



8. NAPOVEDOVANJE POVPRASHEVANJA



To poglavje obravnava teorijo napovedovanja. Posebna pozornost je bila namenjena napovedovanju povpraševanja. Gre za napovedovanje prihodnjih dogodkov (povezanih s povpraševanjem in zahtevami), katerega cilj je zmanjšati tveganja, povezana s sprejemanjem poslovnih odločitev. Najpomembnejša vprašanja, obravnavana v tem poglavju, so naslednja:

- načela in trendi napovedovanja,
- napovedovanje časovnih vrst,
- postopek za pripravo napovedi na podlagi časovnih vrst,
- metode napovedovanja in napake,
- vprašanje umetne inteligence pri napovedovanju.

8.1. Uvod

Napovedovanje je široko uporabljena multidisciplinarna veda. Je pomembna dejavnost, ki se uporablja za sprejemanje poslovnih odločitev na številnih področjih načrtovanja: gospodarskem, industrijskem in znanstvenem (Chatfield, 2001). Izdelana napoved podpira sprejemanje mikro- in makroekonomskih odločitev. Podpira tudi sprejemanje ukrepov za aktiviranje ali nasprotovanje nekemu pojavu. Je tudi vir dragocenih informacij. Napovedovanje lahko imenujemo tudi napovedovanje; napovedovanje prihodnjega povpraševanja, napovedovanje prodaje ali novega trenda. Zato je mogoče predvideti spremembe tržnih razmer, ki se jim mora podjetje prilagoditi

Vendar ta napoved ne more temeljiti zgolj na prvi in intuiciji menedžerjev, ki napovedujejo ali ne na podlagi neustrezno pripravljene podlage, ki jo lahko sproži naprava podjetja. Pri tem ni vsako napovedovanje, saj se napovedovanje (imenovano tudi predvidevanje) uporablja na **racionalnih, običajno znanstvenih podlagah**.



Napovedovanje je sklepanje o neznanih dogodkih na podlagi znanih dogodkov (Cieślak, 2005). Tako lahko na primer napovemo, da: (1) dogodek se bo zgodil, ker se je zgodil v preteklosti; (2) dogodek se bo zgodil, ker na to kaže njegova pogostost; (3) dogodek se bo zgodil, ker je povezan z drugimi dogodki, ki so se zgodili (Dittmann, 2003).

Napovedi se oblikujejo (gradijo) na podlagi zelo različnih predpostavk. Glede na njihovo znanstveno naravo pa so zgrajene predvsem na podlagi statističnih in ekonometričnih modelov ter z uporabo operativnih raziskav. Napovedi se pripravljajo na podlagi zgodovinskih podatkov, torej tistih, ki so se zgodili v preteklosti. Z logističnega vidika pa so povezane s podatki iz bližnje preteklosti. Predvsem v kompleksnih proizvodnih panogah (npr. v avtomobilski industriji) so napovedi povpraševanja ključne za prodajno področje in tudi za učinkovitost proizvodnega sistema.


Napoved se vedno nanaša na določeno obdobje napovedi. Obzorje napovedi je interval $(T, T_i]$, kjer: T - trenutni trenutek, T_i - končni trenutek.

Glede na časovno obdobje se problem napovedovanja na splošno deli na tri področja: kratkoročno, srednjeročno in dolgoročno napovedovanje. Kot smo že omenili, je z vidika vodje logistike ključno **kratkoročno napovedovanje**. Zajema obdobja napovedovanja od ene ure do enega tedna. Z vidika dela vodje logistike je zanimivo tudi srednjeročno napovedovanje, ki se nanaša na napovedi od enega meseca do največ enega leta. Nazadnje lahko ločimo še dolgoročne napovedi, za katere je značilno obdobje napovedovanja, daljše od enega leta. Za operativne dejavnosti, povezane z logistiko, so manj pomembne. Teorija kaosa je v veliki meri pokazala, da je dolgoročno napovedovanje potratno. Zato lahko domnevamo, da je za širše razumljene logistične dejavnosti daljše, kot je napovedno obdobje, manjša je verjetnost, da bo napoved uresničena. Njeno zaupanje se zmanjšuje. Tudi napovedovanje za izdelek v daljšem časovnem obdobju, kot je življenjski cikel izdelka, ni smiselno.

Vrednost (pomembnost) napovednih modelov temelji na njihovi zmožnosti ustvarjanja natančnih napovedi. Zato so napovedi tako dobre, kot so dobre predpostavke uporabljenega modela. Pomembno je poznati te predpostavke in vedeti, kakšne so. Če se katera od teh predpostavk izkaže za napačno, je mogoče napovedi ponovno oceniti, spremeniti in izboljšati.



Glavni problem natančnosti napovedi je nepredvidljivost gospodarskih gibanj ter zunanjih dogodkov in kriz. Zato je treba jasno povedati, da so določene vrednosti napovedi podvržene **napakam** in **negotovosti**. Prihodnost se torej določa na podlagi znanja, ki ga imamo o preteklosti (slika 8.1).



Slika 8.1. Splošni model napovedovanja

Vir: (Dittmann, 2003).

Ne smemo pozabiti na potrebo po izmenjavi informacij pri upravljanju oskrbovalne verige, ki je ključna za uspeh napovedovanja povpraševanja (Altendorfer in Felberbauer, 2023). Natančnejše kot so informacije o povpraševanju, natančnejša bo napoved. Ključno je tudi sprotno posodabljanje informacij o povpraševanju (vključuje spreminjanje prejšnjih informacij, npr. o velikosti naročila), zaradi česar se povpraševanje posodablja v časovnem horizontu in odpravlja asimetrija informacij. Ali in drugi poudarjajo, da je deljenje celotnih napovedi povpraševanja namesto končne količine naročila koristno za uspešnost oskrbovalne verige (Ali in drugi, 2012).

Izzivi uspešnega napovedovanja so več kot le tehnične težave pri razvoju natančnega modela napovedi. Modele napovedi je treba razviti z jasnim razumevanjem tako narave razmer, za katere želimo napovedati, kot tudi virov, ki so na voljo za pripravo napovedi. Pomembno je zagotoviti, da je izbrana spremenljivka neposredno povezana s potrebnimi podatki za napoved (Sheldon, 1993). To ne pomeni, da so napovedi neuporabne, temveč da morajo tisti, ki jih uporabljajo, nenehno spremljati svoje poslovno okolje, da bi odkrili vse dejavnike, ki kažejo na nedosledne ali nepravilne vzorce.

Čeprav je napoved podvržena netočnostim, predstavlja pomembno vodilo za prihodnje operative dejavnosti podjetja. Utemeljitev za izdelavo napovedi v podjetju je tudi cikličnost, ki se pojavlja pri poslovanju podjetja. Predvidevamo, da če se je nek dogodek zgodil v



preteklosti, se lahko zgodi tudi v prihodnosti. Če pa se je dogodek v preteklosti pojavil z določeno pogostostjo, se poveča verjetnost, da se bo ponovil. Kljub številnim negotovostim je napoved, izdelana z znanstvenimi metodami, predpogoj za sprejemanje racionalnih odločitev v zvezi s poslovanjem podjetja.

Tudi gospodarska praksa kaže, da **preprosta metoda napovedovanja ne pomeni samodejno slabše metode** (Kucharski, 2013). Kot poudarja Kucharski, lahko naivne metode napovedujejo iste podatke s podobno natančnostjo. Poleg tega jih je veliko lažje uporabljati. Zaradi dejavnosti, povezanih z napovedovanjem povpraševanja, lahko organizacija pridobi številne koristi (preglednica 8.1).

Tabela 8.1. Prednosti napovedovanja povpraševanja

Ugotovljena korist napovedovanja	Utemeljitev
Boljša organizacija proizvodnje	Če organizacija pozna napovedan obseg prodaje končnih izdelkov, lahko vnaprej načrtuje ustrezen obseg proizvodnje in ustrezno povpraševanje po surovinah in embalaži ter tako odpravi pomanjkanje na proizvodni liniji.
Večji nadzor nad varnostnimi zalogami	Če poznate predvideni obseg prodaje končnih izdelkov, lahko načrtujete varnostne zaloge, ki bodo zagotovile pokritje povpraševanja na trgu.
Učinkovitejše zmanjšanje zastarelega asortimaja	Če poznate predvideni obseg prodaje končnih izdelkov, se lahko osredotočite na oskrbo le tistega asortimaja, ki je potreben za pokrivanje povpraševanja; zastarele izdelke lahko izločite in posledično optimizirate stroške zamrznjenega kapitala v zalogah in stroške skladiščenja.
Večje zadovoljstvo strank in izboljšanje podobe organizacije	Poznavanje napovedanega obsega prodaje končnih izdelkov lahko zagotovi, da se v skladišču vzdržuje ustrezna raven zalog,
Učinkovitejša uporaba skladiščnega prostora	Če poznate predvideni obseg prodaje končnih izdelkov, lahko zberete le potrebne zaloge izdelkov, poleg tega pa lahko bistveno zmanjšate količino uporabljenega skladiščnega prostora.
Učinkovitejši nadzor in zmanjšanje stroškov	Če poznate napovedani obseg prodaje končnih izdelkov, lahko natančneje načrtujete proračun organizacije in natančneje nadzorujete stroške.

Vir: (Wojciechowski & Wojciechowska, 2015; Wolny & Kmiecik, 2020)

Navesti je treba več lastnosti napovedi. Te so



1. Napovedi se oblikujejo na podlagi dosežkov znanosti (razviti in preverjeni matematični modeli).
2. Napovedi se nanašajo na določeno prihodnost.
3. Napovedi se preverjajo empirično (po določenem času).
4. Napovedi so sprejemljive za osebo, ki jih pripravi.

Napovedi podpirajo proces odločanja v podjetju in hkrati opravljajo različne funkcije. (Gajda, 2001):

- Priprava - napoved je spodbuda za določeno dejanje, vendar ne vpliva na napovedani pojav. Na njeni podlagi se sprejemajo le ekonomske odločitve.
- aktiviranje, napoved je spodbuda za določeno dejanje in hkrati vpliva na napovedani pojav. Zato se izvajajo ukrepi, katerih cilj je uresničitev napovedi (samouresničuje se ali ugodne napovedi, ki sprožijo ukrepe, ki ugodno vplivajo na uresničitev napovedi) ali izničenje napovedi (opozorilne napovedi, ki sprožijo ukrepe, ki preprečujejo njihovo uresničitev)).


Vendar je treba upoštevati, da se lahko izdelane napovedi zlahka porušijo zaradi naključnih spremenljivk, ki jih ni mogoče vključiti v model, ali pa so preprosto napačne že od samega začetka. Zato je lahko napovedovanje za organizacije nevarno. Z napovedovanjem so povezane tri težave.

- Podatki, na podlagi katerih se pripravljajo napovedi, so vedno stari in se nanašajo na pretekla obdobja. Zato nikoli ni zagotovljeno, da se bodo pretekli pogoji ohranili tudi v prihodnosti.
- izjemnih ali nepričakovanih dogodkov ali zunanjih učinkov ni mogoče upoštevati (primer pandemije COVID-19; vpliv vojn in oboroženih spopadov; vpliv nepredvidenih gospodarskih kriz),
- napovedi ne morejo upoštevati lastnega vpliva.

Ustrezno izvedeno napovedovanje omogoča podjetnikom in menedžerjem, da vnaprej načrtujejo svoje dejavnosti, kar povečuje možnosti, da ostanejo konkurenčni na trgih.

8.2. Razvrstitev metod napovedovanja

Obstajata dve osnovni skupini metod napovedovanja: kvantitativne in kvalitativne (slika 8.2). Napoved, ki se uvršča med kvantitativne metode napovedovanja, ima obliko določenega števila (točkovna napoved) ali pa številčnega razpona (intervalna napoved).



Slika 8.2. Metode napovedovanja - vrste

Vir: (Dittmann, 2000)

Kvalitativne napovedi imajo neštevilo obliko. Nanašajo se na analizirani pojav v prihodnosti in oceno njegove rasti, upada ali nespremenjenosti. Kvalitativne napovedi se lahko obravnavajo kot tiste, ki temeljijo na mnenjih tržnih strokovnjakov.

Z vidika strokovnjaka za logistiko pa so ključne napovedi tiste, ki jih je mogoče opredeliti s številkami, tj. kvantitativne napovedi. Kvantitativno napovedovanje zaobide strokovni dejavnik in poskuša iz analize odstraniti človeški dejavnik. Ti pristopi se osredotočajo izključno na podatke.

Kvantitativne metode	Modeli časovnih vrst
	Ekonometrični modeli
	Analogni modeli
	Modeli vodilnih spremenljivk
	Modeli kohortne analize
	Tržni testi

Slika 8.3. Kvantitativne metode napovedovanja

Vir: (Dittmann, 2000).



Kvantitativne napovedi je mogoče razvrstiti glede na uporabljene modele (slika 8.3). V tej knjigi se osredotočamo na **modele časovnih vrst**.

8.3. Napovedovanje časovnih vrst

Ena od najpogostejše uporabljenih metod napovedovanja povpraševanja so metode, ki temeljijo na modelih časovnih vrst. Časovne vrste so metodologija za raziskovanje kompleksnih in zaporednih vrst podatkov. V modelih časovnih vrst se zaporedni podatki, ki so sestavljeni iz nizov številčnih podatkov, beležijo v rednih časovnih presledkih (npr. na minuto, na uro ali na dan). Priljubljenost teh metod izhaja iz možnosti pridobivanja informacij o prihodnjem poteku opazovanega pojava z napovedovanjem. Zato ni treba zbirati in analizirati dodatnih podatkov iz drugih virov. Napovedovanje z uporabo časovnih vrst se pogosto uporablja tudi zaradi velike verjetnosti pojava. Tudi gospodarska praksa kaže, da napovedi, pripravljene z uporabo modelov časovnih vrst, niso slabše od napovedi, pridobljenih na podlagi bolj zapletenih modelov. Izkušnje kažejo tudi, da **imajo modeli časovnih vrst razvojni potencial**. Vsaka naslednja sprememba metode ali naslednje metode napovedovanja časovnih vrst naj bi po definiciji izboljšala kakovost njenih rezultatov.


8.4. Razčlenitev časovnih vrst

Napovedi se oblikujejo na podlagi podatkov o časovnih vrstah. To se zgodi ne glede na uporabljeno metodo napovedovanja. Podatki o časovnih vrstah (spremenljivke) so razvrščeni kronološko, od najstarejših podatkov do najnovejših. Poudariti je treba, da zadnji podatki ne ustrezajo času izdelave napovedi. V znanstvenih publikacijah in študijah se predpostavlja, da y_t vedno določa določeno vrednost vrste y v obdobju (trenutku) t

Komponente časovnih vrst so naključna nihanja, razvojna težnja (trend), ciklična nihanja in sezonska nihanja (preglednica 8.2)



Tabela 8.2. Vizualizacija časovnih vrst



Vir: lastna študija

O vsakem od njih lahko povemo nekaj besed (Cieslak, 1997):

- naključna nihanja - to so naključne, naključne in nepredvidljive spremembe serijske spremenljivke z različno močjo, ki jih opazujemo skozi čas in ne kažejo jasne tendence. Povezana so z napakami statistične ali prognostične narave.
- razvojne tendence (trend) - so dolgoročne težnje podatkovnih vrst k enosmernim (monotonim) spremembam napovedane spremenljivke. So naraščajoče ali padajoče narave. Najpogosteje se nanašajo na trajni pojav, ki vpliva na analizirane podatke. Podatki časovnih vrst lahko vsebujejo tako razvojne trende kot naključna nihanja. Da bi izločili razvojne trende, je običajno potrebnih več zgodovinskih podatkov. Zato se ravnamo po pravilu palca: Čim daljše je obdobje opazovanja zgodovinskih podatkov, tem večja je zmožnost natančnega določanja vrste trenda. Trend je predstavljen z linearno ali nelinearno matematično funkcijo,
- Ciklična nihanja - gre za dolgoročna ritmična nihanja vrednosti spremenljivke okoli trenda ali konstantne ravni, ki trajajo dlje časa (več kot eno leto). So



posledica poslovnih ciklov. Opaziti je mogoče različne dolžine ciklov in njihovo dinamiko. Ciklična nihanja so zato povezana s spremembami v gospodarski dejavnosti podjetij, krizami ali okrevanjem gospodarstva ali blaginjo družbe. Za analizo cikličnih nihanj in izdelavo napovedi prihodnjega povpraševanja so potrebni mesečni, četrtni ali letni zgodovinski podatki iz zadnjih nekaj let.

- sezonska nihanja - to so nihanja vrednosti spremenljivke časovne vrste okoli trenda ali stalne ravni, ki se ponavljajo v rednih (sezonskih) intervalih, ki niso daljši od enega leta. V takem primeru bo natančnost izdelanih napovedi odvisna od vrste in obsega sezonskih nihanj, števila in vrste vrzeli v razpoložljivih podatkih ter obdobja napovedi.

Identifikacija in analiza navedenih komponent časovne vrste se imenujeta dekompozicija časovne vrste.

8.5. Priprava podatkov o časovnih vrstah

Preden se lotimo oblikovanja napovedi, je treba opraviti predhodno obdelavo podatkov, imenovano tudi **čiščenje podatkov**. Preveriti jih je treba, da se odpravijo napake ali odstopanja. Izpustitev tega koraka lahko povzroči izkrivljanje rezultatov napovedi in posledično napake v zaključkih. Ne smemo pozabiti, da so podatki, povezani z nenavadnimi primeri (odstopanji ali redkimi primeri), resnične informacije, glede katerih napovedovalec ne dvomi. So preverjeni in zanesljivi.





Obstajajo različne strategije za obravnavanje podatkov, ki odstopajo od pričakovanih vrednosti. Med drugim so to:

- brez ukrepanja, vključuje ignoriranje netipičnih podatkov, saj so nekatere metode napovedovanja odporne na pojav netipičnih podatkov,
- Filtriranje primerov z odstopajočimi podatki - to pomeni odstranitev teh podatkov, vendar to ni najboljša strategija,
- nadomeščanje nenavadnih podatkov - to je priljubljena strategija, pri kateri se izstopajoče vrednosti nadomestijo z: (1) vrednostjo 0, (2) povprečno



vrednostjo, (3) največjo/minimalno vrednostjo filtra ali (4) drugo vrednostjo, določeno na podlagi vsebinskega merila.

Preglednica 8.3. Izbrane vrste odstopanj

Dodajanje izstopajočih vrednosti Zdi se, da je to presenetljivo velika ali presenetljivo majhna vrednost za posamezno opazovanje. Na nadaljnja opazovanja ne vpliva, saj vrednost serije ne odstopa več.	
Inovativno odstopanje Pojavi se kot odstopanje z nadaljnjimi učinki na opazovanja. Opazimo lahko začetni (prvi) učinek z zamikom in podaljšanjem učinka na nadaljnja opazovanja (zmanjševanje ali povečevanje). Ta učinek se lahko sčasoma zmanjša ali poveča.	
Odstopanje pri prehodnih spremembah To se zgodi, ko vpliv eksponentno upada z nadaljnjimi opazovanji. Sčasoma se serija vrne na običajno raven.	
Sezonsko aditivno odstopanje Pojavi se kot presenetljivo velika ali presenetljivo majhna vrednost, ki se pojavlja periodično (v rednih časovnih presledkih).	

Vir: lastna študija

Če v časovni vrsti pustimo netipične podatke, to izkrivlja rezultate njihove analize in otežuje oblikovanje zaključkov, saj imajo netipični podatki izredno majhne ali izredno velike vrednosti. Zaradi njihove nekonsistentnosti se te vrednosti imenujejo **izstopajoče vrednosti**. Posledično povečujejo razpon v časovni vrsti (razpon najmanjše in največje vrednosti). Zato imajo netipični podatki velik izkrivljajoč učinek na vrednost napovedi (preglednica 8.3)

Odločitev o spremembi velikosti nenavadnega elementa, ali njegovi odstranitvi je za napovedovalca vedno zelo subjektivna, zato je potrebna previdnost. Zmanjšanje subjektivnosti napovedovalca pri odstranjevanju netipičnih primerov je mogoče s kvantitativnimi podatki.




Uporabite lahko na primer **pravilo standardnega odklona**. To pomeni, da če so zgodovinski podatki nenavadni (npr. zunaj razpona skupinskega povprečja ($\bar{x}$) plus ali minus 2 ali 3 standardni odkloni), se spremenijo ali odstranijo

Vsako serijo podatkov je vredno predložiti v postopek razgradnje. Določi se lahko več korakov:

1. Določite funkcionalno obliko serije, kar pomeni, da določite vrsto trenda.
2. Poiščite odstopajoča opazovanja in jih nadomestite s povprečnimi vrednostmi ali tako imenovanimi zgornjimi in/ali spodnjimi filtri.
3. Preveri, ali se zadnji opazovani podatek v seriji obnaša značilno; če se ne, ga očisti.
4. Določitev koeficienta naklona trenda, da se določi stabilnost glavnega trenda, opaženega v seriji.
5. Preučite stabilnost trenutnega kratkoročnega trenda.

Filtri (minimalni ali maksimalni) so dobra rešitev, kadar se pojavijo izstopajoče vrednosti (slika 8.4).




Slika 8.4. Očitno neskladne vrednosti s splošno pravilnostjo časovnih vrst.

Vir: lastna študija

Filter se uporablja za popravljanje podatkov pred pripravo naslednje napovedi. Vrednost, ki odstopa od pravilne serije, se nadomesti z minimalnim ali maksimalnim filtrom (slika 8.5). Skrajne izstopajoče vrednosti se najdejo nad $y_{max} + 3R_q$ ali pod $y_{min} - 3R_q$.



Vrednosti, za katere se sumi, da so izstopajoče, so vključene v območja $(y_{min} - 1,5R_q; y_{min} - 3R_q)$ in $(y_{max} + 1,5R_q; y_{max} + 3R_q)$



Slika 8.5. Vrednosti filtrov in izstopajoče vrednosti

Vir: (Grzybowska, 2009)

To je predstavljeno z modelom:

$$F_{min} = y_{min} - 1,5R_q$$

$$F_{max} = y_{max} + 1,5R_q$$

$$R_q = y_{max} - y_{min}$$

kjer:

F_{min} - najmanjša vrednost filtra

F_{max} - največja vrednost filtra

y_{min} - najmanjša vrednost, določena iz časovne vrste

y_{max} - največja vrednost, določena iz časovne vrste

R_q - medkvartilno območje.

8.6. Metode napovedovanja časovnih vrst

Metode napovedovanja časovnih vrst so razdeljene glede na trend podatkov. Napovedi se lahko določijo za konstantno povpraševanje, povpraševanje, podobno trendu (naraščajoče ali padajoče), in sezonsko povpraševanje (slika 8.6).



Konstantno povpraševanje	Naivne metode
	Povprečne metode
	Metoda eksponentnega glajenja (Brownov model)
	Model ARMA
Trendovsko povpraševanje	Linearna metoda eksponentnega glajenja (Holtov model)
	Metoda preproste linearne regresije
	Model ARIMA
	Model RW
Sezonsko povpraševanje	Holt-Winters' sezonska metoda (Holt-Winters' model)

Slika 8.6. Kvantitativne metode za napovedovanje časovnih vrst

Vir: lastna študija

V predstavljenih modelih se parameter y vedno nanaša na dejanske vrednosti povpraševanja, parameter $\hat{y}_t$ pa na izdelano napoved.

Naivne metode

Za metode naivnega napovedovanja je značilno, da so preproste, hitre in poceni. Omogočajo izdelavo napovedi na podlagi majhne količine preteklih podatkov. Naivne metode služijo tudi kot referenčna točka za druge metode napovedovanja (Kucharski, 2013).

Naivne metode so najpreprostejše mehanske metode. Razvite so bile ob predpostavki, da se povpraševanje v prihodnosti ne bo bistveno spremenilo. Zelo primerne so, kadar ni velikih nihanj v napovedani spremenljivki. Temeljijo izključno na preteklih opazovanjih. Naivni modeli imajo spomin samo na eno (zadnje) opazovanje, zato ne bodo filtrirali šumov v podatkih, temveč jih bodo kopirali v prihodnost.

Naivni modeli so sestavljeni iz preprostih projektivnih modelov. To pomeni, da potrebujejo vhodne podatke iz nedavnih opazovanj in da se ne izvaja statistična analiza. So izjemno preprosti in hkrati presenetljivo učinkoviti. Prednost teh metod je hitra odločitev o napovedani vrednosti. Pomanjkljivost pa je nezmožnost analize vzročno-posledičnih povezav, na katerih temelji napovedana spremenljivka



Za namene te študije bodo predstavljene tri naivne metode: (1) naivna napoved; (2) sezonska naivna metoda; (3) metoda drifta.

Naivna napoved

Naivna napoved je napoved, pri kateri je napovedana vrednost za določeno obdobje preprosto enaka vrednosti, ugotovljeni v prejšnjem obdobju. To predstavlja formalni model:

$$\check{y}_t = y_{t-1}$$

kjer:

$\check{y}_t$ - napoved za prihodnje obdobje

$y_{(t-1)}$ - dejanska vrednost povpraševanja iz prejšnjega obdobja.



Formula, uporabljena v Excelu:

napoved_(t) = povpraševanje_(t-1)

Sezonska naivna metoda

Tudi naivna metoda je uporabna za podatke z majhnimi sezonskimi nihanji. V tem primeru je vsaka napoved enaka zadnji opazovani vrednosti iz iste sezone (npr. iz istega meseca prejšnjega leta). Napovedi prevzamejo vrednost, opazovano v prejšnji sezoni. Model je uporaben pri majhnih naključnih nihanjih in aditivni sezonskosti. To predstavlja formalni model:

$$\check{y}_{t+h|T} = y_{t+h-m(k+1)}$$

kjer:

$\check{y}_{t+h|T}$ - napoved za prihodnje obdobje

m - sezonsko obdobje

k - zaključeni deli $(h-1)/m$ (tj. število zaključenih let v obdobju napovedi pred $T+h$).



Model je videti bolj zapleten, kot je v resnici. Če je na primer napoved izdelana na podlagi mesečnih podatkov, velja za vse prihodnje mesečne vrednosti in je enaka zadnji opazovani vrednosti za ta mesec prejšnjega leta. Pri četrtnih podatkih je napoved vseh prihodnjih vrednosti za *drugo četrtno leto* enaka zadnji opaženi vrednosti za *drugo četrtno leto* (kjer *drugo četrtno leto* pomeni drugo četrtno leto). Podobna pravila veljajo tudi za druge mesece in četrtna ter druga sezonska obdobja.



To pojasnjuje formula, ki se uporablja v programu Excel:

napoved_(t) = povpraševanje_(t, prejšnje leto)

Napoved za obdobje t je enaka povpraševanju iz ustreznega obdobja prejšnjega leta. Pri sezonski naivni metodi bo potreben enoletni zamik.

Metoda zdrsa

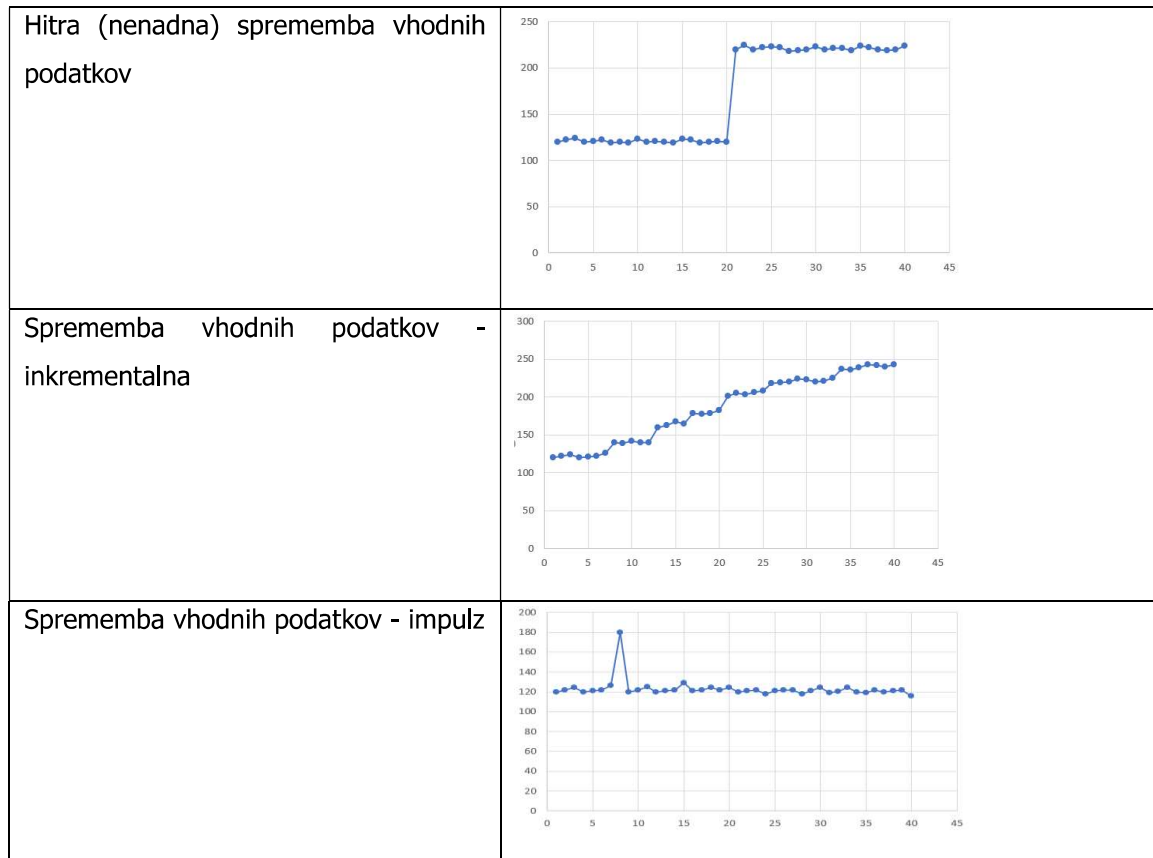
Pri metodi zdrsa, ki je različica sezonske naivne metode, se dovoli, da se napovedi s časom povečujejo ali zmanjšujejo, pri čemer je količina spremembe s časom (imenovana drift) nastavljena na povprečno spremembo, ki je bila ugotovljena v preteklih podatkih. Metoda uporablja dodatno komponento, imenovano premik

Dršenje se nanaša na zmanjšanje učinkovitosti modela zaradi sprememb podatkov in razmerja med vhodnimi in izhodnimi spremenljivkami. To pa lahko povzroči poslabšanje kakovosti modela napovedovanja, kar ima za posledico netočne napovedi. Dršenje spremenljivk se nanaša na spremembe vhodnih vrednosti, npr. zaradi nenadnih sprememb v prodajnih trendih. Spreminjanje vhodnih podatkov je lahko:

- nasilne (nenadne), npr. zaradi zapor med pandemijo COVID-19,
- narašča (počasi se spreminja),
- impulzno (enkratno), npr. v primeru nepravilno posredovanih podatkov.



Preglednica 8.4. Vrste odnašanja



Vir: lastna študija

To je predstavljeno s formalnim modelom:

$$\tilde{y}_{t+h|T} = y_t + h \left(\frac{y_t - y_1}{t-1} \right)$$

kjer:

$\tilde{y}_{t+h|T}$ - napoved za prihodnje obdobje

$h \left(\frac{y_t - y_1}{t-1} \right)$ - sestavni del, ki je povezan z zdrsom.

To je enako, kot če bi potegnili črto med prvim in zadnjim opazovanjem ter jo ekstrapolirali v prihodnost.



To pojasnjuje formula, ki se uporablja v programu Excel:



napoved_(t) = povpraševanje_(iz zadnjega obdobja prejšnjega leta) + [h * (povpraševanje_(iz zadnjega obdobja prejšnjega leta) - povpraševanje_(iz prvega obdobja prejšnjega leta)] / n -

Napoved za obdobje *t* je enaka povpraševanju za zadnje obdobje prejšnjega leta + *komponenta premika*. Komponenta premika vsebuje število *h*, ki se nanaša na naslednje število izdelanih napovedi, *t* pa določa število obravnavanih obdobj v letu.

Povprečne metode

Metode drsečega povprečja delujejo kot filtri, saj iz podatkovnih vrst odstranijo kratkoročna nihanja. Metode drsečega povprečja za izdelavo napovedi uporabljajo določeno število sosednjih podatkov o povpraševanju.

Z večanjem števila preteklih podatkov, na podlagi katerih je izdelana napoved, se povečuje učinek glajenja. To pomeni, da uporaba večjega števila podatkov v modelu močnejše zgladi vrsto. Povzroča tudi počasnejši odziv na spremembe ravni napovedane spremenljivke. In obratno. Uporaba manjšega števila preteklih podatkov pomaga hitreje odražati spremembe povpraševanja iz zadnjih obdobj. Napoved je nato bolj občutljiva na naključna nihanja. Za namene te študije bodo predstavljene 4 metode povprečenja: (1) globalno povprečje ali globalno povprečje; (2) enostavno drseče povprečje, SMA; (3) eksponentno drseče povprečje, EMA; (4) tehtano drseče povprečje, WMA.

Globalno povprečje (mean) ali globalno povprečje (average)

Napoved z uporabo metode globalnega povprečja temelji na vseh razpoložljivih preteklih opazovanjih, vključenih v serijo. S to metodo se določi osrednja tendenca, ki je lokacija središča podatkovne vrste v statistični porazdelitvi.

Vrednost napovedi z uporabo metode globalnega povprečja je treba izračunati tako, da seštejemo vrednosti vseh preteklih podatkov in izračunano vrednost delimo s številom analiziranih obdobj.



To je predstavljeno s formalnim modelom:

$$\tilde{y}_t = \frac{\sum_{t=1}^n y_t}{n}$$

kjer:

n - število analiziranih obdobj.



To pojasnjuje formula, ki se uporablja v programu Excel:

napoved_(t) = povpraševanje/n

Uporaba aritmetične sredine celotnega niza podatkov izkrivlja rezultat napovedi. Podatki, uporabljeni pri tej metodi, so preveč zastareli, kar izkrivlja pravilno sliko prihodnjega povpraševanja.

Enostavno drseče povprečje, SMA

Metoda enostavnega drsečega povprečja uporablja tipično aritmetično povprečje, vendar le za določeno količino zgodovinskih podatkov. Urejeni podatki pomagajo zgladiti podatke o povpraševanju ter zmanjšajo vpliv naključnih nihanj in zastarelih podatkov. Ime drseče povprečje pomeni, da se vsaka napoved izračuna na podlagi podatkov iz prejšnjih *x* obdobj. Preprosto drseče povprečje ne razlikuje zgodovinskih podatkov in teh podatkov ne uteži.

Preprosto drseče povprečje je aritmetično drseče povprečje, ki se izračuna tako, da se seštejejo zadnji podatki o povpraševanju in nato dobljena vrednost deli s številom obdobj v izračunanem povprečju. To je predstavljeno s formalnim modelom:

$$\tilde{y}_t = \frac{\sum_{t+1-m}^t y}{m}$$

kjer:

m - število analiziranih obdobj.



To pojasnjuje formula, ki se uporablja v programu Excel:

za povprečje treh elementov:



**napoved_(t) = SREDNINA(povpraševanje_(t-1); povpraševanje_(t-2);
povpraševanje_(t-3));**

Za izračun drsečega povprečja lahko uporabite preprosto formulo, ki temelji na funkciji AVERAGE z relativnimi referencami.

Ob kopiranju formul po stolpcu navzdol se območje v vsaki vrstici spremeni, da se upoštevajo vrednosti, ki so potrebne za vsako povprečje.

Daljše kot je drseče povprečje, večji je **zamik**. To je mogoče razložiti na naslednji način:

- Napoved, ki temelji na 3 zgodovinskih podatkih, je kratkoročno drseče povprečje; je kot motorni čoln, ki je gibljiv in se hitro spreminja
- Napoved, ki temelji na 50 zgodovinskih podatkih, je dolgoročno drseče povprečje; je kot oceanski tanker - počasen in počasi se spreminja.
- Zato je treba pri izbiri ustreznega števila zgodovinskih obdobj upoštevati faktor zamika (ne uporabljajte preveč podatkov)

EkspONENTNO drseče povprečje, EMA

Metoda eksponentnega drsečega povprečja omogoča zmanjšanje zakasnitve z večjim upoštevanjem nedavnih zgodovinskih vrednosti podatkov. Zaradi tega je metoda bolj odzivna na nedavne vrednosti podatkov. EkspONENTNO drseče povprečje je običajno bolj občutljivo na nedavne spremembe povpraševanja kot preprosto drseče povprečje. To je predstavljeno s formalnim modelom:

$$\tilde{y}_t = p_{t-1} + \alpha(y_{t-1} - p_{t-1})$$

$$\alpha = \frac{2}{n + 1}$$



kjer:

– *multiplier*

n - izbrano časovno obdobje.

Izračun eksponentnega drsečega povprečja vključuje tri korake:

1. Izračun enostavnega drsečega povprečja za obdobje (predhodna napoved). SMA je potrebna le za zagotavljanje začetne vrednosti za nadaljnje izračune.
2. Izračun množitelja za obtežitev eksponentnega drsečega povprečja.

Primer: če je napoved sestavljena iz treh obdobj, se multiplikator izračuna na naslednji

način: $\text{multiplikator} = \alpha = \frac{2}{n+1} = \frac{2}{3+1} = 0,5$

3. Izračun trenutne napovedi v skladu z eksponentnim drsečim povprečjem

Opomnik: Prva izračunana napoved se imenuje predhodna napoved.



To pojasnjuje formula, ki se uporablja v programu Excel:

$\text{napoved}_{(t)} = \text{napoved}_{(t-1)} + \text{multiplikator} * (\text{povpraševanje}_{(t-1)} - \text{napoved}_{(t-1)})$

Metoda EMA se uporablja za zajemanje krajših gibanj trendov, saj se osredotoča na najnovejše podatke in nedavne napovedi.

Uteženo drseče povprečje, WMA

To je različica preprostega drsečega povprečja (SMA). Metoda tehtanega drsečega povprečja (WMA) je drseče povprečje, ki daje težo zadnjim vrednostim povpraševanja. To pomeni, da imajo najnovejši podatki večji vpliv na vrednost napovedi kot starejši podatki. To je mogoče z uporabo ponderiranega faktorja. Uporaba ponderiranih koeficientov omogoča natančnejše napovedi. Za to metodo velja, da je bolj občutljiva na spremembe v povpraševanju.



Napovedi s tehtanim drsečim povprečjem dobimo tako, da vsako vrednost povpraševanja pomnožimo z vnaprej določenim tehtanim faktorjem in dobljene vrednosti seštejemo. To je predstavljeno s formalnim modelom:

$$\tilde{y}_t = \sum_{i=t+1-m}^t (y_i \cdot \varpi_i)$$

kjer:

ϖ - ponderirani koeficient.

Če želite določiti njihovo vrednost, si zapomnite nekaj pravil:

- Vrednosti ponderiranih koeficientov so v območju $, < 0,1 >$
- Vsak naslednji uporabljeni ponderirani koeficient je večji od svojega predhodnika $\varpi_i < \varpi_{i+1} < \varpi_{i+2}$. To je zelo pomembno načelo, saj razlikuje pomembnost uporabljenih zgodovinskih podatkov. Starejši imajo nižji ponderirani koeficient, novejši podatki so pomembnejši in imajo višji ponderirani koeficient,
- Vsota vseh ponderiranih koeficientov mora biti enaka 1: $\sum_1^n \varpi_i = 1$
- Število ponderiranih koeficientov je odvisno od števila analiziranih zgodovinskih obdobj iz časovnih vrst.

To je razloženo s formulo, ki se uporablja v Excelu

za 3-elementno tehtano povprečje:



napoved_(t) = (povpraševanje_(t-3) * $\omega_{(1)}$) + (povpraševanje_(t-2) * $\omega_{(2)}$) + (povpraševanje_(t-1) * $\omega_{(3)}$)

za 5-elementno tehtano povprečje:



$$\text{napoved}_{(t)} = (\text{povpraševanje}_{(t-5)} * \omega_{(1)}) + (\text{povpraševanje}_{((t-)(4))} * \omega_{(2)}) \\ + (\text{povpraševanje}_{(t-3)} * \omega_{(3)}) + (\text{povpraševanje}_{(t-2)} * \omega_{(((4))})}) + \\ (\text{povpraševanje}_{(t-1)} * \omega_{((5))})$$

Pri metodi tehtanega drsečega povprečja je treba določiti vrednost konstante glajenja (koliko preteklih obdobij je treba uporabiti) in ravni posameznih uteži tehtanih koeficientov.

Metode eksponentnega glajenja

Pogosto se uporabljajo metode eksponentnega glajenja (Chatfield et al., 2001). Obstaja 15 različnih metod. Vsaka različica je določena za različen scenarij napovedovanja. Najbolj znane različice metode eksponentnega glajenja so Simple Exponential Smoothing (SES) (brez trenda, brez sezonskosti), Holtova linearna metoda (aditivni trend, brez sezonskosti), Holt-Wintersova aditivna metoda (aditivni trend, aditivna sezonskost) in Holt-Wintersova multiplikativna metoda (aditivni trend, sezonskost). multiplicative) (De Gooijer in Hyndman, 2006). Raziskovalci so predlagali številne različice prvotnih metod eksponentnega glajenja; Carreno in Madinaveitia (1990) sta na primer predlagala spremembe za obravnavo diskontinuitet, Rosas in Guerrero (1994) pa sta obravnavala napovedi z eksponentnim glajenjem ob upoštevanju ene ali več omejitev. Za namene te študije bodo predstavljene tri metode eksponentnega glajenja: (1) enostavno eksponentno glajenje, SES (model Browna); (2) linearno eksponentno glajenje, LES (model Holta); (3) Holt-Wintersova sezonska metoda (model Holt-Winters).

Enostavno eksponentno glajenje, SES (Brownov model)

Enostavno eksponentno glajenje je osnovna oblika eksponentnega glajenja. Metoda eksponentnega glajenja (Brownov model) je razmeroma natančna metoda napovedovanja povpraševanja. Upošteva faktor eksponentnega glajenja (α). Ta koeficient nadzoruje hitrost, s katero podatki vplivajo na izdelane napovedi. Hkrati metoda daje večjo težo novejšim podatkom. Ko so podatki bolj oddaljeni, jim pripisuje eksponentno padajoče uteži.

Če želite določiti vrednost eksponentnega faktorja glajenja, upoštevajte naslednja pravila:



- vrednost eksponentnega koeficienta glajenja je v območju $(0,1)$
- Vrednost eksponentnega koeficienta glajenja se izbere eksperimentalno. Uporabiti je treba naslednjo predpostavko: bližje ko je koeficient 0, bolj so podatki zglajeni (napoved je manj občutljiva na spremembe povpraševanja) in napovedovalec bolj zaupa napovedi iz prejšnjega obdobja; kazalnik, ki je bližje 1, pomeni, da je napoved bolj občutljiva na spremembe povpraševanja in da napovedovalec izhaja iz dejanskega stanja, ki se je zgodilo v prejšnjem obdobju.

To je predstavljeno s formalnim modelom:

$$\tilde{y}_t = a \cdot y_{t-1} + (1 - a) \cdot p_{t-1}$$

kjer:

a faktor eksponentnega glajenja.

Izračun napovedi z uporabo enostavne metode eksponentnega glajenja vključuje tri korake:

1. Izračun naivne napovedi za prvo obdobje (začetna napoved). Začetna napoved je potrebna le za zagotovitev začetne vrednosti za nadaljnje izračune.
2. Določanje faktorja eksponentnega glajenja; faktor eksponentnega glajenja $a = (0,1)$
3. Izračun napovedi po metodi enostavnega eksponentnega glajenja.



Formula, uporabljena v Excelu:

$$\text{napoved}_{(t)} = \text{alfa} * \text{povpraševanje}_{(t-1)} + [(1 - \text{alfa}) * \text{napoved}_{(t-1)}]$$

Za napovedovanje na podlagi podatkov brez izrazitega trenda ali sezonskosti se uporablja preprosta metoda eksponentnega glajenja.

Linearno eksponentno glajenje, LES (Holtov model)



Metoda dvojnega eksponentnega glajenja (tako imenovani Holtov model) zajema linearne trende v podatkih. To je pravi model za povpraševanje, pri katerem je mogoče opaziti konstanten trend naraščanja ali upadanja. Vendar pa ni sezonskosti.

Model dvojnega eksponentnega glajenja temelji na dveh faktorjih glajenja. Eden se nanaša na glajenje ravni spremenljivke (naključna nihanja), drugi pa na njeno povečanje (trendna nihanja). Oba koeficienta morata biti znotraj razpona: $(0,1)$. To je predstavljeno s formalnim modelom:

$$\begin{aligned}\tilde{y}_t &= L_{t-1} + T_{t-1} \\ L_t &= \alpha y_{t-1} + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_{t-1} - L_{t-2}) + (1 - \beta)T_{t-1}\end{aligned}$$

kjer:

α - faktor glajenja ravni spremenljivke

β - dejavnik glajenja rasti.

V skladu z modelom sta potrebni dve začetni vrednosti L_t in T_t :

$L_t = y_{t-1}$ - po naivni metodi;

$T_t = y_{t-1} - y_{t-2}$

Formula, uporabljena v Excelu:



napoved_(t) = [alfa * povpraševanje_(t-1) + (1 - alfa)(naključno nihanje_(t-1)) + trendno nihanje_(t-1)] + [beta * (naključno nihanje_(t-1) - (naključno nihanje_(t-2)) + (1 - beta) * trendno nihanje_(t-1)]

Holt-Wintersova sezonska metoda (Holt-Wintersov model)

Metoda sezonskega eksponentnega glajenja, imenovana tudi Holt-Wintersov model, je zelo primerna za napovedovanje povpraševanja za podatke, za katere sta značilna tako trend kot sezonskost (www_8.1). Vendar je treba pridobiti dolge vrste podatkov o povpraševanju, saj je treba preveriti ponavljajoča se ciklična nihanja (potrditev, da v vrsti obstaja sezonsko



povpraševanje). Sezonska nihanja se pojavljajo v aditivni ali multiplikativni različici (Kucharski, 2013).

Dodatna nihanja se pojavijo, kadar je v posameznih podobdobjih sezonskega cikla mogoče opaziti odstopanja ravni analiziranega pojava od povprečne ravni ali trenda v smislu absolutne vrednosti.

To predstavlja formalni model:

$$\check{y}_t = L_{t-1} + T_{t-1} + S_{t-p}$$

$$L_t = \alpha(y_t - S_{t-p}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

$$S_t = \delta(y_t - L_t) + (1 - \delta)S_{t-p}$$

kjer:

α - faktor glajenja ravni spremenljivke

β - faktor glajenja trenda

δ - koeficient sezonske komponente

L_t - komponenta na ravni v času t

T_t - komponenta trenda v času t

S_t - sezonska komponenta v času t

p - sezonsko obdobje.

Formula, uporabljena v Excelu:



**napoved_(t) = komponenta ravni_(t-1) + komponenta trenda_(t-1) +
komponenta sezonskosti_(t-p)**

**komponenta ravni_(t) = alfa * [povpraševanje_(t) - komponenta
sezonskosti_(t)] + (1 - alfa) * (komponenta ravni_(t-1) + komponenta
trenda_(t-1))**



komponenta trenda_(t) = beta * (komponenta ravni_(t) - komponenta ravni_(t-1)) + [(1 - beta) * komponenta trenda_(t-1)]

komponenta sezonskosti_(t) = gama * (povpraševanje_(t) - komponenta ravni_(t)) + (1 - gama) * komponenta sezonskosti_(t-p)

komponenta sezonskosti_(t-p) za štiri četrletja

komponenta sezonskosti₍₁₎ = povpraševanje₍₁₎ / povprečno povpraševanje₍₁₋₄₎

komponenta sezonskosti₍₂₎ = povpraševanje₍₂₎ / povprečno povpraševanje₍₁₋₄₎

komponenta sezonskosti₍₃₎ = povpraševanje₍₃₎ / povprečno povpraševanje₍₁₋₄₎

komponenta sezonskosti₍₄₎ = povpraševanje₍₄₎ / povprečno povpraševanje₍₁₋₄₎

Multiplikativna nihanja se pojavijo, kadar je v posameznih podobdobjih cikla mogoče opaziti odstopanje od povprečne ravni ali trenda za določeno stalno relativno vrednost (Sobczyk, 2006). To je predstavljeno s formalnim modelom:

$$\check{y}_t = (L_{t-1} + T_{t-1})S_{t-p}$$

$$L_t = \alpha \left(\frac{y_t}{S_{t-p}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

$$S_t = \delta \left(\frac{y_t}{L_t} \right) + (1 - \delta)S_{t-p}$$

kjer:

α - faktor glajenja ravni spremenljivke

β - faktor glajenja trenda

δ - koeficient sezonske komponente



L_t - komponenta na ravni v času t

T_t - komponenta trenda v času t

S_t - sezonska komponenta v času t

p - sezonsko obdobje.

Ne smemo pozabiti, da je aditivni trend povezan z dvojnimi eksponentnim glajenjem z linearnim trendom, multiplikativni trend pa z dvojnimi eksponentnim glajenjem z eksponentnim trendom (www_8.2).

Formula, uporabljena v Excelu:

$\text{napoved}_{(t)} = (\text{komponenta ravni}_{(t-1)} + \text{komponenta trenda}_{(t-1)}) * \text{komponenta sezonskosti}_{(t-p)}$

$\text{komponenta ravni}_{(t)} = \text{alfa} * [\text{povpraševanje}_{(t)} / \text{komponenta sezonskosti}_{(t)}] + (1 - \text{alfa}) * (\text{komponenta ravni}_{(t-1)} + \text{komponenta trenda}_{(t-1)})$

$\text{komponenta trenda}_{(t)} = \text{beta} * (\text{komponenta ravni}_{(t)} - \text{komponenta ravni}_{(t-1)}) + [(1 - \text{beta}) * \text{komponenta trenda}_{(t-1)}]$



$\text{komponenta sezonskosti}_{(t)} = \text{gama} * (\text{povpraševanje}_{(t)} / \text{komponenta ravni}_{(t)}) + (1 - \text{gama}) * \text{komponenta sezonskosti}_{(t-p)}$

komponenta sezonskosti_(t-p) za štiri četrletja

$\text{komponenta sezonskosti}_{(1)} = \text{povpraševanje}_{(1)} / \text{povprečno povpraševanje}_{(1-4)}$

$\text{komponenta sezonskosti}_{(2)} = \text{povpraševanje}_{(2)} / \text{povprečno povpraševanje}_{(1-4)}$

$\text{komponenta sezonskosti}_{(3)} = \text{povpraševanje}_{(3)} / \text{povprečno povpraševanje}_{(1-4)}$



$$\text{komponenta sezonskosti}_{(4)} = \frac{\text{povpraševanje}_{(4)}}{\text{povprečno povpraševanje}_{(1-4)}}$$

Avtoregresijske metode

Med modeli napovedovanja imajo posebno mesto modeli stacionarnih serij ARMA (AutoRegressive Moving Average) in nestacionarnih serij ARIMA (AutoRegressive Integrated Moving Average model). To so modeli, ki temeljijo na pojavu avtokorelacije in so nastali z integracijo avtoregresijskega modela AR (AutoRegressive model) in modela MA (Moving Average) (Grzelak, 2019).

Za namene te študije bodo predstavljene tri avtoregresivne metode: (1) avtoregresivno drseče povprečje (ARMA); (2) avtoregresivno integrirano drseče povprečje (ARIMA); (3) naključna hoja (RW).

Modela ARMA in ARIMA imata veliko podobnosti. Sestavini AR(p) - splošni avtoregresijski model in MA - splošni model drsečega povprečja MA(q) sta enaki. Razlika med modeloma ARMA in ARIMA je v tem, da se razlikujeta. Če v modelu ARMA ni razlik, postane preprosto model ARIMA.

Avtoregresijsko drseče povprečje, ARMA

Pogoj za napovedovanje po metodi ARMA je vrsta podatkov, za katere je značilna stacionarnost. To pomeni, da lahko v tej vrsti razlikujemo konstantno srednjo vrednost, konstantno varianco in konstantno kovarianco, ki je odvisna le od časovnega intervala med vrednostmi (Schaffer et al., 2021).

V skladu z modelom ARMA je napovedana vrednost v času t odvisna od njenih preteklih vrednosti in od razlik med dejanskimi preteklimi vrednostmi napovedane spremenljivke in njenimi vrednostmi, pridobljenimi iz modela - napake napovedi. Ta model se imenuje model ARMA(p,q), kjer se p nanaša na red avtoregresijskega polinoma, q pa je red polinoma drsečega povprečja. To je predstavljeno s formalnim modelom:

$$\hat{y}_t = \varepsilon_t + (\alpha y_{t-1} + \varepsilon_t) + (\beta y_{t-2} - \alpha y_{t-1} + \varepsilon_t) + (\varepsilon_t + \alpha \varepsilon_{t-1})$$



kjer:

α - parameter avtoregresijskega modela

β - parameter modela drsečega povprečja

ε - modelska napaka (beli šum).

Formula, uporabljena v Excelu:

napoved_(t) = napaka modela_(t) + komponenta₁ + komponenta₂ + komponenta₃



Napaka modela_(t) = NORM.S.INV(rand())

komponenta₁ = alfa * komponenta_{1(t-1)} + napaka modela_(t)

komponenta₂ = beta * komponenta_{2(t-2)} - alfa * komponenta_{2(t-1)} + napaka modela_(t)

komponenta₃ = napaka modela_(t) + alfa * modelska napaka_(t-1)

Avtoregresijsko integrirano drseče povprečje, ARIMA

Pri modelih ARIMA je pozornost namenjena nestacionarnosti serije. V modelu so trije parametri: avtoregresijski parameter (p), parameter drsečega povprečja (q) in red diferenciacije (d). Model ARIMA(p,q,d) se opisuje tudi s številkami, na primer: (1,1,0), kar pomeni, da je v vrsti p=1 en sam avtoregresijski parameter, q=1 en sam parameter drsečega povprečja, d =0 pa ne pride do diferenciacije (Malska in Wachta, 2015).). Za dani primer je formalni splošni model naslednji:

$$\check{y}_t = \alpha + y_{t-1} + \beta_1(y_{t-1} - y_{t-2})$$

kjer:

α - parameter avtoregresijskega modela

β - parameter drsečega povprečja.



Formula, uporabljena v Excelu:

napoved_(t) = alfa + povpraševanje_(t-1) + beta * [povpraševanje_(t-1) - povpraševanje_(t-2)]

Naključni sprehod, RW

Model naključne hoje je podkategorija modela ARIMA. V preprostem modelu RW se predpostavlja, da je vsaka napoved vsota zadnjega opazovanja in naključnega izraza napake. Zato predpostavlja, da je zadnje opazovanje najboljši pokazatelj za oblikovanje najbližje naslednje napovedi. Ta model je precej preprost za razumevanje in izvajanje. Uporablja se, kadar je v zaporedju podatkov opazen trend razvoja. To je predstavljeno s formalnim modelom:

$$\tilde{y}_t = y_{t-1} + \varepsilon_t$$

$$\varepsilon_t = y_{t-1} - y_{t-2}$$

kjer:

ε - modelska napaka (beli šum).



Formula, uporabljena v Excelu:

napoved_(t) = povpraševanje_(t-1) + [povpraševanje_(t-1) - povpraševanje_(t-2)]

Ugotovljeno je bilo, da številne kompleksne metode napovedovanja, ki temeljijo na linearni strukturi, ne morejo premagati naivnega modela RW (Adhikari & Agrawal, 2014).

Regresijske metode

V regresijskih modelih ni mogoče govoriti o vplivu ene spremenljivke na drugo. S pomočjo spremenljivke ali niza spremenljivk se pojasnjuje druga spremenljivka. Za uporabo



regresijskih metod je potrebna večja količina preteklih podatkov - daljše kot je obdobje opazovanja preteklih podatkov, večja je možnost natančnega določanja napovedi.

Poznamo številne različice regresijskih modelov: linearna regresija, nelinearna regresija, logistična regresija, stopenjska regresija, ordinalna regresija. Formula za splošno obliko regresije je naslednja:

$$\hat{y}_t = f(X, \beta) + \varepsilon_t$$

kjer:

X - pojasnjevalna, napovedna spremenljivka

β - regresijski koeficient

$f(X, \beta)$ - regresijska enačba

ε_t - naključna napaka.

Za namene te študije bodo predstavljene tri metode eksponentnega glajenja: (1) metoda projekcije trenda; (2) metoda enostavne linearne regresije; (3) metoda večkratne linearne regresije.

Metoda projekcije trenda

Metoda projekcije trendov je različica linearne metode. Jet je najbolj klasična metoda poslovnega napovedovanja, ki obravnava gibanje spremenljivk skozi čas. Razlikujemo lahko med **grafično metodo** - pri kateri so podatki prikazani na grafu, skozi katerega se ročno potegne črta. Pri risanju črte se upošteva najmanjša razdalja med označenimi točkami in črto; metodo prilaganja enačbe trenda z uporabo podatkov in enačbe ravne ali eksponentne črte.

Metoda enostavne linearne regresije

Metoda linearne regresije je najpreprostejša različica regresije. Namen metode linearne regresije je, da se podatkom prilaga ravna črta. Zato morate poiskati rešitev, ki vam bo omogočila poiskati optimalno premico, ki bo najbolje prikazala razmerje med podatki. Pri preprosti metodi linearne regresije model napovedovanja temelji na linearni tendenci. Za določitev regresijske premice in s tem vrednosti v linearnem regresijskem modelu morate izračunati koeficienta premice a in b . To predstavlja formalni model:



$$\tilde{y}_t = an + b$$

kjer:

a - vrednost spremenljivke v analiziranem obdobju

b - vrednost povečanja ali zmanjšanja odvisne spremenljivke

n - serijska številka analiziranega in napovedanega obdobja.

Za določitev parametrov a in b morate izračunati sistem dveh enačb. Ta ima naslednjo obliko:

$$\begin{cases} a \sum_{i=1}^n t_i^2 + b \sum_{i=1}^n t_i = \sum_{i=1}^n t_i \cdot y_i \\ a \sum_{i=1}^n t_i + b \cdot n = \sum_{i=1}^n y_i \end{cases}$$

kjer:

t_i - zaporedna številka obdobja ($t = 1, 2, 3, \dots$), ki je vrednost neodvisne časovne spremenljivke

y_i - odvisna spremenljivka (npr. povpraševanje po določeni dobrini v določenem časovnem obdobju)

a - vrednost spremenljivke v analiziranem obdobju

b - vrednost povečanja ali zmanjšanja odvisne spremenljivke

n - število vseh analiziranih obdobj.



Najhitreje pa lahko zgornje regresijske koeficiente izračunate z uporabo funkcije LINEST.

Sintaksa: **LINEST(znan_y,[znan_x],[konstanta],[statistika])**

Metoda večkratne linearne regresije

Večkratna linearna regresija omogoča oblikovanje modelov linearnih povezav med več spremenljivkami. Metoda večkratne linearne regresije se uporablja pri analizi podatkov za



preučevanje zapletenih razmerij med več spremenljivkami. To je predstavljeno s formalnim modelom:

$$\check{y}_t = a + b_1 y_1 + b_2 y_2 + \dots + b_i y_i + \varepsilon$$

kjer:

a - Vrednost spremenljivke v analiziranem obdobju.

b - vrednost povečanja ali zmanjšanja odvisne spremenljivke

ε - modelska napaka (beli šum).

8.7. Napake v napovedi

Za oceno natančnosti napovedi je treba izmeriti napake napovedi. Glede na to, da ni zagotovila za popolno napoved prihodnjega povpraševanja (Hopp in Spearman, 1999), je vsaka napoved podvržena napakam.

Raziskovalci razlikujejo med sistematičnimi in nesistematičnimi učinki napak v napovedih (Zeiml et al., 2019). Uspešnost sistema napovedovanja se običajno meri z različnimi merami napak napovedi (preglednica 8.5).

Preglednica 8.5. Izbrane napake napovedi

Napaka v napovedi	Model	Tolmačenje
Srednja kvadratna napaka (MSE)	$MSE = \frac{\sum (y_t - p_t)^2}{n}$	Srednja kvadratna napaka je lahko le pozitivna, njena vrednost pa mora biti čim manjša. Vrednost te napake, ki je enaka 0, pomeni odlično natančnost napovedi.
Korenska srednja kvadratna napaka (RMSE)	$RMSE = \sqrt{\frac{\sum (p_t - y_t)^2}{n}}$	Vrednost napake mora biti čim bližje 0. Manjša kot je vrednost povprečne kvadratne napake, boljši je model. Tudi popoln model ima vrednost, ki je enaka 0.
Povprečna absolutna odstotna napaka (MAPE)	$MAPE = \frac{\sum E_t - A_t }{n}$	To je ena izmed najbolj priljubljenih mer napak. Vrednost 0 pomeni, da model nima povprečne napake, kar pomeni, da mora biti vrednost čim bližje 0. Pri enakih napakah napovedi je zaradi manjših dejanskih vrednosti relativna napaka večja.



Napaka v napovedi	Model	Tolmačenje
Povprečna odstotna napaka (MPE)	$MPE = \frac{100\%}{n} \sum \frac{a_t - f_t}{a_t}$	To je povprečni odstotek napake (ali odstopanja). Pove, kolikšno bo povprečno odstopanje od dejanske vrednosti v obdobju napovedi. MPE je uporaben, ker omogoča preverjanje, ali model napovedi sistematično podcenjuje (bolj negativna napaka) ali precenjuje (pozitivna napaka).
Srednje absolutno odstopanje (MAD)	$MAD = \sum \frac{ x_t - \bar{x}_t }{n}$	Gre za preprosto razširitev absolutne variance. Povprečni absolutni odklon se uporablja kot merilo variabilnosti podatkov.

Vir: (Hyndman & Koehler, 2006; Zeiml, et al., 2019)

8.8 Prednosti napovedovanja z uporabo Excel Forecasting

Za napovedovanje se lahko uporablja program Microsoft Excel. Z uporabo razvitih algoritmov in na podlagi zbranih podatkov iz preteklosti lahko pripravite obrazce za izdelavo napovedi in posledično sprejmete prave poslovne odločitve. Excel je osnovno orodje za napovedovanje.

Tabela 8.6. Izbrane funkcije programa Excel

Funkcija	Razlaga:
=ZELENINA	Ta funkcija omogoča izračun povprečja na podlagi obstoječih vrednosti.
=SUM	Funkcija omogoča izračun vsote na podlagi obstoječih vrednosti.
=FORECAST	Funkcija omogoča napovedovanje prihodnje vrednosti na podlagi obstoječih vrednosti z uporabo linearne regresije.



Funkcija	Razlaga:
=FORECAST.ETS	Izračuna ali napoveduje prihodnjo vrednost na podlagi obstoječih (preteklih) vrednosti z uporabo različice algoritma eksponentnega glajenja (ETS).
=LINEST	Izračuna statistične podatke za črto z metodo najmanjših kvadratov.
=FORECAST.LINEAR	Iz obstoječih vrednosti z linearno regresijo izračuna ali predvidi prihodnjo vrednost.
=TREND	Uporablja se za določitev linearnega trenda.
=FORECAST.ETS.SEASONALITY	Izračuna dolžino sezonskega vzorca na podlagi obstoječih vrednosti in časovnice.

Vir: lastna študija

Excel za napovedovanje uporablja številna mala, srednja in velika podjetja (tudi korporacije), saj ima na voljo številna ustrezna orodja. Podatke je mogoče preprosto shraniti in izračunati v Excelovem delovnem zvezku. Excel lahko pridobljene in obdelane podatke vizualizira na različne načine, kar je koristno in pripomore k lažjemu napovedovanju (www_8.3).

Konec koncev Excel uporablja številne formule, ki jih je mogoče uporabiti v delovnem zvezku programa za pomoč pri izračunu predvidenih vrednosti. Excel podpira več različnih funkcij, ki omogočajo praktično uporabo programa (preglednica 8.6). Njihovo razumevanje je ključnega pomena za to, da boste Excel kar najbolj izkoristili.

Pomanjkljivosti programa Excel vključujejo potrebo po ročni sinhronizaciji podatkov in ročnem posodabljanju podatkov. Druga pogosta težava je možnost napak zaradi nepravilno izvedenega uvoza podatkov ali zaradi prekinitve formule. Ker je Excel program za ročni vnos podatkov, podatki, ki se uporabljajo za napovedovanje, niso podatki v realnem času.



8.9 Umetna inteligenca pri napovedovanju

Podatki o dobavni verigi so večdimenzionalni in nastajajo na več točkah verige, za različne namene, v velikih količinah (zaradi številnih dobaviteljev, izdelkov in strank) in z veliko hitrostjo (zaradi številnih transakcij, ki se nenehno obdelujejo v omrežjih oskrbovalne verige). Zaradi te kompleksnosti in večdimenzionalnosti oskrbovalnih verig se je treba od konvencionalnih (statističnih) pristopov k napovedovanju povpraševanja, ki temeljijo na ugotavljanju statistično povprečnih trendov (ki jih označujejo atributi povprečja in variance) (Michna, i in., 2020), preusmeriti k inteligentnim napovedim, ki se lahko učijo iz preteklih podatkov in se inteligentno razvijajo, da bi se prilagodile predvidevanju nenehno spreminjajočega se povpraševanja v oskrbovalnih verigah.

Odgovor na nove potrebe in izzive je anticipativna logistika, ki podpira procese, kot je napovedovanje povpraševanja. Njeno bistvo je možnost uporabe umetne inteligence (AI). Gre za kombinacijo sodobnih tehnologij, kot so Big Data (BD), strojno učenje (ML) in umetna inteligenca (Sczaniecka in Smarzyńska, 2018). Tehnološki napredek v zadnjih letih je privedel do vse pogostejšega ustvarjanja in shranjevanja velikih količin podatkov. Ti podatki se sčasoma zajemajo na različnih točkah (npr. v različnih členih oskrbovalne verige) in shranjujejo na različnih mestih. Zato jih je treba učinkovito obdelati, da bi iz njih pridobili uporabno in dragoceno znanje (Galicia et al., 2019).

Veliki podatki se nanašajo na dinamične, obsežne, hitre in raznolike podatkovne nize, ki presegajo zmožnosti obdelave tradicionalnih pristopov za upravljanje podatkov (Chen et al, 2014). Veliki podatki lahko zagotovijo veliko edinstvenih vpogledov v stvari, kot so tržni trendi, nakupni vzorci strank in cikli vzdrževanja, ter načine za zmanjšanje stroškov in sprejemanje bolj usmerjenih poslovnih odločitev (Wang et al, 2016). Raziskave kažejo, da lahko analiza velikih količin podatkov (Big Data Analytics - BDA) zagotovi način za pridobivanje natančnejših napovedi, ki bolje odražajo potrebe strank, olajša ocenjevanje uspešnosti oskrbovalne verige, izboljša učinkovitost oskrbovalne verige, skrajša odzivne čase in podpira oceno tveganja v dobavni verigi (Awwad et al., 2018)).



Analitika velikih količin podatkov (Big Data Analytics - BDA) na področju upravljanja oskrbovalne verige (Supply Chain Management - SCM) pridobiva vse večjo pozornost (Seyedan & Mafakheri, 2020). Analiza podatkov o oskrbovalni verigi je postala zapletena naloga zaradi (Awwad et al., 2018)

- vse večje število subjektov SC,
- vedno več različnih konfiguracij SC glede na homogenost ali heterogenost izdelkov,
- soodvisnosti med temi subjekti,
- negotovost glede dinamičnega obnašanja teh sestavnih delov,
- pomanjkanje informacij o subjektih oskrbovalne verige,
- mrežno povezanih proizvodnih enot zaradi njihovega vse večjega usklajevanja in sodelovanja, da bi dosegli visoko raven prilagajanja in prilagajanja različnim potrebam strank,
- vse večja uporaba praks digitalizacije oskrbovalne verige (in uporaba tehnologije Blockchain) za sledenje dejavnostim oskrbovalne verige.

Metode umetne inteligence se v svetu zelo intenzivno razvijajo, tako teoretično kot aplikativno (Trojanowska in Malopolski, 2004). Med metodami umetne inteligence se za napovedovanje uporabljajo umetne nevronske mreže. Nevronske mreže imajo številne lastnosti, ki so uporabne za analizo in napovedovanje časovnih vrst. Njihova učinkovitost je povezana predvsem z ugaševanjem sprejete strukture na podlagi podatkov. Postopek izgradnje nevronskega modela vključuje raziskovanje razpoložljivih podatkovnih nizov in omogoča samodejno ocenjevanje modela. Dodatna prednost nevronske mreže je njihovo enostavno prilagajanje spreminjajočim se tržnim razmeram (Ciežak et al., (2006).

V nasprotju s tradicionalnimi metodami, ki temeljijo na modelih, so umetne nevronske mreže (ANN) samoprilagodljive metode, ki temeljijo na podatkih. Učijo se iz primerov in zajemajo subtilne funkcionalne odnose med podatki, tudi če osnovni odnosi niso znani ali jih je težko opisati. Umetne nevronske mreže lahko posplošujejo (Hornik et al., 1989). Po preučitvi predstavljenih podatkov lahko sklepajo o nevidnem delu populacije, tudi če vzorčni podatki



vsebujejo šumeče informacije. Imajo tudi splošnejše in prožnejše funkcionalne oblike kot tradicionalne statistične metode (Zhang et al., 1998).

VPRAŠANJA

1. Katere so omejitve uporabe metod časovnih vrst pri napovedovanju povpraševanja?
2. Katere so glavne komponente časovne vrste in kakšen je njihov pomen v procesu napovedovanja?
3. Katere so različne strategije za ravnanje z odstopajočimi podatki?

LITERATURA

Adhikari R., Agrawal R.K. (2014) A combination of artificial neural network and random walk models for financial time series forecasting. *Neural Comput & Applic* 24, 1441-1449.

Ali M.M., Boylan J.E. & Syntetos A.A. (2012). Forecast errors and inventory performance under forecast information sharing, *International Journal of Forecasting*, 28(4), 830-841.

Altendorfer K. & Felberbauer T. (2023) Forecast and production order accuracy for stochastic forecast updates with demand shifting and forecast bias correction. *Simulation Modelling Practice and Theory*, 125, 102740.

Awwad, M., Kulkarni, P., Bapna, R. & Marathe, A. (2018). Big data analytics in supply chain: a literature review. *Proceedings of the International Conference on Industrial Engineering and Operations Management Washington DC, USA, Vol. 2018*, pp. 418-25.

Carreno J.J. & Madinaveitia J. (1990) A modification of time series forecasting methods for handling announced price increases. *International Journal of Forecasting*, 6(4), 479-484.

Chatfield Ch., Koehler A.B., Ord J.K. & Snyder R.D. (2001) A New Look at Models For Exponential Smoothing, *Journal of the Royal Statistical Society: Series D (The Statistician)*, 50(2), 147-159.

Chatfield, C. (2001). *Time Series Forecasting*, Chapman & Hall/CRC, Floryda: Boca Raton



- Chen, M., Mao, S., Zhang, Y. & Leung, V.C. (2014). Big data: related technologies, challenges and future prospects (Vol. 100). Heidelberg: Springer
- Cieślak, M. (Ed.) (2005): Prognozowanie gospodarcze. Metody i zastosowania. Wyd. Naukowe PWN. Warszawa
- De Gooijer J.G. & Hyndman R.J. (2006) 25 years of time series forecasting, International Journal of Forecasting, 22(3), 443-473.
- Dittmann, P. (2003). Prognozowanie w przedsiębiorstwie. Kraków: Oficyna Ekonomiczna
- Gajda, J.B. (2001). Prognozowanie i symulacja a decyzje gospodarcze, Warszawa: Wydawnictwo C.H. Beck
- Galicia A, Talavera-Llames R., Troncoso A., Koprinska I. & Martínez-Álvarez F. (2019). Multi-step forecasting for big data time series based on ensemble learning, Knowledge-Based Systems, 163, pp. 830-841.
- Grzelak M. (2019) Zastosowanie modelu ARIMA do prognozowania wielkości produkcji w przedsiębiorstwie, Systemy Logistyczne Wojsk, 50.
- Grzybowska, K. (2009). Gospodarka Zapasami i Magazynem, cz. 1, Difin.
- Güllü R. (1996) On the value of information in dynamic production/inventory problems under forecast evolution. Naval Research Logistics (NRL), 43(2), 289-303.
- Hopp W.J. & Spearman M.L. (1999). Factory physics. 2nd. edn. McGraw-Hill / Irwin: Boston
- Hornik K., Stinchcombe M. & White H. (1989) Multilayer feedforward networks are universal approximators. Neural networks, 2(5), 359-366.
- Hyndman R.J. & Koehler A.B. (2006) Another look at measures of forecast accuracy. International journal of forecasting, 22(4), 679-688.
- Kucharski, A. (2013). Prognozowanie szeregów czasowych metodami ewolucyjnymi. Łódź: Wydawnictwo Uniwersytetu Łódzkiego
- Malska W. & Wachta H. (2015) Wykorzystanie modelu ARIMA do analizy szeregu czasowego. Advances in IT and Electrical Engineering, 23(34-3), 23-30.



- Michna Z., Disney S.M., Nielsen P. (2020). The impact of stochastic lead times on the bullwhip effect under correlated demand and moving average forecasts, *Omega*, 93, 102033.
- Rosas A.L. & Guerrero V.M. (1994) Restricted forecasts using exponential smoothing techniques. *International Journal of Forecasting*, 10(4), 515-527.
- Sczaniecka, E. & Smarzyńska, N. (2018). Logistyka wyprzedzająca, czyli innowacyjne podejście do branży e-commerce. *Journal of TransLogistics*, 4(1), pp. 119-128
- Seyedan M. & Mafakheri F. (2020) Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. *J Big Data* 7(53).
- Schaffer A.L., Dobbins T.A. & Pearson S.A. (2021) Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. *BMC Med Res Methodol* 21(58).
- Sheldon, P.J. (1993). Forecasting tourism: expenditure versus arrivals, *Journal of Travel Research*, 32, 13-20
- Sobczyk M. (2006) *Statystyka, aspekty praktyczne i teoretyczne*. Lublin: Wydaw. UMCS.
- Tan T., Güllü R. & Erkip N. (2009) Using imperfect advance demand information in ordering and rationing decisions, *International Journal of Production Economics*, 121(2), 665-677.
- Trojanowska M. & Malopolski J. (2004) Zastosowanie metod sztucznej inteligencji do prognozowania miesięcznej sprzedaży energii elektrycznej na wsi. *Acta Scientiarum Polonorum. Technica Agraria*, 3(1-2).
- Wang G., Gunasekaran A., Ngai E.W.T., Papadopoulos T. (2016). Big data analytics in logistics and supply chain management: Certain investigations for research and applications. *International Journal of Production Economics*, 176, pp. 98-110.
- Wojciechowski, A. & Wojciechowska, N. (2015). Zastosowanie klasycznych metod prognozowania popytu w logistyce dużych sieci handlowych. *Zeszyty Naukowe Uniwersytetu Szczecińskiego*, 41, 545-554
- Wolny, M. & Kmiecik, M. (2020). Forecasting demand for products in distribution networks using R software. *Zeszyty Naukowe. Organizacja i Zarządzanie/Politechnika Śląska*, 107-116



Zeiml S., Altendorfer K., Felberbauer T. & Nurgazina J. (2019) Simulation based forecast data generation and evaluation of forecast error measures. In 2019 Winter Simulation Conference (WSC) (2119-2130). IEEE.

Zhang G., Patuwo B.E. & Hu M.H. (1998) Forecasting with artificial neural networks:: The state of the art, International Journal of Forecasting, 14(1), 35-62.

(www_8.1) <https://online.stat.psu.edu/stat501/> (dostep: 08.02.2024)

(www_8.2) <https://machinelearningmastery.com/exponential-smoothing-for-time-series-forecasting-in-python/> (dostep: 08.02.2024)

(www_8.3) <https://www.inventory-planner.com/forecasting-in-excel/> (dostep: 08.02.2024)

(www_8.4) [IPM Insights Metrics \(oracle.com\)](https://ipm.oracle.com/) (dostep: 05.02.2024)