



9. Napovedovanje povpraševanja, vizualizacija in inženiring časovnih vrst v oskrbovalnih verigah

Kaj je napovedovanje povpraševanja? Kako lahko učinkovito vizualiziramo in sklepamo o podatkih o strankah? Kako izvesti inženiring značilnosti časovnih vrst?

Na ta in podobna vprašanja bomo poskušali odgovoriti v naslednjem poglavju.

9.1 Kaj je povpraševanje kupcev in napovedovanje povpraševanja?

Povpraševanje končnega kupca spravi v tek celotno oskrbovalno verigo zainteresiranih strani (Syntetos et al., 2016). V skladu s tem je povpraševanje strank ključna sestavina za načrtovanje vseh logističnih procesov v oskrbovalni verigi, zato je določanje ravni povpraševanja strank zelo zanimivo za upravitelje oskrbovalne verige. Poleg tega je napovedovanje povpraševanja bistvena dejavnost za načrtovanje in razporeditev logističnih dejavnosti v opazovani oskrbovalni verigi (Mircetic et al., 2017). Natančni modeli napovedovanja povpraševanja neposredno vplivajo na zmanjšanje logističnih stroškov, saj zagotavljajo oceno povpraševanja strank (Mircetic et al., 2016). Napovedovanje v oskrbovalnih verigah presega operativno nalogo ekstrapolacije zahtev po povpraševanju na eni stopnji. Vključuje kompleksna vprašanja, kot sta usklajevanje oskrbovalne verige in izmenjava informacij med več deležniki (Syntetos et al., 2016).


Povpraševanje kupcev in spremljajoče napovedi so za podjetja ključnega pomena, saj zagotavljajo osnovne podatke za načrtovanje in nadzor vseh funkcionalnih področij, vključno z logistiko, trženjem, proizvodnjo itd. (Mircetic, 2018). Če bi bilo končno povpraševanje potrošnikov konstantno ali z gotovostjo znano precej vnaprej, potem bi bilo delovanje oskrbovalne verige preprosto (za nazaj) za načrtovati. Vendar pa povpraševanje ni znano, zato ga je treba napovedati. Prav zaradi negotovosti, povezane s tem povpraševanjem, je upravljanje oskrbne verige zelo zahtevno (Syntetos et al., 2016). Na učinkovitost napovedovanja povpraševanja vplivajo negotovosti, ki so neločljivo povezane s časovnimi vrstami povpraševanja, ki jih imajo oskrbovalne verige (Rostami-Tabar, 2013). Posledično sta obravnavata in razumevanje teh negotovosti velik izziv za menedžerje pri usklajevanju in načrtovanju dejavnosti v oskrbovalnih verigah (Mircetic, 2018).



Negotovost povpraševanja je eden največjih izzivov za sodobne oskrbovalne verige. Nedavna pandemija COVID-19 je to vprašanje še dodatno poudarila, saj je povzročila obsežne motnje, ki so otežile načrtovanje in nadzor oskrbovalne verige (Nikolopoulos et al., 2020). Napovedovanje povpraševanja v oskrbovalnih verigah pogosto vključuje napovedovanje povpraševanja po številnih postavkah. Napovedovalci v oskrbovalnih verigah običajno ekstrapolirajo podatke časovnih vrst za vsako enoto za vzdrževanje zalog posebej. Trgovec na drobno lahko na primer uporabi podatke s prodajnih mest za izdelavo napovedi na ravni posamezne trgovine (Mircetic et al., 2022).

9.2 Koraki napovedovanja povpraševanja v oskrbovalnih verigah?

V skladu z zgoraj navedenimi trditvami in ugotovitvami glede pomena povpraševanja in napovedovanja povpraševanja za oskrbovalne verige je pri oblikovanju napovedi v oskrbovalnih verigah pomembno upoštevati posebne korake (slika 9.1).



Slika 9.1 Osnovni koraki za pravilno izvajanje napovedi v podjetju (Makridakis et al., 1998; Makridakis et al., 1983).

Vsak od korakov na sliki 9.1 ima svoje prednosti in prispeva k oblikovanju zanesljivih in uporabnih (poslovno usmerjenih) napovedi. V skladu s tem je opredelitev problema pogosto najtežji del



napovedovanja in zahteva razumevanje, kako se bodo napovedi uporabljale, ter vloge funkcij napovedovanja v opazovanem podjetju. Napovedovalec mora porabiti precej časa za komunikacijo z vsemi, ki sodelujejo pri zbiranju podatkov, vzdrževanju podatkovne zbirke in uporabi napovedi za načrtovanje prihodnosti. Eden od glavnih oteževalnih dejavnikov pri opredelitvi problema je, kako se bo končna napoved uporabljala pri vsakodnevnih logističnih dejavnostih (kakšna platforma, zasnova programske opreme, uporabniški vmesnik itd.)

Za korak zbiranja informacij sta vedno potrebni vsaj dve vrsti informacij: statistični podatki in strokovno znanje ljudi, ki zbirajo podatke in uporabljajo napovedi. V praksi je pogosto težko pridobiti zgodovinske podatke za oblikovanje dobrega statističnega modela. Prav tako obstaja veliko nerazumevanje, kaj so podatki o povpraševanju in kaj se lahko uporabi kot njihov približek. Obstaja slaba praksa uporabe podatkov o pošiljkah in dobavah kot približka podatkov o povpraševanju, kar samo poslabša postopek odločanja na podlagi napovedi, izdelanih na podlagi enostavne vrste podatkov. Podatki o prodaji so edini zanesljivi približek podatkov o povpraševanju (Syntetos et al., 2016), čeprav ta poenostavitev ni popolna, zlasti v oskrbovalnih verigah z veliko primeri izpada zalog.

V koraku predhodne analize podatkov je priporočljivo, da analizo podatkov vedno začnete z grafičnimi prikazi in tako odgovorite na naslednja vprašanja. Ali obstajajo dosledni vzorci? Ali obstaja pomemben trend? Ali je opazna sezonskost? Ali obstajajo dokazi o poslovnih ciklih? Kako močne so povezave med spremenljivkami? To so vprašanja, na katera lahko odgovori preprosta grafična ponazoritev, in omogočijo nadaljnjo analizo podatkov z zožitvijo fokusa, katere modele uporabiti za odkrite značilnosti povpraševanja. Običajno lahko tako preprost model premaga bolj zapletene in kompleksne modele (Rostami-Tabar in Mircetic, 2023).


Izbira in oblikovanje modelov napovedovanja je najpomembnejši korak pri oblikovanju modela napovedovanja. Kateri model bomo uporabili, je odvisno od več dejavnikov, med katerimi sta najpomembnejša razpoložljivost preteklih podatkov in korelacija med odvisnimi in neodvisnimi spremenljivkami. Običajno se pri izbiri modela primerja dva ali tri možne modele. Vsak model je umetna konstrukcija, ki temelji na nizu predpostavk (eksplicitnih in implicitnih) in običajno vključuje enega ali več parametrov, ki jih je treba ustvariti z uporabo znanih preteklih podatkov. V naslednjem poglavju bo predstavljen postopek razvoja in uporabe modela ARIMA, ki je eden najboljših in najbolj priljubljenih modelov.

Vrednotenje modela napovedi je korak, ki meri uporabnost ustvarjenega modela. Po izbiri modela napovedovanja in oceni njegovih parametrov se model uporabi za izdelavo napovedi. Natančnost

modela se oceni z uporabo različnih statističnih podatkov, pomembno pa je tudi, da se napovedi preverijo z merami poslovnih implikacij (tj. merami uporabnosti).


9.3 Napovedovanje povpraševanja v živilski industriji

Podatki o porabi vseh izdelkov opazovanega podjetja iz živilske industrije so predstavljeni kot tedensko povpraševanje od januarja 2012 do decembra 2014 (slika 9.2). Os x predstavlja čas, medtem ko so vrednosti povpraševanja predstavljene na osi y. Ti podatki so prikazani v tedenskih intervalih, saj to ustreza obdobju, v katerem poteka dobava na končna prodajna mesta. Posledično se vodstvo podjetja osredotoča na napovedovanje tedenske porabe na trgu.



Slika 9.2 Podatki o povpraševanju za opazovano živilsko podjetje.

Slika 9.2 prikazuje več pomembnih značilnosti in lastnosti danih podatkov. Prvič, podatki imajo izrazito sezonski značaj, saj je največja prodaja sredi leta (v poletnih mesecih). Drugič, posezonski graf (spodnji graf na sliki 9.2) prikazuje pomembno spremembo vzorca trenda upadanja v letu 2014. To sta zelo pomembni značilnosti za izbiro pravega modela napovedovanja in za višje vodstvene delavce v podjetju, saj razkrivata znaten upad porabe in izgubo trga. Za nadaljnjo raziskavo opaženih značilnosti je uporabljena metodologija razgradnje sezonskega trenda (STL) (slika 9.3). Dekompozicija STL razdeli izvirne vzorce povpraševanja na tri komponente: sezonsko komponento, komponento trenda in komponento preostanka.



Slika 9.3 Razčlenitev STL podatkov o povpraševanju.

STL je pokazala, da imajo opazovane časovne vrste aditivno naravo, kar pomeni, da se nihanja okoli krivulje trenda in cikla s časom ne povečujejo bistveno. Zato za neobdelane časovne vrste ni bilo treba uporabiti Box-Coxove transformacije. Dekompozicija je razkrila, da v opazovanih časovnih vrstah prevladuje sezonska komponenta, ki kaže velika nihanja znotraj enega leta. Glede na omejeno število let opazovanj je težko opredeliti poslovni cikel. Dekompozicija je tudi pokazala, da je trend v seriji minimalen, z upadajočim vzorcem od sredine leta 2013 naprej.

Te ugotovljene značilnosti so predstavljale pomemben vhodni podatek v postopku oblikovanja ustreznega modela napovedovanja. V ta namen je bil izbran model S-ARIMA (Seasonal Autoregressive Integrated Moving Average). Model S-ARIMA je zelo učinkovit za napovedovanje, saj združuje tako avtoregresijsko komponento kot komponento drsečega povprečja ter diferenciranje, da so podatki stacionarni. Ta model je še posebej dober pri zajemanju in modeliranju sezonskih vzorcev v podatkih časovnih vrst, zato je idealen za panoge s cikličnimi vzorci povpraševanja, kot je živilska industrija. Poleg tega zmožnost modela S-ARIMA, da obravnava kompleksne sezonske strukture in trende, omogoča natančnejše in zanesljivejše napovedi, ki so ključne za učinkovito načrtovanje oskrbovalne verige in upravljanje zalog. Strukturna oblika S-ARIMA je predstavljena v enačbi (1).

$$\Phi(B^m)\phi(B)(1-B^m)^D(1-B)^d y_t = c + \Theta(B^m)\theta(B)\varepsilon_t, (1)$$



kjer sta $\Phi(z)$ in $\Theta(z)$ polinoma reda P oziroma Q , od katerih vsak nima korenov znotraj enotskega kroga. B je operator povratnega premika, ki se uporablja za opis procesa diferenciranja, tj. $By = y_{t-1}$. Če je $c \neq 0$, je v napovedni funkciji impliciran polinom reda $d+D$. Ker je model S-ARIMA zelo parametriziran, je ključno vprašanje pri uporabi modela S-ARIMA izbira ustreznega reda modela, kar vključuje določitev vrednosti p, q, P, Q, D in d . Če sta d in D znana, lahko rede p, q, P in Q izberemo z uporabo informacijskega merila, kot je Akaikejev informacijski kriterij (AIC) ali Bayesov informacijski kriterij (BIC). Formuli za AIC in BIC sta naslednji:

$$AIC = -2\log(L) + 2(k);$$

$$BIC = N \log\left(\frac{SSE}{N}\right) + (k+2)\log(N) \quad (2)$$

kjer je $k=p+q+P+Q+1$, če je vključen konstantni člen, in 0 v nasprotnem primeru, L je maksimizirana verjetnost modela, prilagojenega diferenciranim podatkom, SSE je vsota kvadratnih napak, N je število opazovanj, uporabljenih za oceno, in k je število napovednikov v modelu.

Hyndman in Khandakar (2007) sta za določitev optimalnega nabora parametrov predlagala Canova-Hansenov in KPSS test korena enote v naslednjih korakih:

- Uporabite test Canova-Hansen za določitev D v okviru ARIMA.
- Izberite d z uporabo zaporednega KPSS testa enotnega korena na sezonsko diferenciranih podatkih (če je $D = 1$) ali na izvirnih podatkih (če je $D = 0$).
- Izberite optimalne vrednosti p, q, P in Q z zmanjšanjem AIC.

9.4 Razvoj modela napovedovanja S-ARIMA

Razvoj modela napovedovanja S-ARIMA

V skladu z zgoraj navedenim postopkom je bilo preizkušenih več nastavitev parametrov, njihova učinkovitost pa je predstavljena v preglednici 9.1. Za preizkušanje učinkovitosti različnih modelov je uporabljenih več meril: povprečna absolutna odstotna napaka (MAPE), povprečna kvadratna napaka (RMSE), povprečna absolutna skalirana napaka (MASE), AIC in BIC (enačbi 2 in 3).

$$MAPE = \frac{1}{N} \sum_{i=1}^N |e_i|;$$



$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2};$$

$$MASE = \frac{1}{N} \sum_{j=1}^N |q_j|, \quad (3)$$

kjer so e_t rezidualne vrednosti in $q_j = \frac{e_j}{\frac{1}{T-m} \sum_{t=m+1}^T |y_t - y_{t-m}|}$

Najbolj priljubljeni meri za vodje v oskrbovalnih verigah sta RMSE in MAPE, saj zagotavljata "občutek", kako dobro deluje model v realnih številkah (RMSE) in odstotkih (MAPE).

Preglednica 9.1 Uspešnost modelov S-ARIMA z različnimi nastavitvami parametrov.

Modeli ^a	RMSE	MAPE	MASE	AIC	BIC
S-ARIMA (5,0,1)(1,0,0) ₅₂ ^b	1023	14.18 %	0.60 %	86.62	110.50
S-ARIMA (4,0,0)(1,0,0) ₅₂ ^c	1041	14.53 %	0.62 %	86.73	105.31
S-ARIMA (4,0,0)(0,1,1) ₅₂ ^d	1882	22.12 %	1.05 %	41.74	53.560
S-ARIMA (4,0,1)(1,0,0) ₅₂ ^e	1050	14.18 %	0.60 %	88.23	109.47
S-ARIMA (0,0,1)(0,1,0) ₅₂ ^f	1797	21.42 %	1.02 %	36.52	40.460

^a Napake modela se izračunajo na testnem nizu podatkov.

^b Podrobnosti o modelu S-ARIMA (5,0,1)(1,0,0)₅₂ so navedene v nadaljevanju.

$$c(1 - 0.39B + 0.06B + 0.04B - 0.46B)(1 - 0.65B^{52})y_t = 8.52$$

$$d(1 - 0.29B + 0.19B - 0.05B - 0.19B)(1 - B^{52})y_t = (1 + 0.12B^{52})e_t$$

$$e(1 - 0.29B + 0.01B + 0.05B - 0.48B)(1 - 0.65B^{52})y_t = 8.52 + (1 + 0.13B)e_t$$

$$f(1 - B^{52})y_t = (1 + 0.3B)e_t$$

Iz preglednice 9.1 je razvidno, da je model S-ARIMA (5,0,1)(1,0,0)₅₂ presegel konkurenčne modele, saj je dosegel najnižje napake RMSE, MAPE in MASE. Oblika modela S-ARIMA (5,0,1)(1,0,0)₅₂ je predstavljena v enačbi (4), kjer je $\phi_1 = -0.5421$, $\phi_2 = 0.2962$, $\phi_3 = -0.099$, $\phi_4 = 0.3974$, $\phi_5 = 0.4994$, $\Phi_1 = 0.9558$, $c = 8.523$ in $\Theta_1 = 0.6345$.




$$(1 - \phi_1 B - \phi_2 B - \phi_3 B - \phi_4 B - \phi_5 B)(1 - \Phi_1 B^{52})y_t = c + (1 + \theta_1 B)e_t, \quad (4)$$

Podobno uspešnost sta imela modela S-ARIMA (4,0,0)(1,0,0)₅₂ in S-ARIMA (4,0,1)(1,0,0)₅₂. Pri izvajanju napovedi model S-ARIMA (5,0,1)(1,0,0)₅₂ v povprečju povzroči napako 1023 izdelkov, kar pomeni 14,18 %. Ti rezultati poudarjajo pomen skrbne izbire izrazov, ki jih je treba vključiti v model S-ARIMA, saj med uspešnostjo modela z različnimi parametri ni bistvenih razlik. Ocena je pokazala, da so bili modeli, ki so vključevali avtoregresijske (p , P) in drseče povprečne komponente (q , Q), učinkovitejši pri napovedovanju porabe pijač kot modeli, ki so vključevali sezonsko ali nesezonsko diferenciranje. Poleg tega je primerjalni pregled razkril nekaj nepričakovanih ugotovitev, na primer, da so modeli, ki vključujejo sezonsko diferenciranje S-ARIMA (4,0,0)(0,1,1)₅₂ in S-ARIMA (0,0,1)(0,1,0)₅₂, slabši od preprostega povprečnega naivnega modela napovedi, kar se kaže v tem, da so njihove napake MASE presegle ena.

9.5 Napovedi prihodnjega povpraševanja

Slika 9.4 prikazuje uspešnost metode S-ARIMA (5,0,1)(1,0,0)₅₂. V zgornji levi plošči so podatki o začetnem povpraševanju, ki so obarvani zaradi lažjega razlikovanja različnih tržnih let. Zgornja desna plošča je vhodni podatek za S-ARIMA (5,0,1)(1,0,0)₅₂, ki predstavlja učne podatke, na podlagi katerih se parametri v S-ARIMA določijo po postopku, opisanem v podpoglavju 9.3. To je zelo pomembno, da razumemo, kako težko je delo modela za napovedovanje, saj ima v tem primeru kot vhodne podatke dve leti, napovedati pa mora prihodnje povpraševanje za eno leto vnaprej! To je precej pogost scenarij v oskrbovalnih verigah in logistiki, saj velja nenapisano pravilo, da podjetja hranijo zgodovino svojih podatkov tri leta, nato pa podatke zavržejo.



Slika 9.4 Usposabljanje, testiranje in napovedano povpraševanje modela S-ARIMA (5,0,1)(1,0,0)_{s2}.

Spodnja leva plošča na sliki 9.4 prikazuje uspešnost opazovanega modela. Uspešnost modela je že predstavljena v preglednici 9.1 z različnimi statističnimi merami, vendar je za upravljavce običajno težko dobiti občutek, kako dober ali slab je model. V ta namen je na plošči grafično prikazana uspešnost modela. Lahko trdimo, da model precej dobro sledi testnim podatkom in v večini obdobjev kaže odlično uspešnost. Za izdelavo prihodnjih napovedi je bil model S-ARIMA (5,0,1)(1,0,0)_{s2} ponovno oblikovan tako, da so bili podatkom iz usposabljanja dodani podatki iz leta 2014. Po tem modelu so bile izdelane 52-tedenske napovedi za leto 2015. Napovedi za leto 2015 so predstavljene v spodnji levi plošči. Napovedim sta priložena 80- in 95-odstotna napovedna intervala, ki kažeta na morebitno razpršenost prihodnjih napovedi od povprečnih napovedanih vrednosti. Model napoveduje nadaljnje zmanjševanje povpraševanja, ki se je začelo leta 2014. Vzroki za ta upad bi lahko bili različni, zato bi jih morali menedžerji na strateški ravni podjetja dodatno raziskati.

Literatura poglavje 9

- Hyndman, R., & Khandakar, Y. (2007). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3). <http://www.jstatsoft.org/v27/i03>
- Makridakis, S., Wheelwright, S., & Hyndman, R. J. (1998). *Forecasting: Methods and applications* (3rd ed.). New York: John Wiley & Sons.
- Makridakis, S., Wheelwright, S., & McGee, V. (1983). *Forecasting: Methods and applications* (2nd ed.). New York: John Wiley & Sons.



- Mircetic, D. (2018). *Boosting the performance of top-down methodology for forecasting in supply chains via a new approach for determining disaggregating proportions*. University of Novi Sad.
- Mircetic, D., Nikolicic, S., Maslaric, M., Ralevic, N., & Debelic, B. (2016). Development of S-ARIMA model for forecasting demand in a beverage supply chain. *Open Engineering*, 6(1).
- Mircetic, D., Rostami-Tabar, B., Nikolicic, S., & Maslaric, M. (2022). Forecasting hierarchical time series in supply chains: An empirical investigation. *International Journal of Production Research*, 60(8), 2514-2533.
- Mircetic, D., Nikolicic, S., Stojanovic, D., & Maslaric, M. (2017). Modified top-down approach for hierarchical forecasting in a beverage supply chain. *Transportation Research Procedia*, 22, 193–202.
- Nikolopoulos, K., Punia, S., Schäfers, A., Tsinopoulos, C., & Vasilakis, C. (2020). Forecasting and planning during a pandemic: COVID-19 growth rates, supply chain disruptions, and governmental decisions. *European Journal of Operational Research*, 290(1), 99–115.
- Rostami-Tabar, B. (2013). *ARIMA demand forecasting by aggregation*. Université Sciences et Technologies Bordeaux I.
- Rostami-Tabar, B., & Mircetic, D. (2023). Exploring the association between time series features and forecasting by temporal aggregation using machine learning. *Neurocomputing*, 548, 126376.
- Syntetos, A. A., Babai, Z., Boylan, J. E., Kolassa, S., & Nikolopoulos, K. (2016). Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*, 252(1), 1-26.