (nivoja) in β za glajenje trenda,
- primerna je za časovne vrste brez sezonskih nihanj, ki kažejo linearni naraščajoč ali padajoč trend,
- omogoča ustvarjanje napovedi, ki se s časom linearno povečujejo ali zmanjšujejo, skladno z ugotovljenim trendom v podatkih.

Matematično je metoda izražena s tremi enačbami (2), (3), (4):

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

$$F_{t+m} = L_t + b_t m \quad (4)$$

kjer je:

- L_t – ocena za raven (nivo) v periodi t ,
- T_t – ocena za trend v periodi t ,
- F_{t+m} – napoved za m obdobj vnaprej,
- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- α – parameter glajenja, $\alpha \in [0,1]$,
- β – parameter glajenja, $\beta \in [0,1]$.

Prva enačba posodablja raven glede na trenutno vrednost podatka in oceno za nivo ter trend v prejšnji periodi. Druga izračuna, kako hitro se spreminja raven oz. trend. Tretja poda napoved za prihodnja obdobja, kjer se na izglajeno raven doda napovedana sprememba (trend), pomnožena s številom obdobj.

Holtova metoda je še posebej uporabna v situacijah, kjer je trend izrazit, vendar ni prisotne sezonskosti, npr. v obdobjih po enkratnih šokih, kot je bil padec registracij med pandemijo COVID-19, ko je potrebno trend ponovno ujeti in razširiti v prihodnost. V takih primerih se lahko Holtova metoda zaradi svoje preprostosti in hitrosti izkaže za zelo stabilno in zanesljivo rešitev (Ferbar Tratar in drugi, 2016).

4.2.3 Aditivna Holt-Wintersova metoda

Aditivna Holt-Wintersova metoda (angl. Additive Holt-Winters method, v nadaljevanju AHW) je nadgradnja Holtove metode, saj poleg ravni in trenda vključuje še sezonsko komponento, ki jo modelira na aditiven način. Metoda je posebej primerna za časovne vrste, kjer je sezonski učinek skozi čas konstanten v absolutnem znesku, torej ni odvisen od višine nivoja (Hyndman in Athanasopoulos, 2018). V primeru registracij vozil se tak vzorec pojavlja, kadar so sezonska nihanja (npr. pomladna rast in poletni upad) približno enaka iz leta v leto.

Glavne značilnosti metode AHW:

- uporablja tri parametre: α (za glajenje ravni), β (za trend) in γ (za sezonskost),
- primerna je za časovne vrste z aditivno sezonsko komponento – kadar so sezonska nihanja stalna ne glede na raven časovne vrste,
- omogoča napovedovanje s konstantnimi sezonskimi razlikami med posameznimi obdobji (npr. med meseci v letu).

Matematično je metoda razložena z naslednjimi enačbami (5), (6), (7) in (8):

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (7)$$

$$F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (8)$$

kjer je:

- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- L_t – ocena za raven (nivo) v periodi t ,
- F_{t+m} – napoved za m obdobj vnaprej,
- b_t – ocena trenda v periodi t ,
- S_t – ocena sezonskega indeksa v periodi t ,
- s – dolžina sezone,
- α, β, γ – parametri glajenja, $\alpha, \beta, \gamma \in [0,1]$.

Metoda AHW bi bila primerna za napovedovanje naše časovne vrste, če ugotovimo, da registracije vozil vsako leto upadejo ali narastejo za približno enako število enot (ne pa sorazmerno z višino trga). Napovedi so sestavljene iz treh komponent: ocene ravni, ocene trenda in ocene sezonske komponente, pri čemer se sezonski vzorec periodično obnavlja glede na dolžino sezone (npr. 12 mesecev).

Kot ena najzanesljivejših, se metoda AHW izkaže pri napovedovanju časovnih vrst z izrazito, vendar stabilno sezonskostjo. Zaradi svoje pregledne strukture in enostavne interpretacije je metoda pogosto prva izbira v praksi, kadar je zaznana sezonska komponenta brez spreminjajoče se amplitude (Ferbar Tratar in drugi, 2016).

4.2.4 Multiplikativna Holt-Wintersova metoda

Multiplikativna Holt-Wintersova metoda (angl. Multiplicative Holt-Winters method, v nadaljevanju MHW) predstavlja razširjen model eksponentnega glajenja, ki upošteva raven, trend in sezonskost, pri čemer je sezonska komponenta modelirana na multiplikativni način. Tak pristop je primeren za časovne vrste, pri katerih velikost sezonskih nihanj ni konstantna, temveč se povečuje ali zmanjšuje sorazmerno z rastjo ali padcem osnovnega nivoja (Ferbar Tratar in drugi, 2016).

Model uporablja tri parametre glajenja: α za raven, β za trend in γ za sezonskost. Sezonski faktorji so definirani kot odstotne prilagoditve glede na raven, kar omogoča, da se moč sezonskega učinka spreminja skupaj z velikostjo časovne vrste. To pomeni, da bodo npr. sezonski vrhovi višji v obdobjih rasti in nižji v obdobjih padca (Hyndman in Athanasopoulos, 2018).

Matematično je multiplikativna metoda definirana z naslednjimi enačbami (9), (10), (11) in (12):

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (9)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (10)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (11)$$

$$F_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (12)$$

kjer je:

- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- L_t – ocena za raven (nivo) v periodi t ,
- F_{t+m} – napoved za m obdobj vnaprej,
- b_t – ocena trenda v periodi t ,
- S_t – ocena sezonskega indeksa v periodi t ,
- s – dolžina sezone (npr. 12 za mesečne podatke),
- α, β, γ – parametri glajenja, $\alpha, \beta, \gamma \in [0,1]$.

Takšna metoda je posebej uporabna za napovedovanje registracij osebnih avtomobilov, kjer se v nekaterih letih pojavijo izrazita nihanja zaradi gospodarskih ciklov ali zunanjih vplivov, kar vpliva tudi na sezonsko dinamiko. V obdobjih splošne rasti trga so lahko spomladanski

ali jesenski vrhovi precej bolj izraziti kot v stabilnih letih, zato aditivna sezonskost ne bi zadostovala (Davalos, 2024).

Po ugotovitvah Holtovega izvirnega pristopa in kasnejših razširitev Wintersove metode se multiplikativni model izkaže kot zanesljivejši pri podatkih z relativnimi, odstotnimi sezonskimi razlikami (Winters, 1960; Holt, 2004). V praksi je model pogosto uporabljen v primerih, kjer sezonski učinki niso stabilni, temveč rasteta njihova moč in amplituda skupaj z ravno (nivojem) celotne vrste.

4.2.5 Razširjena aditivna Holt-Wintersova metoda

Razširjena aditivna Holt-Wintersova metoda (angl. Additive Extended Holt-Winters method, v nadaljevanju EHW) je napredna različica klasične aditivne Holt-Wintersove metode, namenjena natančnejšemu modeliranju časovnih vrst s sezonskimi in trendnimi komponentami. V primerjavi z osnovnim modelom AHW vključuje bolj fleksibilno določanje sezonskih indeksov, kar povečuje natančnost napovedi pri kompleksnih podatkovnih nizih (Davalos, 2024; Hyndman in Athanasopoulos, 2018).

Metoda EHW ohranja aditivni pristop, kar pomeni, da sezonski učinki delujejo kot stalne absolutne vrednosti, neodvisne od ravni vrste. Uporablja štiri parametre, α , β , γ in δ . Dodani parameter δ je vsebovan v enačbi za nivo vrste, in sicer omogoča, da se sezonski indeksi še dodatno gladijo. To je še posebej pomembno pri časovnih vrstah, kjer trend ni stabilen skozi celotno obdobje, kot na primer v letih, zaznamovanih z nenadnimi šoki.

Matematično se od metode AHW razlikuje le v enačbi za nivo vrste (5). Ostale enačbe (6, 7 in 8) ostanejo nespremenjene.

Enačba za nivo vrste pri EHW (13):

$$L_t = \alpha Y_t - \delta S_{t-s} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (13)$$

kjer je:

- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- L_t – ocena za raven (nivo) v periodi t ,
- L_{t-1} – ocena za raven v prejšnji periodi,
- b_{t-1} – ocena trenda v prejšnji periodi,
- S_{t-s} – ocena sezonskega indeksa v periodi $t-s$,
- s – dolžina sezone (npr. 12 za mesečne podatke),
- α, δ – parametra glajenja, $\alpha, \delta \in [0,1]$.

Metoda EHW se v primerjavi s klasično aditivno Holt-Wintersovo metodo izkaže za posebej uporabno pri napovedovanju časovnih vrst z izrazitim šumom, neenakomerno sezonskostjo ali izrazitimi prelomnicami. Dodatni parameter δ omogoča dodatno glajenje vpliva sezonske

komponente pri ocenjevanju ravni časovne vrste, kar se odrazi v stabilnejših in zanesljivejših napovedih. Z vključitvijo tega parametra se napake napovedovanja bistveno zmanjšajo, zlasti pri kratkoročnih napovedih in v primerih, kjer vrsta vsebuje nepravilnosti ali strukturne spremembe. EHW združuje prednosti enostavnega modeliranja in prilagodljivosti, zaradi česar je primerna tudi za zahtevnejše podatkovne nize, kot so registracije vozil, ki so pogosto pod vplivom zunanjih šokov (npr. pandemije, sprememb zakonodaje ali gospodarskih razmer) (Ferbar Tratar in drugi, 2016).

4.3 Merjenje natančnosti napovedi

Za učinkovito primerjavo metod napovedovanja je potrebno uporabiti ustrezne kazalnike napak, ki omogočajo oceno razlike med napovedanimi in dejanskimi vrednostmi. Nobena metoda ni univerzalno najboljša, saj je njena uspešnost odvisna od strukture podatkov, prisotnosti trendov in sezonskih komponent. Smiselna je uporaba več kazalnikov hkrati, saj vsak izpostavi drugačen vidik natančnosti. V tej nalogi bodo uporabljeni trije standardni metrični kazalniki: povprečna kvadratna napaka (angl. mean squared error, v nadaljevanju MSE), povprečna absolutna napaka (angl. mean absolute error, v nadaljevanju MAE) in povprečna odstotna napaka (angl. mean absolute percentage error, v nadaljevanju MAPE) (Hyndman in Athanasopoulos, 2018).

MSE meri povprečno kvadratno napako med napovedano in dejansko vrednostjo podatka. Zaradi kvadriranja napak daje večjo težo večjim odstopanjem in je zato še posebej občutljiva na velike napake. To je koristno, kadar želimo, da kazalnik močneje poudari intervale napak, v katerih napovedi močno odstopajo od dejanskih podatkov. Ta občutljivost napake pomeni tudi, da lahko že nekaj večjih napak nesorazmerno vpliva na končno vrednost MSE, kar lahko vodi do napačne interpretacije natančnosti pri časovnih vrstah z redkimi, a izrazitimi odkloni (npr. med pandemijo COVID-19).

MSE enačbi (14) in (15):

$$MSE = \frac{1}{2} \sum_{t=1}^n e_t^2 \quad (14)$$

$$e_t = Y_t - F_t \quad (15)$$

kjer je:

- e_t – napaka napovedi v periodi t ,
- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- F_t – napoved za trenutno periodo t ,
- n – število opazovanih obdobj.

MAE meri povprečno absolutno napako in je bolj robustna kot MSE, saj vse napake obravnava enako, ne glede na njihovo velikost. Njena interpretacija predstavlja povprečni odklon napovedi od dejanske vrednosti. Prav zato je MAE pogosto prva izbira pri ocenjevanju uspešnosti metod, kadar želimo realen povprečni prikaz napake napovedovanja.

MAE enačbi (15) in (16):

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (16)$$

kjer je:

- e_t – napaka napovedi v periodi t ; enačba (14),
- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- F_t – napoved za trenutno periodo t ,
- n – število opazovanih obdobj.

MAPE meri povprečno absolutno relativno napako in omogoča primerjavo napak med obdobji ali različnimi podatkovnimi vrstami. Ker upošteva relativno razmerje med napako in dejansko vrednostjo, je še posebej uporabna pri vrstah z različno ravno vrednosti, kot je primer registracij vozil, kjer so razlike med meseci velike. Slabost MAPE je njena občutljivost na zelo nizke vrednosti, kjer že majhna napaka lahko povzroči visoko odstotno odstopanje (Davalos, 2024). Dodatna slabost MAPE je pri uporabi časovnih vrst, ki vsebujejo podatke z vrednostjo 0, saj v tem primeru relativne napake ne moremo izračunati.

MAPE enačbi (17) in (18):

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t| \quad (17)$$

$$PE_t = \frac{Y_t - F_t}{Y_t} \cdot 100 \quad (18)$$

kjer je:

- PE_t – odstotna napaka napovedi v periodi t ,
- Y_t – dejanska vrednost opazovanega podatka v periodi t ,
- F_t – napoved za trenutno periodo t ,
- n – število opazovanih obdobj.

Ključ do realne ocene uspešnosti metod je v kombinirani uporabi več metod, saj se metode med seboj razlikujejo ne le v konstrukciji, ampak tudi v odzivu na variabilnost podatkov (Ferbar Tratar, 2015). Izbira napačne metode lahko povzroči zavajajoče sklepe o tem, katera metoda je najboljša oz. najbolj primerna. Na primer, model z zelo nizkim MSE morda kaže

visoko MAPE, kar pomeni, da je razmeroma slabši pri nizkih vrednostih – kar je v realnosti pomembna ugotovitev (Ferbar Tratar in drugi, 2016).

V tej raziskavi bodo napake napovedovanja analizirane z vsemi tremi kazalniki, in sicer tako za celotno obdobje kot tudi ločeno brez leta 2020. To bo omogočilo dodatno presojo, kako odporne so posamezne metode na izredne dogodke in koliko se njihova natančnost spremeni v obdobjih šokov ali nepričakovanih odklonov (Klein in drugi, 2021; Ferbar Tratar, 2015). Tako bo tak pristop zagotavljal objektivno in podatkovno utemeljeno izbiro najbolj ustrezne metode za napovedovanje prihodnjih registracij.

Za dodatno preverjanje napak bo v izračunih uporabljen tudi relativni kazalnik Theilova U-statistika, ki omogoča oceno, ali je izbrana metoda napovedovanja boljša od preproste (naivne) metode, ki za napoved preprosto uporabi zadnjo razpoložljivo dejansko vrednost.

Naivna metoda je ena najosnovnejših metod napovedovanja, pri kateri se predpostavi, da bo prihodnja vrednost enaka zadnji znani vrednosti časovne vrste. Uporablja se kot model, s katerim primerjamo uspešnost bolj kompleksnih metod. Zaradi svoje preprostosti je pogosto prva izbira pri začetnem ocenjevanju natančnosti napovedi (Hyndman in Athanasopoulos, 2018).

Enačba za napoved pri naivni metodi je (19):

$$F_t = Y_{t-1} \quad (19)$$

kjer je:

- F_t – napoved za trenutno periodo t ,
- Y_{t-1} – dejanska vrednost opazovanega podatka v prejšnji periodi $t-1$.

Čeprav je ta pristop zelo preprost, je najbolj učinkovit pri stabilnih časovnih vrstah brez izrazitih vzorcev ali v primerih, ko spremembe v podatkih sledijo naključnemu procesu (Hyndman in Athanasopoulos, 2018).

U-statistika je definirana kot (20):

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left(\frac{F_{t+1} - Y_{t+1}}{Y_t} \right)^2}{\sum_{t=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}} \quad (20)$$

kjer je:

- F_{t+1} – napoved za naslednjo periodo $t+1$,
- Y_{t+1} – dejanska vrednost opazovanega podatka v naslednji periodi $t+1$,
- Y_t – dejanska vrednost opazovanega podatka v periodi t .

Če je vrednost $U < 1$, izbrana metoda napovedovanja napoveduje bolje kot naivna metoda; če je vrednost $U = 1$, je izbrana metoda napovedovanja enako dobra; če je $U > 1$, je izbrana metoda napovedovanja slabša od naivne metode. Ta statistika omogoča razmeroma neodvisno oceno uspešnosti in je posebej uporabna za primerjavo različnih metod pri časovnih vrstah z enostavno strukturo (Statistics How To, brez datuma).

5 NAPOVEDOVANJE REGISTRACIJ OSEBNIH AVTOMOBILOV

V tem delu je predstavljena analiza napovedovanja mesečnega števila prvih registracij navadnih osebnih avtomobilov fizičnih oseb v Sloveniji. Z uporabo metod časovnih vrst (SES, Holt, AHW, MHW, EHW) in minimiziranjem napak (MSE, MAE, MAPE) je bil cilj raziskati, katere metode zagotavljajo najbolj zanesljive napovedi v prisotnosti sezonskosti, trendov in izrednih dogodkov.

5.1 Predstavitev in analiza podatkovne baze

Kot podatkovna osnova je uporabljena časovna vrsta mesečnega števila prvič registriranih navadnih osebnih avtomobilov fizičnih oseb v Sloveniji, zajeta v obdobju od januarja 2015 do decembra 2024. Podatki so pridobljeni preko Statističnega urada Republike Slovenije (SURS). Osredotočajo se izključno na vozila, ki so prvič vključena v slovenski prometni sistem in registrirana na fizične osebe, kar izključuje podjetja, javne ustanove in druge pravne subjekte.

Podatkovna tabela vsebuje 120 mesečnih opazovanj in predstavlja neprekinjeno časovno vrsto z mesečnimi podatki. V podatkih ni manjkajočih vrednosti, kar omogoča neposredno uporabo za nadaljnje analize in modeliranje časovne vrste.


Za namen preverjanja je bila celotna vrsta razdeljena v tri obdobja:

- inicializacijsko obdobje (2015–2016), ki služi za nastavitev začetnih parametrov metod,
- učno obdobje (2017–2023), ki je namenjeno učenju metod napovedovanja,
- testno obdobje (2024), ki omogoča preverjanje natančnosti napovedi na novih podatkih.

Poseben poudarek je namenjen tudi letu 2020, ki predstavlja izjemen dogodek zaradi pandemije COVID-19. To leto kaže izrazito odstopanje v številu registracij zaradi zaprtij avtomobilskih salonov, motenj v dobavnih verigah in povečane negotovosti potrošnikov. Posledično je bil del analize za dve najboljši metodi opravljen dvakrat – enkrat z vključitvijo leta 2020 in drugič brez njega, da se oceni vpliv tega šoka na učinkovitost in uspešnost napovedi.

Na začetku analize je bil izveden vizualni pregled celotne časovne vrste. Splošna gibanja števila registracij skozi čas prikazuje slika 1, ki potrjuje prisotnost dolgoročnega trenda in sezonskih nihanj.


Slika 1: Prikaz mesečnega števila prvič registriranih navadnih osebnih avtomobilov fizičnih oseb v Sloveniji za obdobje 2015–2024



Vir: SURS (brez datuma).

S slike 1 je razvidna rahla rast števila registracij vse do leta 2019, nato izrazit padec v letu 2020 in postopno izboljšanje v letih 2021–2024, vendar brez doseganja predpandemskih ravni. Poleg sezonskosti je prisoten tudi strukturni prelom, zato bosta dve najboljši metodi izračunani še enkrat brez leta 2020. Za nadaljnjo potrditev sezonske strukture je bila oblikovana slika 2, ki prikazuje gibanja po mesecih za vsako leto posebej.


Slika 2: Prikaz sezonskosti za obdobje 2015–2024



Vir: lastno delo.

Slika 2 prikazuje sezonski vzorec; registracije so najvišje v marcu in aprilu, sledi manjše poletno znižanje, nato še en porast jeseni (september–oktober) in ponovno zmanjšanje v zimskih mesecih. Leto 2020 izstopa s precej nižjimi vrednostmi v več mesecih, kar je posledica izrednih razmer. Za kvantitativno oceno sezonskosti in preverjanje odvisnosti med podatki osnovne vrste ter vrste z zamikom enega, dveh, treh ... mesecev (za dvajset zamikov) je bila izvedena analiza avtokorelacijske funkcije (angl. Autocorrelation function, v nadaljevanju ACF), ki jo kaže slika 3.

Slika 3: Graf analize avtokorelacijske funkcije



Vir: lastno delo.

Slika 3 prikazuje izrazito visoko vrednost pri zamiku 1 meseca, kar pomeni, da obstaja močna povezava med zaporednimi meseci, torej se vrednosti iz meseca v mesec ne spreminjajo drastično. Pomemben vrh opazimo tudi pri zamiku 12, kar potrjuje prisotnost sezonskosti z letno periodičnostjo. To pomeni, da se vzorci registracij ponavljajo na letni ravni – npr. registracije marca 2023 so podobne registracijam marca 2022. Med zamiki od 1 do 12 ima najnižjo vrednost zamik za 6 mesecev, kar nakazuje na pojav antifaze – vrhovi se v poletnih mesecih prekrivajo z dolinami iz zimskih mesecev prejšnjega leta.

Negativna avtokorelacija pri zamiku 18 dodatno podpira ugotovitve o sezonski naravi vrste. Ker je 18 mesecev natanko leto in pol, se pri tem zamiku ponovno srečajo visoke in nizke vrednosti, kar povzroči negativno povezavo in dodatno potrjuje cikličnost z obdobji dolžine 12 mesecev.

5.2 Rezultati posameznih metod napovedovanja

5.2.1 Metoda enostavnega eksponentnega glajenja

Rezultati metode SES so predstavljeni v tabeli 1. V učni množici (obdobje 2015–2023, torej periode 25–109) se metoda izkaže za razmeroma uspešno – vse tri vrednosti Theilove U-

statistike (U (MSE), U (MAE) ter U (MAPE)) so nižje od 1, kar pomeni, da so napovedi vseh treh metod natančnejše od napovedi, izračunane z naivno metodo. Najnižjo vrednost doseže U (MAE) z vrednostjo 0,894.


Tabela 1: Vrednosti izračunov metode enostavnega eksponentnega glajenja

	UČNA MNOŽICA (25–109)	TESTNA MNOŽICA (110–121)
MSE	902.472,219	592.295,373
U (MSE)	0,901	1,017
MAE	683,170	648,245
U (MAE)	0,894	1,044
MAPE	16,404	12,301
U (MAPE)	0,898	1,089

Vir: lastno delo.

V testni množici (leto 2024, torej periode 110–121) se učinkovitost metode SES poslabša. Vse tri vrednosti U-napak presegajo vrednost 1, kar pomeni, da so bile napovedi manj natančne kot napovedi naivne metode. Tak rezultat je pričakovan, saj metoda SES ne upošteva sezonskosti in trendov, ki so značilni za obravnavano časovno vrsto. To je razvidno tudi s slike 4, kjer se napovedi metode SES ne odzivajo na sezonska nihanja; napovedi ostajajo skoraj konstantne, medtem ko dejanske vrednosti precej variirajo med posameznimi meseci.

Slika 4: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z metodo enostavnega eksponentnega glajenja



Vir: lastno delo.

Metoda SES je zaradi svoje preprostosti primerna predvsem za vrste brez izrazitega trenda in sezonskosti, zato je v tej analizi uporabljena predvsem kot referenca pri ocenjevanju uspešnosti bolj naprednih metod eksponentnega glajenja.

5.2.2 Holtova metoda

Holtova metoda, ki modelira tako raven kot trend časovne vrste, se v učni množici izkaže za solidno, kar je razvidno iz rezultatov v tabeli 2. Vrednosti napak MSE in MAE so nekoliko višje kot pri nekaterih drugih metodah, Theilova U-statistika ($MSE = 0,964$ in $MAE = 0,998$) pa kaže, da sta bili dve metodi na tem vzorcu še vedno natančnejši od naivne metode. Vrednost U (MAPE) že v učnem obdobju preseže 1, kar namiguje na težave metode pri napovedovanju manjših relativnih nihanj.

Tabela 2: Vrednosti izračunov Holtove metode


	UČNA MNOŽICA (25–109)	TESTNA MNOŽICA (110–121)
MSE	1.001.221,959	874.689,885
U (MSE)	0,964	1,235
MAE	743,307	979,479
U (MAE)	0,998	1,447
MAPE	16,646	21,219
U (MAPE)	1,027	1,740

Vir: lastno delo.

V testni množici se natančnost metode opazno poslabša. Vse tri U-statistike presežejo vrednost 1, kar pomeni, da je bila napoved v tem obdobju manj uspešna od napovedi naivne metode. Posebej izstopa $U (MAPE) = 1,740$, ki nakazuje precejšnje težave pri napovedovanju relativnih sprememb v registracijah, zlasti v mesecih, ko so bile vrednosti zelo nizke ali visoke.

Kot prikazuje slika 5, Holtova metoda zaradi odsotnosti sezonske komponente ne zazna ponavljajočih se mesečnih vzorcev. Napovedi so podcenile tako mesece z visokimi registracijami kot tudi mesece z nižjimi vrednostmi. Kot rezultat so povečane povprečna kvadratna, absolutna ter relativna napaka v testnem obdobju.

Slika 5: Primerjava dejanskih vrednosti in vrednosti, pridobljenih s Holtovo metodo



Vir: lastno delo.

Čeprav Holtova metoda vključuje komponento trenda in tako omogoča bolj fleksibilno dinamiko kot SES, se zaradi pomanjkanja sezonskega prilagajanja ne izkaže kot ustrezna za podatke, ki imajo jasno izraženo sezonskost. Takšna struktura je prisotna v analiziranih podatkih registracij vozil, kjer se vrhovi redno pojavljajo v določenih mesecih leta. Holtova metoda je tako bolj primerna za časovne vrste z linearnim trendom, a brez sezonskih nihanj.

5.2.3 Aditivna Holt-Wintersova metoda

AHW, ki vključuje trendno in sezonsko komponento, se je izkazala kot ena izmed najbolj učinkovitih metod v tej analizi. Rezultati, prikazani v tabeli 3, kažejo, da je metoda dosegla zelo dobre rezultate tako na učni kot tudi na testni množici. V vseh primerih so vrednosti U-statistike ostale pod vrednostjo 1, kar pomeni, da je bila metoda uspešnejša od naivne metode.

Tabela 3: Vrednosti izračunov aditivne Holt-Wintersove metode

	UČNA MNOŽICA (25–109)	TESTNA MNOŽICA (110–121)
MSE	682.288,446	322.144,965
U (MSE)	0,812	0,783
MAE	479,990	372,050
U (MAE)	0,843	0,627
MAPE	12,587	101,225
U (MAPE)	0,861	0,589


Vir: lastno delo.

V učnem obdobju se je metoda dobro prilagodila dinamiki časovne vrste. Napovedi so bile dovolj natančne v vseh treh pogledih (absolutnem, relativnem in kvadratnem), pri čemer so bile razlike v primerjavi z dejanskimi vrednostmi majhne in stabilne.

V testnem obdobju je AHW ohranila visoko natančnost napovedovanja. Najboljši rezultat je bil dosežen pri U (MAPE), ki je bil med vsemi primerjanimi metodami eden najnižjih. Visoka vrednost MAPE je posledica enega od mesecev z zelo nizko dejansko vrednostjo, ki povzroči zelo velik odstotek napake, kar je znana slabost tega kazalnika.

Slika 6 prikazuje primerjavo med dejanskimi vrednostmi in napovedmi za leto 2024. Razvidno je, da AHW precej uspešno sledi sezonskim vrhuncem in padcem.

Slika 6: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z aditivno Holt-Wintersovo metodo



Vir: lastno delo.

Vizualno je jasno, da napovedi metode AHW dobro zajamejo sezonske značilnosti vrste. Zaradi uravnoteženega pristopa, ki upošteva tako raven kot trend in stabilno sezonskost, se je AHW izkazala kot zelo primerna za modeliranje registracij vozil, kjer so redni sezonski vzorci izraziti, amplituda pa ostaja razmeroma stalna.

5.2.4 Multiplikativna Holt-Wintersova metoda

Rezultati MHW so prikazani v tabeli 4 in potrjujejo visoko natančnost tako v učni kot tudi v testni množici.

Tabela 4: Vrednosti izračunov multiplikativne Holt-Wintersove metode

	UČNA MNOŽICA (25-109)	TESTNA MNOŽICA (110-121)
MSE	693.439,271	403.623,157
U (MSE)	0,806	0,872
MAE	490,585	529,082
U (MAE)	0,821	0,859
MAPE	12,652	8,393
U (MAPE)	0,837	0,763

Vir: lastno delo.


V učni množici so vse tri U-statistike pod vrednostjo 1, kar pomeni, da je metoda natančnejša od naivne metode. Najnižja vrednost U-statistike je dosežena pri minimizaciji MSE.

V testnem obdobju je metoda ohranila visoko raven natančnosti. MAPE je bil najnižji med vsemi analiziranimi metodami, kar kaže na odlično sposobnost metode pri zaznavanju in sledenju relativnih nihanj v časovni vrsti. Čeprav je prišlo do rahlega povečanja absolutne

napake, je relativna natančnost ostala visoka, kar je pomemben pokazatelj pri časovnih vrstah z različno amplitudo.

Slik 7 prikazuje, kako napovedi metode MHW sledijo dejanskim vrednostim skozi celotno leto 2024. Napovedi se uspešno prilagajajo tako trendu kot spreminjajoči se sezonski dinamiki.

Slika 7: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z multiplikativno Holt-Wintersovo metodo



Vir: lastno delo.

Metoda je še posebej primerna za časovne vrste, kjer sezonska nihanja niso konstantna, temveč se njihova amplituda povečuje ali zmanjšuje z nivojem vrste, kar je značilno za podatke o registracijah vozil. MHW se zato izkaže kot izjemno zanesljiva izbira za modeliranje časovnih vrst z naraščajočo ali padajočo sezonsko komponento.

5.2.5 Razširjena aditivna Holt-Wintersova metoda

EHW se je izkazala za eno izmed najbolj stabilnih in natančnih metod v celotni analizi napovedovanja registracij osebnih avtomobilov. Rezultati, prikazani v tabeli 5, potrjujejo njeno visoko zanesljivost tako v učni kot v testni množici.

Tabela 5: Vrednosti izračunov razširjene aditivne Holt-Wintersove metode

	UČNA MNOŽICA (25–109)	TESTNA MNOŽICA (110–121)
MSE	735.598,155	267.494,989
U (MSE)	0,812	0,678
MAE	517,567	434,041
U (MAE)	0,820	0,673
MAPE	13,209	10,237
U (MAPE)	0,878	0,899


Vir: lastno delo.

V učni množici so vse vrednosti U-statistike manjše od 1, kar kaže, da je bila metoda EHW učinkovitejša od naivne metode. Nizki vrednosti MAE in MSE potrujeta, da metoda zanesljivo sledi strukturi podatkov tudi v obdobju učenja.

V testni množici se je metoda izkazala kot ena uspešnejših. Z zelo nizkima vrednostma MSE in MAE je pokazala dobro sposobnost prenosa naučenih vzorcev na nove podatke. MAPE ostaja nizka, kar potrjuje stabilno relativno natančnost napovedi tudi izven učnega obdobja.

Slika 8 prikazuje napovedne vrednosti metode EHW v primerjavi z dejanskimi podatki za leto 2024. Vidno je, da napovedi sledijo sezonskim vzorcem, vključno z vrhovi v spomladanskih in jesenskih mesecih.

Slika 8: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z razširjeno aditivno Holt-Wintersovo metodo



Vir: lastno delo.

Zaradi vključitve dodatnega parametra δ se EHW bolje prilagaja nenadnim spremembam v trendu ter ohranja visoko natančnost tudi v obdobjih po šokih, kot je bila pandemija COVID-19. V primerjavi z osnovnim modelom AHW dosega EHW boljšo prožnost in prilagodljivost, kar je še posebej opazno pri napovedovanju obdobj z izrazitimi nihanji.

5.3 Primerjava metod glede na napake napovedovanja

V učni množici (periode 25–109) se glede na rezultate v tabeli 6 kot najučinkovitejši izkažeta metodi AHW in MHW. Metoda AHW dosega najnižje vrednosti vseh treh napak MSE, MAE in MAPE, medtem ko se MHW uvršča tik za njo z zelo podobnimi vrednostmi ter celo manjšimi vrednostmi U-statistik.

Tabela 6: Zbirna tabela napak za učno množico

	MSE	U (MSE)	MAE	U (MAE)	MAPE	U (MAPE)
SES	902.472,219	0,901	683,170	0,894	16,404	0,898
HOLT	1.001.221,959	0,964	743,307	0,998	16,646	1,027
AHW	682.288,446	0,812	479,990	0,843	12,587	0,861
MHW	693.439,271	0,806	490,585	0,821	12,652	0,837
EHW	735.598,155	0,812	517,567	0,820	13,209	0,878

Vir: lastno delo.

Metoda EHW ima malce slabše rezultate v primerjavi z metodama AHW in MHW, doseže pa najnižjo vrednost U (MAE) vseh metod. SES in Holtova metoda v učni množici nista dosegli primerljivih rezultatov. Njune vrednosti MSE in MAE so opazno višje, kar kaže na slabšo prilagoditev metode učnim podatkom.

Na testni množici (periode 110–121) so razlike med metodami še bolj izrazite. Tabela 7 kaže, da je metoda EHW glede na minimizacijo MSE najbolj dosledna in natančna. Z najnižjimi vrednostmi MSE in U (MSE) potrdi svojo robustnost tudi izven učnega nabora. Njena sposobnost natančnega napovedovanja na testni množici se kaže tudi v drugi najnižji vrednosti MAE ter U (MAE).

Tabela 7: Zbirna tabela napak za testno množico

	MSE	U (MSE)	MAE	U (MAE)	MAPE	U (MAPE)
SES	592.295,373	1,017	648,245	1,044	12,301	1,089
HOLT	874.689,885	1,235	979,479	1,447	21,219	1,740
AHW	322.144,965	0,783	372,050	0,627	101,225	0,589
MHW	403.623,157	0,872	529,082	0,859	8,393	0,763
EHW	267.494,989	0,678	434,041	0,673	10,237	0,899

Vir: lastno delo.

Glede na minimizacijo MAE je med vsemi metodami najbolj natančna AHW, doseže pa tudi najmanjšo vrednost U (MAPE). MHW se v testni množici izkaže kot najučinkovitejša le pri kazalniku MAPE, kjer dosega najnižjo vrednost med vsemi metodami.

Metodi SES in Holt se ponovno izkažeta za najmanj primerni. Vse njune U-vrednosti presegajo 1, kar pomeni, da sta pri napovedovanju slabši celo od naivne metode. To potrjuje, da metoda, ki ne vključuje sezonskosti (SES), in metoda, ki upošteva zgolj trend (Holt), nista primerni za modeliranje časovne vrste s kompleksnimi sezonskimi vzorci in morebitnimi nihanji v trendu.

Na podlagi analize učne in testne množice se kot najboljši metodi napovedovanja izkažeta AHW in EHW. AHW dosega najnižje absolutne napake in izkazuje zelo dobro zaznavanje sezonskih vzorcev, medtem ko EHW izstopa kot najbolj prilagodljiva in natančna metoda za napovedovanje prihodnjih gibanj, saj učinkovito združuje zaznavanje trenda in sezonskosti ter uspešno obvladuje nestanovitne premike v podatkih.


EHW se izkaže kot najprimernejša metoda v obdobjih negotovosti in strukturnih sprememb, kot je bilo leto 2020, medtem ko AHW predstavlja zanesljivo izbiro v obdobjih s stabilno sezonskostjo. Obe metodi ponujata visoko natančnost napovedovanja in sta najboljši izbiri za napovedovanje registracij osebnih vozil v Sloveniji.

5.4 Učinek izločitve leta 2020 na kakovost napovedi

5.4.1 Predstavitev in analiza podatkovne baze brez leta 2020

Leto 2020 je predstavljalo izrazito odstopanje v časovni vrsti registracij vozil, saj je bilo močno zaznamovano s posledicami pandemije COVID-19. Zaradi nenavadnih okoliščin je bilo smiselno preveriti, kako izločitev tega leta vpliva na delovanje in natančnost napovednih modelov. Na sliki 9 je prikazan časovni potek mesečnega števila prvič registriranih osebnih avtomobilov v Sloveniji med januarjem 2015 in decembrom 2024, pri čemer je iz časovne vrste izpuščeno leto 2020. Izključitev tega obdobja omogoča bolj nepopačen prikaz običajnih sezonskih in trendnih vzorcev, saj je leto 2020 predstavljalo izjemen odklon zaradi vpliva pandemije COVID-19.

Slika 9: Prikaz mesečnega števila prvič registriranih navadnih osebnih avtomobilov fizičnih oseb v Sloveniji za obdobje 2015–2024 brez 2020




Vir: SURS (brez datuma).

Slika 9 kaže jasen sezonski vpliv časovne vrste, z rednimi vzponi in padci znotraj vsakega koledarskega leta. Največ registracij je običajno zaznanih v pomladnih in jesenskih mesecih, medtem ko se v zimskih mesecih beležijo nižje vrednosti. Poleg sezonskih vzorcev se opazijo tudi dolgoročne spremembe: postopno rast v obdobju od leta 2015 do 2019 ter stabilizacijo in zmerno nihanje v letih po pandemiji.

Odstranitev leta 2020 omogoča bolj jasen vpogled v dinamiko časovne vrste brez vpliva izrednih dogodkov, kar je ključno pri izbiri in preverjanju napovednih modelov. S to sliko je omogočena čistejša analiza sezonskosti in trenda, kar povečuje zanesljivost nadaljnjih statističnih obdelav.

Slika 10 prikazuje sezonski vzorec mesečnih registracij brez vpliva leta 2020. Na sliki so za vsako leto prikazane vrednosti po mesecih, kar omogoča neposredno primerjavo sezonskih nihanj med leti.

Slika 10: Prikaz sezonskosti za obdobje 2015–2024 brez 2020




Vir: lastno delo.

S slike 10 je jasno razvidna ponavljajoča se struktura, kjer se registracije praviloma povečajo v spomladanskih mesecih (predvsem marca in aprila) ter ponovno v jeseni (najpogosteje oktobra), medtem ko se v poletnih (julij, avgust) in zimskih mesecih (december, januar) vidi upad. Ta značilna sezonska dinamika je prisotna v večini let, kar potrjuje obstoj stabilne sezonske komponente v podatkovni vrsti.

Z izključitvijo leta 2020 se sezonski vzorec dodatno izostri, saj to leto ni porušilo povprečnih vrednosti zaradi izrednih razmer. Tudi v letih po pandemiji (2021–2024) opazimo, da se vrsta vrača k običajnemu sezonskemu toku, čeprav z nekoliko nižjimi vrednostmi v nekaterih mesecih. Slika 11 prikazuje ACF-graf časovne vrste registracij osebnih avtomobilov brez vključitve leta 2020.

Slika 11: Graf analize avtokorelacijske funkcije brez 2020



Vir: lastno delo.

S slike 11 je razvidno, da avtokorelacijski koeficient pri zamiku 1 meseca ostaja zelo visok, kar pomeni močno povezavo med zaporednimi meseci tudi brez vpliva leta 2020. Povezanost ostaja visoka tudi do zamika 4, nato pa začne postopoma upadati.

Najpomembnejši izstopajoči zamik je spet zamik 12 mesecev, kjer koeficient doseže najvišjo vrednost v celotni sliki. To močno potrjuje izrazito letno sezonskost in pomeni, da se mesečni vzorci registracij očitno ponavljajo vsako leto.

Znotraj prvih 12 zamikov je najnižja vrednost pri zamiku 6, kar pomeni, da je ob polletnem zamiku povezava med podatki najslabša. To se razloži z dejstvom, da se takrat vrhovi časovne vrste pokrijejo z dolinami, kar pomeni obratni sezonski učinek (antifaza).

Tudi tukaj zamik 18 mesecev doseže najnižjo vrednost med vsemi zamiki, kar pomeni, da se po enem letu in pol zopet pokrijejo obdobja z nasprotnimi značilnostmi (visoke vrednosti z nizkimi), kar še dodatno potrjuje ponavljajoči se letni sezonski vzorec.

5.4.2 Rezultati aditivne Holt-Wintersovove metode in multiplikativne Holt-Wintersove metode

Napovedi so bile ponovno izračunane z uporabo metod AHW in EHW, ki sta se v osnovni analizi izkazali za najuspešnejši. Rezultati so podani ločeno za učno množico (periode 25–97) in testno množico (periode 97–109).

5.4.2.1 Aditivna Holt-Wintersova metoda

Metoda AHW, uporabljena na časovni vrsti brez vključitve leta 2020, se je v učnem obdobju izkazala za izjemno natančno. Napovedi, ki temeljijo na podatkih brez izjemnih nihanj, so se zelo dobro prilegale dejanskim vrednostim. Vrednosti napak napovedovanja kažejo na nizko povprečno odstopanje napovedi od dejanskih podatkov, kar potrjuje tudi nizka relativna napaka. Vse tri ocenjevalne metrike, kvadratna napaka, povprečna absolutna napaka in povprečna relativna napaka, imajo v primerjavi z metrikami celotne časovne vrste nižje vrednosti, kar kaže na stabilnost metode in njeno sposobnost, da dobro zajame strukturo časovne vrste.

Tabela 8 prikazuje rezultate napovedovanja na učni in testni množici. V učnem obdobju so bile vse vrednosti Theilove U-statistike nižje od vrednosti 1, kar pomeni, da je bila metoda uspešnejša od osnovne naivne metode. Napovedi so se dobro odzvale tako na sezonske vzorce kot tudi na trendne značilnosti podatkov.

Tabela 8: Vrednosti izračunov aditivne Holt-Wintersove metode brez 2020


	UČNA MNOŽICA (25–97)	TESTNA MNOŽICA (97–109)
MSE	284.293,864	605.960,001
U (MSE)	0,594	1,068
MAE	350,249	430,788
U (MAE)	0,631	0,698
MAPE	7,778	102,304
U (MAPE)	0,628	0,589

Vir: lastno delo.

Tudi v testnem obdobju je metoda pokazala dobre rezultate. Napovedi so v povprečju dovolj natančne, da ustrezno zaznajo sezonska nihanja in ohranijo nizko raven napake glede na naivno napoved.

Napovedi za leto 2024 so prikazane na sliki 12, kjer lahko opazimo, da dobro sledijo dinamiki dejanskih podatkov. Metoda uspešno zajame sezonske vrhove in padce, kar je ključno za tovrstno časovno vrsto. Uporaba AHW brez obdobja nenavadnih motenj se tako izkaže kot dobra izbira za stabilne in redne podatkovne strukture.

Slika 12: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z aditivno Holt-Wintersovo metodo, brez 2020



Vir: lastno delo.

5.4.2.2 Razširjena aditivna Holt-Wintersova metoda

Metoda EHW, uporabljena na podatkih brez leta 2020, je pokazala zelo dobre rezultate tako pri učenju kot pri napovedovanju. Že v učni množici se je metoda izkazala z natančnimi napovedmi, ki so se zelo dobro prilegale dejanskim podatkom. Vrednosti napak so nizke, kar kaže na visoko stopnjo prilagodljivosti metode in uspešno zajemanje sezonskih ter trendnih značilnosti časovne vrste.

Vse tri vrednosti Theilove U-statistike ostajajo pod 1, kar pomeni, da so napovedi boljše kot pri naivni metodi. To potrjuje, da zna EHW učinkovito izkoristiti razpoložljive informacije za izboljšanje napovedi tudi pri izločitvi izjemnega leta. Rezultati so prikazani v tabeli 9, kjer je razvidno, da metoda v učnem obdobju ohranja nizke vrednosti vseh napak, kar potrjuje dobro stabilnost napovedi.

Tabela 9: Vrednosti izračunov razširjene aditivne Holt-Wintersove metode brez 2020


	UČNA MNOŽICA (25–97)	TESTNA MNOŽICA (97–109)
MSE	319.317,198	199.270,472
U (MSE)	0,637	0,607
MAE	385,838	466,516
U (MAE)	0,654	0,729
MAPE	8,394	8,610
U (MAPE)	0,650	0,720

Vir: lastno delo.

V testnem obdobju, kjer metoda napoveduje vrednosti, ki jih pred tem ni preučevala, je EHW prav tako ohranila visoko raven natančnosti. Napovedi ostajajo blizu dejanskim vrednostim,

kar kaže na dobro posplošitev in robustnost metode. Na sliki 13 so prikazane napovedi metode EHW v primerjavi z dejanskimi podatki. Kot je razvidno, napovedi ustrezno sledijo dinamiki registracij, zajemajo sezonske vrhove in padce ter se učinkovito prilagajajo strukturi podatkovne vrste. Metoda EHW se tudi brez vključitve ekstremnega obdobja izkazuje kot zanesljiva in prilagodljiva.

Slika 13: Primerjava dejanskih vrednosti in vrednosti, pridobljenih z razširjeno aditivno Holt-Wintersove metode, brez 2020



Vir: lastno delo.

5.4.3 Primerjava aditivne Holt-Wintersove metode in razširjene aditivne Holt-Wintersove metode

V učni množici metoda AHW izkazuje boljšo natančnost napovedovanja. Rezultati so predstavljeni v tabeli 10. AHW dosega nižje vrednosti vseh treh napovednih napak – kvadratne, absolutne in relativne. Prav tako so vse pripadajoče U-statistike pod vrednostjo 0,65. To kaže na odlično sposobnost metode AHW za učenje iz podatkov z izraženo sezonskostjo in trendom, kadar vrste ne zmoti nenavaden dogodek, kot je leto 2020 oz. COVID-19.

Tabela 10: Zbirna tabela napak za učno množico brez upoštevanja leta 2020

	MSE	U (MSE)	MAE	U (MAE)	MAPE	U (MAPE)
AHW	284.293,864	0,594	350,249	0,631	7,778	0,628
EHW	319.317,198	0,637	385,838	0,654	8,394	0,650

Vir: lastno delo.

V testni množici, predstavljeni v tabeli 11, ki obsega zadnjih 12 mesecev časovne vrste, torej leto 2024, metoda EHW izstopa kot natančnejša. Zabeleži precej nižjo kvadratno napako od metode AHW in najnižjo U (MSE) vrednost, kar kaže na njeno sposobnost učinkovitega

zajemanja dinamike novih podatkov. Čeprav ima AHW nekoliko nižjo vrednost U (MAPE), njena visoka absolutna odstotna napaka (MAPE) nakazuje, da se napovedi v tem obdobju močno razlikujejo od dejanskih vrednosti. To lahko kaže na občutljivost AHW na večje odklone ali spremembe v časovni vrsti, ki jih EHW uspešneje ublaži.

Tabela 11: Zbirna tabela napak za testno množico brez upoštevanja leta 2020

	MSE	U (MSE)	MAE	U (MAE)	MAPE	U (MAPE)
AHW	605.960,001	1,068	430,788	0,698	102,304	0,589
EHW	199.270,472	0,607	466,516	0,729	8,610	0,720

Vir: lastno delo.

Na podlagi obeh tabel (10 in 11) lahko sklenemo, da metoda AHW bolje deluje znotraj učne množice, kjer ni izrazitih nepravilnosti ali nenadnih sprememb. Njene napovedi so stabilne in natančne, kadar ima časovna vrsta jasno izražen sezonski in trendni vzorec. Po drugi strani se metoda EHW v polovici kazalnikov izkaže kot zanesljivejša pri napovedovanju v prihodnosti, kar je razvidno iz rezultatov testne množice.

Glede na cilj raziskave, torej najti čim bolj natančno metodo za napovedovanje prihodnjih registracij osebnih vozil, se kot bolj primerna metoda izkaže AHW. Njena sposobnost učinkovitega prilagajanja že znanim podatkom v preteklosti ter nižjih napak napovedovanja pri več kot polovici kazalnikov v testnem obdobju so ključne prednosti za nadaljnjo uporabo v praksi. Metoda EHW v testni množici doseže bistveno nižje vrednosti MSE in MAPE, kar kaže na njeno visoko natančnost pri napovedovanju novih podatkov, zato se EHW priporoča kot dopolnilna metoda, saj ponuja dodatno varnost pri validaciji napovedi, zlasti v bolj nestabilnih obdobjih. Kombinirana uporaba obeh metod izboljša celostno zanesljivost napovedovanja.

6 SKLEP

Namen naloge je bil napovedati mesečno število prvih registracij navadnih osebnih avtomobilov fizičnih oseb v Sloveniji v obdobju 2015–2024 ter oceniti učinkovitost različnih metod eksponentnega glajenja. Poseben poudarek je bil namenjen primerjavi metod glede na njihovo natančnost, stabilnost in prilagodljivost pri modeliranju časovne vrste z jasno izraženo sezonskostjo, dolgoročnim trendom in obdobji nenadnih sprememb, zlasti vplivom pandemije COVID-19.

Analiza je pokazala, da sta metodi SES in Holt, ki ne vključujeta sezonske komponente, pri obravnavani vrsti neustrezni. V obeh obdobjih, učnem in testnem, sta dosegli slabšo natančnost kot naivna metoda. AHW in EHW sta izkazali bistveno večjo uspešnost. AHW je bila posebej učinkovita v učnem obdobju s stabilnejšo sezonsko strukturo, kjer je dosegla najnižjo absolutno napako MAE, EHW pa se je kot bolj robustna metoda izkazala predvsem

v testnem obdobju in pri vrsti brez vpliva leta 2020, saj se je bolje odzivala na spremembe v dinamiki podatkov.

Dodatna analiza brez netipičnega leta 2020 je potrdila, da takšni dogodki pomembno vplivajo na natančnost napovedi. AHW in EHW sta ohranili visoko raven zanesljivosti, EHW pa se je še posebej izkazala s sposobnostjo učinkovitega prilagajanja in stabilnimi rezultati v testni množici. Dosegla je tudi najnižje vrednosti Theilove U-statistike, kar potrjuje, da je bila uspešnejša od naivne metode tudi v pogojih negotovosti.

Na podlagi primerjanja lahko zaključimo, da sta AHW in EHW najbolj primerni metodi za napovedovanje registracij osebnih avtomobilov v Sloveniji. EHW je optimalna izbira v situacijah z večjo dinamiko in nepredvidljivostjo, AHW pa je zanesljiva rešitev v stabilnejših tržnih pogojih.

Ugotovitve te naloge ponujajo uporabno osnovo za strateško načrtovanje v avtomobilskem sektorju, pri javnih politikah in v finančnih institucijah. Raziskava odpira možnosti za nadgradnjo metod z vključevanjem eksogenih dejavnikov, kot so cene goriva, gospodarski kazalniki ali okoljske politike.

V prihodnjih raziskavah bi bilo smiselno preučiti vključitev naprednejših modelov, ki zajemajo kompleksnejše nelinearne odnose, ter povečati frekvenco podatkovne baze (npr. na tedensko raven). S tem bi se še dodatno izboljšala natančnost napovedi in podala poglobljena razlaga tržnih gibanj. Raziskava prispeva k boljšemu razumevanju vedenja trga osebnih avtomobilov ter k razvoju napovednih pristopov, primernih za odziv na realne izzive dinamičnega gospodarskega okolja.

SEZNAM KLJUČNE LITERATURE

1. ACEA. (2025, 10. februar). *Passenger cars: what they are and why they are so important*. <https://www.acea.auto/fact/passenger-cars-what-they-are-and-why-they-are-so-important/>
2. Ferbar Tratar, L., Mojškerc, B. in Toman, A. (2016). Demand forecasting with four-parameter exponential smoothing. *International Journal of Production Economics*, 181, 162–173. <https://doi.org/10.1016/j.ijpe.2016.08.004>
3. Frieske, B., in Stieler, S. (2022). The “Semiconductor Crisis” as a Result of the COVID-19 Pandemic and Impacts on the Automotive Industry and Its Supply Chains. *World Electric Vehicle Journal*, 13(10), 189. <https://doi.org/10.3390/wevj13100189>
4. Klein, C., Høj, J., in Machlica, G. (2021). *The impacts of the COVID-19 crisis on the automotive sector in Central and Eastern European countries (OECD Economics Department Working Papers No. 1658)*. <https://doi.org/10.1787/a7d40030-en>
5. Statistični urad Republike Slovenije – SURS. (brez datuma). *Mesečni podatki o prvič registriranih vozilih*. <https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/2222100S.px/>

LITERATURA IN VIRI

1. ACEA. (2021, 9. marec). *COVID-19 impact on EU automobile production, full-year 2020*. <https://www.acea.auto/figure/interactive-map-covid-19-impact-on-eu-automobile-production-full-year-2020/>
2. ACEA. (2025, 10. februar). *Passenger cars: what they are and why they are so important*. <https://www.acea.auto/fact/passenger-cars-what-they-are-and-why-they-are-so-important/>
3. Avto-moto zveza Slovenije. (2025, 24. februar). *Slovenski avtomobilski trg v letu 2024: Tesla z največjim minusom*. <https://www.amzs.si/motorevija/v-zarometu/avto-moto/2025-02-24-slovenski-avtomobilski-trg-v-letu-2024-tesla-z-najvecjim-minusom>
4. China Briefing. (2025, 11. april). *Trump Raises Tariffs on China to 145% – Overview and Trade Implications*. <https://www.china-briefing.com/news/trump-raises-tariffs-on-china-to-125-overview-and-trade-implications/>
5. Da Veiga, C. P., Da Veiga, C. R. P., & Tortato, U. (2016). Demand forecasting strategies: Understanding the most important concepts. *Espacios (Caracas, Venezuela)*, 37(5), 1–1. <https://revistaespacios.com/a16v37n05/16370506.html>
6. Davalos, G. (2024, 1. september). *Demand forecasting with Holt-Winters: Unlocking value in supply chains*. <https://medium.com/@gustavodavalos/demand-forecasting-with-holt-winters-unlocking-value-in-supply-chains-0efc2818e452>
7. Eko sklad. (brez datuma). *Električna vozila: Subvencija*. <https://www.ekosklad.si/>
8. Ferbar Tratar, L. (2015). Forecasting method for noisy demand. *International Journal of Production Economics*, 161, 64–73. <https://doi.org/10.1016/j.iipe.2014.11.019>
9. Ferbar Tratar, L., Mojškerc, B., in Toman, A. (2016). Demand forecasting with four-parameter exponential smoothing. *International Journal of Production Economics*, 181, 162–173. <https://doi.org/10.1016/j.iipe.2016.08.004>
10. Frieske, B., in Stieler, S. (2022). The “Semiconductor Crisis” as a Result of the COVID-19 Pandemic and Impacts on the Automotive Industry and Its Supply Chains. *World Electric Vehicle Journal*, 13(10). <https://doi.org/10.3390/wevj13100189>
11. Fronteli, M. H., in Pacheco Paladini, E. (2023). Trends, Enablers, and Barriers for Car Ownership. *Transportation Research Record*, 2677(1), 1290–1310. <https://doi.org/10.1177/03611981221103863>
12. Holt, C. C. (2004). Author’s retrospective on ‘Forecasting seasonals and trends by exponentially weighted moving averages’. *International Journal of Forecasting*, 20(1), 11–13. <https://www.sciencedirect-com.nukweb.nuk.uni-lj.si/science/article/pii/S0169207003001158?via%3Dihub>
13. Hyndman, R. J., in Athanasopoulos, G. (2018, 6. maj). *Forecasting: Principles and Practice* (2. izd.). OTexts.

14. Klein, C., Høj, J., in Machlica, G. (2021). *The impacts of the COVID-19 crisis on the automotive sector in Central and Eastern European countries* (OECD Economics Department Working Papers No. 1658). <https://doi.org/10.1787/a7d40030-en>
15. KPMG Slovenija. (brez datuma). *Covid-19 crisis in the automotive sector*. <https://kpmg.com/si/en/home/insights/2020/08/aut-covid-19-crisis-in-the-automotive-sector.html>
16. Ministrstvo za javno upravo. (brez datuma). *Prvič registrirana vozila po mesecih*. <https://podatki.gov.si/dataset/prvic-registrirana-vozila-po-mesecih>
17. Office for National Statistics (UK). (2024, 14. februar). Consumer price index (CPI) of new car purchases annually in the United Kingdom (UK) from 2008 to 2023. <https://www-statista-com.nukweb.nuk.uni-lj.si/statistics/286563/consumer-price-index-cpi-of-new-car-purchases-annual-average-uk/>
18. Statista. (brez datuma). *Impact of COVID-19 on the automotive industry worldwide*. <https://www.statista.com/topics/8749/impact-of-covid-19-on-the-automotive-industry-worldwide/#topicOverview>
19. Statistics How To. (brez datuma). *U Statistic: Definition, Different Types; Theil's U*. <https://www.statisticshowto.com/u-statistic-theils/>
20. Statistični urad Republike Slovenije – SURS. (brez datuma). *Mesečni podatki o prvič registriranih vozilih*. <https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/2222100S.px/>
21. Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3), 324–342. <https://doi.org/10.1287/mnsc.6.3.324>

PRILOGA

Priloga 1: Izračun napovedi razširjene aditivne Holt-Wintersove metode z minimizacijo povprečne odstotne napake

Leto	Mesec	Yt (Število)	Lt	bt	St	Ft	IPEI					
2015	1	4071			1				alfa=	0,731		
	2	3665			1				beta=	0,028		
	3	4448			1				gama=	1,000		
	4	3970			1				delta=	0,459		
	5	3888			1							
	6	3915			1				MAPE (2–109)=	12,704		
	7	4021			1				MAPE (26–109)=	13,209		
	8	3082			1							
	9	3646			1				MAPE (110–121)=	10,237		
	10	3834			1							
	11	3519			1							
	12	3430	3791	49	1							
2016	1	4441	4279	61	162	3841	14					
	2	4326	4329	61	– 3	4341	0					
	3	5173	4962	77	211	4392	15					
	4	4501	4645	66	– 144	5040	12					
	5	4526	4575	62	– 49	4712	4					
	6	4800	4756	66	44	4639	3					
	7	4130	4315	51	– 185	4822	17					
	8	3781	3938	39	– 157	4368	16					
	9	4275	4195	46	80	3979	7					
	10	4498	4428	51	70	4241	6					

se nadaljuje

Priloga 1: Izračun napovedi razširjene aditivne Holt-Wintersove metode z minimizacijo povprečne odstotne napake (nad.)

	11	4182	4261	45	– 79	4480	7					
	12	3931	4031	37	– 100	4307	10				$((F_{t+1}-Y_{t+1})/Y_t)^2$	$((Y_{t+1}-Y_t)/Y_t)^2$
2017	1	5130	4770	57	360	4231	18				0,052	0,093
	2	4972	4934	60	38	4823	3				0,001	0,001
	3	6147	5740	80	407	5205	15				0,036	0,056
	4	5081	5346	67	– 265	5676	12				0,009	0,030
	5	5255	5320	65	– 65	5364	2				0,000	0,001
	6	5504	5452	66	52	5429	1				0,000	0,002
	7	4717	5018	52	– 301	5333	13				0,013	0,020
	8	4438	4680	42	– 242	4913	11				0,010	0,003
	9	4593	4591	38	2	4802	5				0,002	0,001
	10	5105	4945	47	160	4699	8				0,008	0,012
	11	4924	4979	46	– 55	4912	0				0,000	0,001
	12	3846	4209	24	– 363	4925	28				0,048	0,048
2018	1	5930	5308	54	622	4593	23				0,121	0,294
	2	4954	5046	45	– 92	5399	9				0,006	0,027
	3	6699	6080	72	619	5498	18				0,059	0,124
	4	5592	5864	64	– 272	5887	5				0,002	0,027
	5	6006	6015	67	– 9	5864	2				0,001	0,005
	6	5861	5896	62	– 35	6134	5				0,002	0,001
	7	5843	6012	63	– 169	5657	3				0,001	0,000
	8	5052	5439	45	– 387	5833	15				0,018	0,018
	9	4956	5097	35	– 141	5486	11				0,011	0,000
	10	5735	5499	45	236	5292	8				0,008	0,025
	11	5082	5231	36	– 149	5489	8				0,005	0,013

se nadaljuje

Priloga 1: Izračun napovedi razširjene aditivne Holt-Wintersove metode z minimizacijo povprečne odstotne napake (nad.)

	12	3975	4490	14	– 515	4904	23				0,033	0,047
2019	1	5955	5279	36	676	5126	14				0,044	0,248
	2	5539	5521	42	18	5223	6				0,003	0,005
	3	6531	5986	54	545	6182	5				0,004	0,032
	4	5725	5935	51	– 210	5767	1				0,000	0,015
	5	5744	5813	46	– 69	5976	4				0,002	0,000
	6	5436	5566	38	– 130	5824	7				0,005	0,003
	7	5701	5753	42	– 52	5435	5				0,002	0,002
	8	4789	5237	26	– 448	5408	13				0,012	0,026
	9	4850	5026	20	– 176	5122	6				0,003	0,000
	10	5786	5478	32	308	5281	9				0,011	0,037
	11	4917	5145	22	– 228	5361	9				0,006	0,023
	12	4097	4621	6	– 524	4652	14				0,013	0,028
2020	1	5663	5074	19	589	5303	6				0,008	0,146
	2	5519	5396	27	123	5110	7				0,005	0,001
	3	2754	3222	– 34	– 468	5968	117				0,339	0,251
	4	1962	2388	– 57	– 426	2978	52				0,136	0,083
	5	5132	4411	1	721	2262	56				2,139	2,610
	6	5897	5557	33	340	4282	27				0,099	0,022
	7	5938	5868	41	70	5539	7				0,005	0,000
	8	4509	5091	18	– 582	5462	21				0,026	0,058
	9	4610	4825	10	– 215	4934	7				0,005	0,001
	10	4344	4335	– 4	9	5143	18				0,030	0,003
	11	2212	2887	– 44	– 675	4103	86				0,190	0,241
	12	1875	2376	– 57	– 501	2319	24				0,040	0,023

se nadaljuje

Priloga 1: Izračun napovedi razširjene aditivne Holt-Wintersove metode z minimizacijo povprečne odstotne napake (nad.)

2021	1	2907	2478	– 52	429	2908	0				0,000	0,303
	2	4599	3958	– 10	641	2549	45				0,497	0,339
	3	7217	6553	63	664	3481	52				0,660	0,324
	4	4113	4982	17	– 869	6190	50				0,083	0,185
	5	5375	4943	16	432	5721	6				0,007	0,094
	6	5298	5051	18	247	5298	0				0,000	0,000
	7	5276	5188	22	88	5139	3				0,001	0,000
	8	4313	4822	11	– 509	4628	7				0,004	0,033
	9	4563	4734	8	– 171	4617	1				0,000	0,003
	10	4895	4850	11	45	4752	3				0,001	0,005
	11	4300	4761	8	– 461	4186	3				0,001	0,015
	12	3395	3995	– 13	– 600	4268	26				0,041	0,044
2022	1	4336	4044	– 12	292	4410	2				0,000	0,077
	2	4287	3924	– 15	363	4673	9				0,008	0,000
	3	5055	4442	0	613	4574	10				0,013	0,032
	4	4322	4753	9	– 431	3573	17				0,022	0,021
	5	5039	4766	9	273	5195	3				0,001	0,028
	6	5086	4889	12	197	5022	1				0,000	0,000
	7	4577	4624	5	– 47	4989	9				0,007	0,010
	8	4345	4655	5	– 310	4120	5				0,002	0,003
	9	4534	4647	5	– 113	4489	1				0,000	0,002
	10	4278	4358	– 3	– 80	4697	10				0,009	0,003
	11	4086	4370	– 3	– 284	3894	5				0,002	0,002
	12	3790	4221	– 7	– 431	3767	1				0,000	0,005
2023	1	4732	4458	0	274	4506	5				0,004	0,062

se nadaljuje

Priloga 1: Izračun napovedi razširjene aditivne Holt-Wintersove metode z minimizacijo povprečne odstotne napake (nad.)

	2	4817	4554	3	263	4821	0				0,000	0,000
	3	6313	5559	31	754	5170	18				0,056	0,096
	4	4825	5229	20	– 404	5158	7				0,003	0,056
	5	5349	5197	19	152	5522	3				0,001	0,012
	6	5413	5269	20	144	5413	0				0,000	0,000
	7	4847	4988	12	– 141	5243	8				0,005	0,011
	8	4534	4802	7	– 268	4690	3				0,001	0,004
	9	5236	5173	17	63	4695	10		U-učna	0,878	0,014	0,024
	10	5195	5230	18	– 35	5110	2				0,000	0,000
	11	5226	5362	21	– 136	4964	5				0,003	0,000
	12	4315	4800	5	– 485	4953	15	m			0,015	0,030
2024	1	5529			274	5079	8	1			0,011	0,079
	2	5943			263	5073	15	2			0,025	0,006
	3	6536			754	5569	15	3			0,026	0,010
	4	5784			– 404	4415	24	4			0,044	0,013
	5	5314			152	4976	6	5			0,003	0,007
	6	4982			144	4972	0	6	U-testna	0,899	0,000	0,004
	7	5743			– 141	4693	18	7			0,044	0,023
	8	4772			– 268	4571	4	8			0,001	0,029
	9	5305			63	4906	8	9			0,007	0,012
	10	5497			– 35	4813	12	10			0,017	0,001
	11	4855			– 136	4716	3	11			0,001	0,014
	12	3985			– 485	4372	10	12			0,006	0,032

Vir: lastno delo.