



9. Predviđanje potražnje, vizualizacija i inženjering značajki vremenskih serija u opskrbnim lancima

Što je predviđanje potražnje? Kako možemo učinkovito vizualizirati podatke o kupcima i donijeti zaključke o njima? Kako provesti inženjering značajki vremenskih serija?

Na ova i slična pitanja pokušat ćemo dati odgovore u sljedećem poglavlju.

9.1 Što je potražnja kupaca i predviđanje potražnje?

Zahtjev krajnjeg kupca pokreće cijeli opskrbni lanac (Syntetos i dr., 2016). Sukladno tome, potražnja kupaca je ključna komponenta za planiranje svih logističkih procesa u opskrbnom lancu pa je određivanje razine potražnje kupaca od velikog interesa za menadžere opskrbnog lanca. Komplementarno, predviđanje potražnje bitna je aktivnost za planiranje i raspoređivanje logističkih aktivnosti unutar promatranog opskrbnog lanca (Mircetic i dr., 2017). Precizni modeli predviđanja potražnje izravno utječu na smanjenje logističkih troškova budući da daju procjenu potražnje kupaca (Mircetic i dr., 2016). Predviđanje u opskrbnim lancima nadilazi operativni zadatak ekstrapolacije zahtjeva potražnje na jednom nivou. Uključuje složena pitanja kao što su koordinacija opskrbnog lanca i dijeljenje informacija između višestrukih dionika (Syntetos i dr., 2016).

Potražnja kupaca i popratne prognoze od vitalnog su značaja za opskrbne lance, budući da pružaju osnovne ulazne podatke za planiranje i kontrolu svih funkcionalnih područja, uključujući logistiku, marketing, proizvodnju itd. (Mircetic, 2018). Kad bi potražnja krajnjih kupaca bila stalna, ili poznata sa sigurnošću puno unaprijed, tada bi rad opskrbnog lanca bio izravna (unatrag) vježba planiranja. Međutim, potražnja nije poznata i stoga je treba predvidjeti. Nesigurnost povezana s ovom potražnjom čini upravljanje opskrbnim lancem vrlo teškim (Syntetos i dr., 2016). Na učinkovitost predviđanja potražnje utječu inherentne neizvjesnosti u vremenskoj seriji potražnje koje opskrbni lanci imaju (Rostami-Tabar, 2013.).




Posljedično, rješavanje i razumijevanje ovih neizvjesnosti veliki je izazov za menadžere prilikom koordinacije i planiranja operacija unutar opskrbnih lanaca (Mircetic, 2018).

Nesigurnost potražnje jedan je od najznačajnijih izazova za suvremene opskrbe lance. Nedavna pandemija COVID-19 dodatno je naglasila ovaj problem, uzrokujući široko rasprostranjene poremećaje koji su komplicirali planiranje i kontrolu opskrbnog lanca (Nikolopoulos i dr., 2020). Predviđanje potražnje u opskrbnim lancima često uključuje predviđanje potražnje za brojnim artiklima. Prognostičari u opskrbnim lancima obično ekstrapoliraju vremenske serije podataka za svaku jedinicu za čuvanje zaliha (engl. *stock-keeping unit* – SKU) pojedinačno. Na primjer, trgovac na malo može koristiti podatke o prodajnom mjestu za generiranje predviđanja na razini pojedinačne prodavaonice (Mircetic i dr., 2022).

9.2 Koraci predviđanja potražnje u opskrbnom lancu?

U skladu s gore navedenim izjavama i zaključcima, u pogledu važnosti potražnje i predviđanja potražnje za opskrbe lance, važno je slijediti specifične korake pri izradi prognoza u opskrbnim lancima (slika 9.1).



Slika 4.54Osnovni koraci za pravilnu implementaciju predviđanja unutar poduzeća (Makridakis i dr., 1998; Makridakis i dr., 1983).



Svaki od koraka na slici 9.1 ima svoje prednosti i doprinos stvaranju pouzdanih i korisnih (poslovno orijentiranih) prognoza. Sukladno tome, definiranje problema često je najteži dio predviđanja i zahtijeva razumijevanje načina na koji će se predviđanja koristiti, kao i uloge funkcija predviđanja unutar promatranog poduzeća. Prognostičar bi trebao potrošiti dosta vremena na komunikaciju sa svima koji su uključeni u prikupljanje podataka, održavanje baze podataka i korištenje prognoza za buduće planiranje. Jedan od glavnih otežavajućih čimbenika u definiranju problema je kako će se konačna prognoza koristiti u svakodnevnim logističkim operacijama (koja platforma, dizajn softvera, korisničko sučelje itd.).

Za korak prikupljanja informacija uvijek su potrebne najmanje dvije vrste informacija: statistički podaci i akumulirana stručnost ljudi koji prikupljaju podatke i koriste predviđanja. U praksi je često teško dobiti povijesne podatke za stvaranje dobrog statističkog modela. Također, postoji veliki nesporazum o tome što su podaci o potražnji i što se može koristiti kao njihova zamjena. Postoji loša praksa korištenja podataka o otpremi i isporuci kao zamjene za podatke o potražnji, što će samo pogoršati proces donošenja odluka na temelju predviđanja napravljenih na jednostavnoj vrsti podataka. Podaci o prodaji jedina su pouzdana zamjena za podatke o potražnji (Syntetos i dr., 2016), iako ovo pojednostavljenje nije savršeno, osobito u opskrbnim lancima s puno situacija kada nema zaliha (engl. *out-of-stock* – OOS).

Za korak preliminarne analize podataka, preporučuje se uvijek započeti analizu podataka s grafičkim prikazima kako bi se odgovorilo na sljedeća pitanja. Postoje li dosljedni obrasci? Postoji li značajan trend? Postoji li primjetna sezonalnost? Postoje li dokazi o poslovnim ciklusima? Koliko su jaki odnosi između varijabli? Ovo su pitanja na koja jednostavna grafika može dati odgovore i omogućiti daljnju analizu podataka sužavanjem fokusa koje modele primijeniti na otkrivena obilježja potražnje. Obično, jednostavni model, određen na ovaj način, može pobijediti one sofisticiranije i kompliciranije (Rostami-Tabar & Mircetic, 2023).


Odabir i izrada modela predviđanja najvažniji je korak pri izradi modela predviđanja. Koji model koristiti ovisi o nekoliko čimbenika, od kojih su najvažniji dostupnost povijesnih podataka i korelacija između zavisnih i nezavisnih varijabli. Uobičajeno je da se prilikom odabira modela uspoređuju dva ili tri potencijalna modela. Svaki je model umjetna konstrukcija temeljena na skupu pretpostavki (eksplicitnih i implicitnih) i općenito uključuje jedan ili više parametara koji se moraju izraditi korištenjem poznatih povijesnih podataka. U sljedećem poglavlju bit će

prikazan proces razvoja i primjene modela ARIMA, kao jednog od najboljih i najpopularnijih modela.

Ocjenjivanje modela predviđanja je korak kojim se mjeri upotrebljivost izrađenog modela. Nakon odabira prognostičkog modela i procjene njegovih parametara, model se koristi za izradu prognoza. Točnost modela procjenjuje se korištenjem različitih statistika, ali također je važno testirati predviđanja putem mjerila poslovnih implikacija (tj. metrike korisnosti).

9.3 Predviđanje potražnje u prehrambenoj industriji


Podaci o potrošnji za sve proizvode promatranog poduzeća u prehrambenoj industriji prikazani su kao tjedna potražnja u rasponu od siječnja 2012. do prosinca 2014. (slika 9.2). X os predstavlja vrijeme, dok su vrijednosti potražnje prikazane na y osi. Ovi podaci prikazani su u tjednim intervalima, jer to odgovara razdoblju u kojem se vrši opskrba krajnjih prodajnih mjesta. Slijedom toga, menadžment tvrtke fokusiran je na predviđanje tjedne potrošnje tržišta.



Slika 4.55 Podaci o potražnji za promatranu prehrambenu tvrtku.

Slika 9.2 pokazuje nekoliko važnih obilježja i karakteristika danih podataka. Prvo, podaci imaju snažan sezonski karakter s vršnom prodajom koja se događa sredinom godine (ljetni mjeseci). Drugo, podsezonski grafikon (donji grafikon na slici 9.2) prikazuje značajnu promjenu uzorka trenda pada u 2014.! Ovo je vrlo značajna karakteristika za odabir pravog modela predviđanja

i za menadžere u poduzeću buduću da otkriva značajan pad potrošnje i gubitak tržišta. Za daljnje istraživanje promatranih karakteristika koristi se metodologija dekompozicije sezonskog trenda (engl. *seasonal trend decomposition* - STL) (slika 9.3). STL dekompozicija dijeli izvorne obrasce potražnje na tri komponente: sezonsku, trend i ostatak.



Slika 4.56 STL dekompozicija podataka o potražnji.

STL je otkrio da promatrane vremenske serije pokazuju aditivnu prirodu, što znači da se fluktuacije oko krivulje trend-ciklus ne povećavaju značajno tijekom vremena. Kao rezultat toga, Box-Coxove transformacije nisu bile potrebne za neobrađene vremenske serije. Dekompozicija je otkrila da je sezonska komponenta dominantna u promatranom nizu, pokazujući visoke fluktuacije unutar jedne godine. S obzirom na ograničeni broj godina promatranja, teško je identificirati poslovni ciklus. Dekompozicija je također pokazala da je trend u seriji minimalan, s opadajućim uzorkom počevši od sredine 2013.

Ove identificirane karakteristike predstavljale su važan input tijekom procesa dizajna odgovarajućeg prognostičkog modela. U tu svrhu odabran je model S-ARIMA (engl. *Seasonal Autoregressive Integrated Moving Average*). Model S-ARIMA vrlo je učinkovit za predviđanje jer kombinira i autoregresivnu komponentu i komponentu pomičnog prosjeka, zajedno s razlikom kako bi podaci bili stacionarni. Ovaj je model posebno vješt u hvatanju i modeliranju sezonskih obrazaca u podacima o vremenskoj seriji, što ga čini idealnim za industrije s cikličkim obrascima potražnje, kao što je prehrambena industrija. Dodatno, sposobnost S-ARIMA-e da



se nosi sa složenim sezonskim strukturama i trendovima omogućuje preciznije i pouzdanije prognoze, koje su ključne za učinkovito planiranje opskrbnog lanca i upravljanje zalihama. S-ARIMA strukturni oblik predstavljen je u jednadžbi (1).

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

gdje su $\Phi(z)$ i $\Theta(z)$ polinomi reda P odnosno Q , od kojih svaki ne sadrži korijene unutar jedinične kružnice. B je operator pomaka unazad koji se koristi za opisivanje procesa diferenciranja, tj. $By_t = y_{t-1}$. Ako je $c \neq 0$, postoji implicirani polinom reda $d + D$ u funkciji prognoze. Budući da je S-ARIMA visoko parametrizirani model, ključno pitanje pri korištenju S-ARIMA modela je odabir odgovarajućeg redoslijeda modela, što uključuje određivanje vrijednosti p, q, P, Q, D i d . Ako su d i D poznati, poredak p, q, P i Q može se odabrati korištenjem informacijskog kriterija kao što je Akaikeov informacijski kriterij (AIC) ili Bayesov informacijski kriterij (BIC). Formule za AIC i BIC dane su prema:

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

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

gdje je $k=p+q+P+Q+1$ ako je uključen konstantni izraz i 0, inače, L je maksimizirana vjerojatnost modela prilagođenog različitim podacima, SSE je zbroj kvadrata pogrešaka, N je broj opažanja koji se koristi za procjenu, a k je broj prediktora u modelu.

Za određivanje optimalnog skupa parametara Hyndman i Khandakar (2007) predložili su Canova-Hansen i KPSS test jediničnog korijena kroz sljedeće korake:

- Upotrijebite Canova-Hansen test za određivanje D u okviru ARIMA.
- Odaberite d primjenom uzastopnog KPSS testa jediničnog korijena na sezonski diferencirane podatke (ako je $D = 1$) ili na izvorne podatke (ako je $D = 0$).
- Odaberite optimalne vrijednosti za p, q, P i Q minimiziranjem AIC-a.

9.4 Razvoj modela predviđanja S-ARIMA

Razvoj S-ARIMA prognostičkog modela

U skladu s gore navedenim postupkom ispitano je nekoliko postavki parametara, a njihova izvedba prikazana je u tablici 9.1. Za testiranje performansi različitih modela koristi se nekoliko mjera: srednja apsolutna postotna pogreška (engl. *mean absolute percentage error* - MAPE), korijen srednje kvadratne pogreške (engl. *root mean square error* - RMSE), srednja apsolutna skalirana pogreška (engl. *mean absolute scaled error* - MASE), AIC i BIC (jednadžbe 2 i 3)

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

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

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

gdje su e_i reziduali i $q_j = \frac{e_j}{\frac{1}{T-m} \sum_{t=m+1}^T |y_t - y_{t-m}|}$.

Najpopularnije mjere za menadžere u opskrbnim lancima su RMSE i MAPE jer daju "osjećaj" koliko je model dobar u realnim brojevima (RMSE) i postocima (MAPE).

Tablica 4.5 Izvedba S-ARIMA modela s različitim postavkama parametara.

Modeli ^a	RMSE	MAPE	MASE	AIC	BIC
S- ARIMA (5,0,1)(1,0,0) ₅₂ ^b	1023	14,18 %	0,60 %	86.62	110.5 0
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	53,56 0
	godine				
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	40,46 0
	godine				

^a Pogreške modela izračunavaju se na skupu testnih podataka.

^b Detalji o modelu S-ARIMA (5,0,1)(1,0,0)₅₂ navedeni su u nastavku .

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

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

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

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

Tablica 9.1 pokazuje da je model S-ARIMA (5,0,1)(1,0,0)₅₂ nadmašio konkurentne modele postižući najniže pogreške RMSE, MAPE i MASE. Oblik modela S-ARIMA (5,0,1)(1,0,0)₅₂ predstavljen je u jednadžbi (4), gdje je $\phi_1 = -0,5421$, $\phi_2 = 0,2962$, $\phi_3 = -0,099$, $\phi_4 = 0,3974$, $\phi_5 = 0,4994$, $\Phi_1 = 0,9558$, $c = 8,523$, i $\Theta_1 = 0,6345$.


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

Slična izvedba primijećena je s modelima S-ARIMA (4,0,0)(1,0,0)₅₂ i S-ARIMA (4,0,1)(1,0,0)₅₂. Prilikom izvođenja predviđanja, model S-ARIMA (5,0,1)(1,0,0)₅₂ u prosjeku proizvodi pogrešku od 1023 proizvoda, što znači 14,18 %. Ovi rezultati naglašavaju važnost pažljivog odabira uvjeta za uključivanje u S-ARIMA model budući da nema značajnih razlika između performansi modela s različitim parametrima. Procjena je pokazala da su modeli koji uključuju autoregresivne (p , P) i komponente pomičnog prosjeka (q , Q) učinkovitiji u predviđanju potrošnje pića od onih koji uključuju sezonske ili nesezonske razlike. Osim toga, usporedni pregled otkrio je neke neočekivane nalaze, kao što su modeli koji uključuju sezonsku razliku S-ARIMA (4,0,0)(0,1,1)₅₂ i S-ARIMA (0,0,1)(0,1,0)₅₂ imaju lošiju izvedbu od jednostavnog prosječnog modela naivne prognoze, što dokazuje njihova MASE pogreška veća od jedinice.

9.5 Predviđanja buduće potražnje

Slika 9.4 prikazuje izvedbu S-ARIMA (5,0,1)(1,0,0)₅₂. Gornji lijevi prikaz predstavlja početne podatke o potražnji, obojene radi lakšeg razlikovanja različitih marketinških godina. Gornji desni prikaz su ulazni podaci za S-ARIMA (5,0,1)(1,0,0)₅₂, koji predstavljaju podatke o obuci,

tj. testiranje za koje se parametri u S-ARIMA određuju prema postupku opisanom u potpoglavlju 9.3. Ovo je vrlo važno za razumijevanje koliko je težak posao modela predviđanja, budući da u ovom slučaju ima dvije godine podataka kao ulaz i treba predvidjeti buduću potražnju godinu dana unaprijed! Ovo je prilično čest scenarij u opskrbnim lancima i logistici jer postoji nepisano pravilo da tvrtke čuvaju povijest svojih podataka tri godine nakon čega odbacuju podatke.



Slika 4.57 Obuka, testiranje i predviđena potražnja S-ARIMA (5,0,1)(1,0,0) 52 modela.

Donji lijevi prikaz na slici 9.4 predstavlja performanse promatranog modela. Učinkovitost modela već je prikazana u tablici 9.1 putem različitih statističkih mjera, ali menadžerima je obično teško steći dojam koliko je model dobar ili loš. U tu svrhu prikaz grafički prikazuje performanse modela. Moglo bi se tvrditi da model prilično dobro prati testne podatke i u većini razdoblja pokazuje izvrsne performanse. Kako bi se generirale buduće prognoze, S-ARIMA (5,0,1)(1,0,0) 52 je preuređen dodavanjem podataka iz 2014. godine. Nakon toga, model je proizveo prognoze za 52 tjedna unaprijed za 2015. godinu. Prognoze za 2015. godinu prikazane su u donjem desnom prikazu. Prognoze su popraćene intervalima predviđanja od 80% i 95%, koji pokazuju da se moguće buduće prognoze razlikuju od srednjih predviđenih vrijednosti. Model predviđa kontinuirani pad potražnje koji je započeo 2014. Uzroci ovog pada mogu biti različiti i trebali bi ih dodatno istražiti menadžeri na strateškoj razini poduzeća.



LITERATURA 9. POGLAVLJA

- 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., Tsiniopoulos, 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.