



9. Predviđanje potražnje, vizualizacija i inženjering karakteristika vremenskih serija u lancima snabdevanja

Šta je predviđanje potražnje? Kako možemo efikasno vizualizovati podatke o kupcima i doneti zaključke o njima? Kako sprovesti inženjering karakteristika vremenskih serija?

Na ova i slična pitanja pokušaćemo dati odgovore u sledećem poglavljiju.

9.1 Šta je potražnja kupaca i predviđanje potražnje?

Zahvat krajnjeg kupca pokreće ceo lanac snabdevanja (Syntetos i dr., 2016). Shodno tome, potražnja kupaca je ključna komponenta za planiranje svih logističkih procesa u lancu snabdevanja pa je određivanje nivoa potražnje kupaca od velikog interesa za menadžere lanca snabdevanja. Komplementarno, predviđanje potražnje bitna je aktivnost za planiranje i raspoređivanje logističkih aktivnosti unutar promatranog lanca snabdevanja (Mircetic i dr., 2017). Precizni modeli predviđanja potražnje direktno utiču na smanjenje logističkih troškova budući da daju procenu potražnje kupaca (Mircetic i dr., 2016). Predviđanje u lancima snabdevanja prevazilazi operativni zadatak ekstrapolacije zahteva potražnje na jednom nivou. Uključuje složena pitanja kao što su koordinacija lanca snabdevanja i dijeljenje informacija između višestrukih učesnika (Syntetos i dr., 2016).

Potražnja kupaca i prateće prognoze su od vitalnog značaja za lance snabdevanja, 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 unapred, tada bi rad lanca snabdevanja bio direktna (unazad) vežba planiranja. Međutim, potražnja nije poznata i stoga je treba predvideti. Nesigurnost povezana s ovom potražnjom čini upravljanje lancem snabdevanja

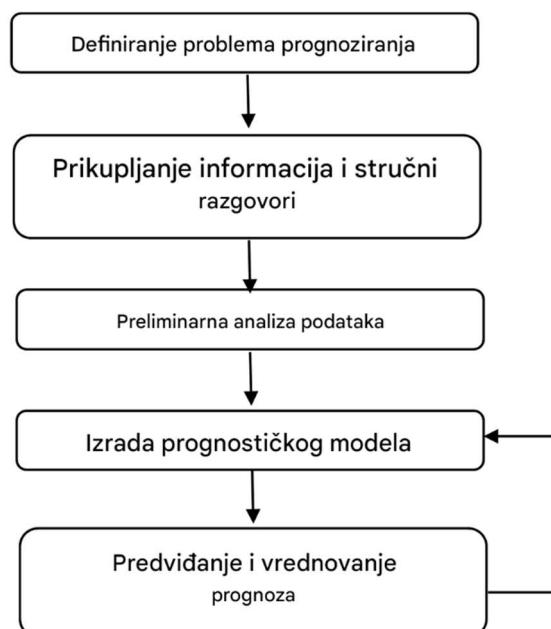


vrlo teškim (Syntetos i dr., 2016). Na učinkovitost predviđanja potražnje utiču inherentne neizvesnosti u vremenskoj seriji potražnje koje lanci snabdevanja imaju (Rostami-Tabar, 2013.). Posledično, rešavanje i razumevanje ovih neizvesnosti je veliki izazov za menadžere prilikom koordinacije i planiranja operacija unutar lanaca snabdevanja (Mircetic, 2018).

Nesigurnost potražnje je jedan od najznačajnijih izazova za savremene lance snabdevanja. Nedavna pandemija COVID-19 dodatno je naglasila ovaj problem, uzrokujući široko rasprostranjene poremećaje koji su komplikovali planiranje i kontrolu lanca snabdevanja (Nikolopoulos i dr., 2020). Predviđanje potražnje u lancima snabdevanja često uključuje predviđanje potražnje za brojnim artiklima. Prognostičari u lancima snabdevanja obično ekstrapoliraju vremenske serije podataka za svaku jedinicu zaliha (engl. *stock-keeping unit – SKU*) pojedinačno. Na primer, trgovac na malo može koristiti podatke o prodajnom mestu za generisanje predviđanja na nivou pojedinačne prodavnice (Mircetic i dr., 2022).

9.2 Koraci predviđanja potražnje u lancu snabdevanja?

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



Slika 4.54Osnovni koraci za pravilnu implementaciju predviđanja unutar preduzeća (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 orijentisanih) prognoza. Shodno tome, definisanje problema često je najteži deo predviđanja i zahteva razumevanje načina na koji će se predviđanja koristiti, kao i uloge funkcija predviđanja unutar promatranog preduzeća. Prognostičar bi trebao potrošiti dosta vremena na komunikaciju sa svima koji su uključeni u prikupljanje podataka, održavanje baze podataka i korišćenje prognoza za buduće planiranje. Jedan od glavnih otežavajućih činioca u definisanju problema je kako će se konačna prognoza koristiti u svakodnevnim logističkim procesima (koja platforma, dizajn softvera, korisnički interfejs itd.).

Za fazu prikupljanja informacija uvek su potrebne najmanje dve vrste informacija: statistički podaci i akumulirana stručnost ljudi koji prikupljaju podatke i koriste predviđanja. U praksi je često teško dobiti istorijske podatke za kreiranje dobrog statističkog modela. Takođe, postoji veliki nesporazum o tome šta su podaci o potražnji i što se može koristiti kao njihova zamena. Postoji loša praksa korišćenja podataka o otpremi i isporuci kao zamene za podatke o potražnji, što će samo pogoršati proces donošenja odluka na bazi predviđanja napravljenih na jednostavnoj vrsti podataka. Podaci o prodaji jedina su pouzdana zamena za podatke o potražnji (Syntetos i dr., 2016), iako ovo pojednostavljenje nije savršeno, posebno u lancima snabdevanja s puno situacija kada nedostaju zalihe (engl. *out-of-stock* – OOS).

Za fazu preliminarne analize podataka, preporučuje se uvek započeti analizu podataka s grafičkim prikazima kako bi se odgovorilo na sledeća pitanja. Postoje li dosledni obrasci? Postoji li značajan trend? Postoji li primetna 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 dalju analizu podataka sužavanjem fokusa na modele koje treba primeniti na otkrivena obležja potražnje. Uglavnom, jednostavni model, ovako određen, može pobediti one sofisticirane i komplikovane (Rostami-Tabar & Mircetic, 2023).

Izbor i izrada modela predviđanja je najvažniji korak pri izradi modela predviđanja. Koji model koristiti zavisi od nekoliko faktora, od kojih su najvažniji dostupnost istorijskih podataka i korelacija između zavisnih i nezavisnih varijabli. Uobičajeno je da se prilikom izbora modela upoređuju dva ili tri potencijalna modela. Svaki model je veštačka konstrukcija bazirana na skupu pretpostavki (eksplicitnih i implicitnih) i generalno uključuje jedan ili više parametara koji se moraju izraditi korišćenjem poznatih istorijskih podataka. U sledećem

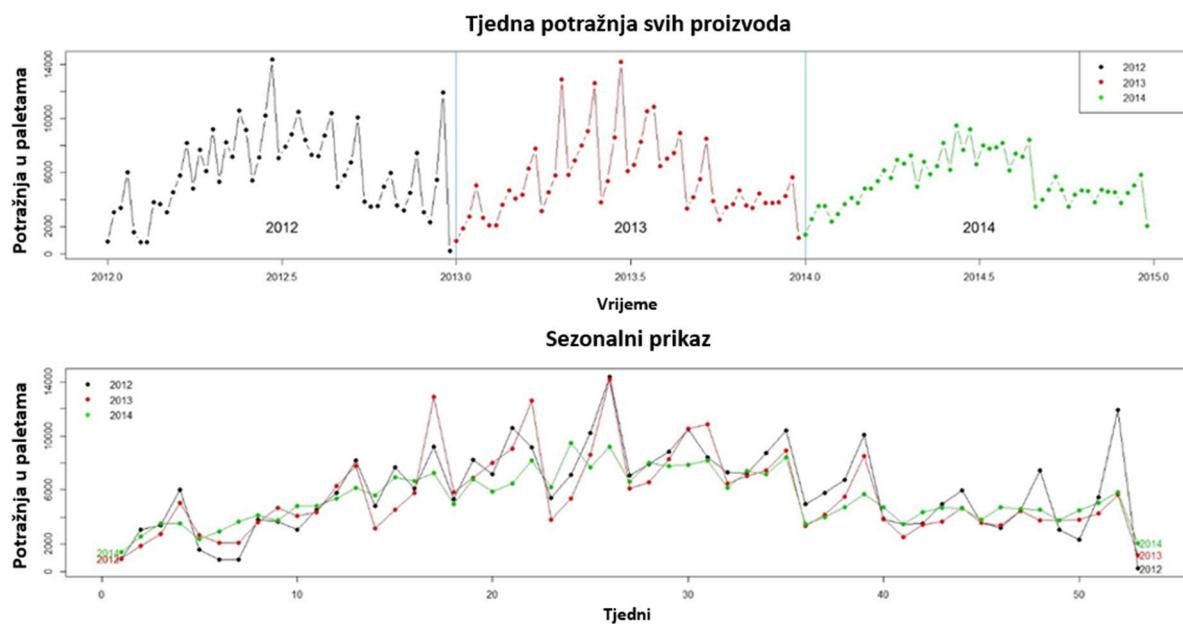


poglavlju biće prikazan proces razvoja i primene modela ARIMA, kao jednog od najboljih i najpopularnijih modela.

Ocenjivanje modela predviđanja je korak kojim se meri upotrebljivost kreiranog modela. Nakon izbora prognostičkog modela i procene njegovih parametara, model se koristi za izradu prognoza. Tačnost modela procenjuje se korišćenjem različitih statistika, ali takođe je važno testirati predviđanja putem merila poslovnih implikacija (tj. metrike korisnosti).

9.3 Predviđanje potražnje u prehrambenoj industriji

Podaci o potrošnji za sve proizvode promatranog preduzeća u prehrambenoj industriji prikazani su kao nedeljna potražnja u periodu od januara 2012. do decembra 2014. (slika 9.2). X osa predstavlja vreme, dok su vrednosti potražnje prikazane na y osi. Ovi podaci prikazani su u nedeljnim intervalima, jer to odgovara periodu u kojem se vrši snabdevanje krajnjih prodajnih mesta. Shodno tome, menadžment kompanije fokusiran je na predviđanje nedeljne potrošnje tržišta.

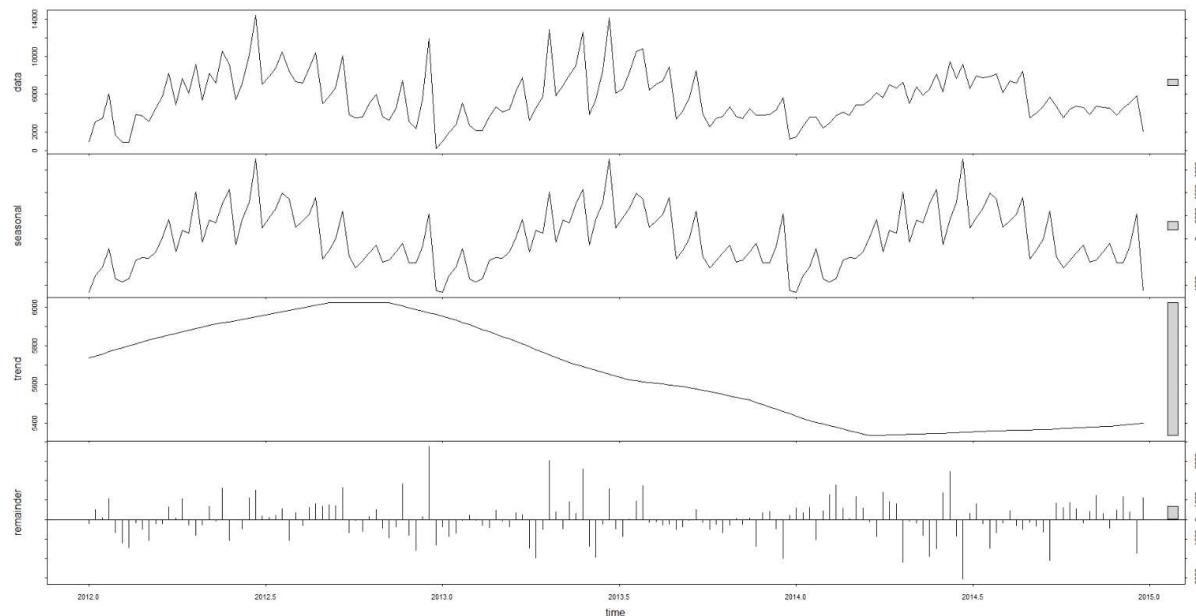


Slika 4.55 Podaci o potražnji za posmatranu prehrambenu kompaniju.

Slika 9.2 pokazuje nekoliko važnih obeležja i karakteristika datih podataka. Prvo, podaci imaju snažan sezonski karakter s vršnom prodajom koja se događa sredinom godine (letnji meseci). Drugo, podsezonski grafikon (donji grafikon na slici 9.2) prikazuje značajnu



promenu uzorka pada trendu u 2014.! Ovo je vrlo značajna karakteristika za izbor pravog modela predviđanja i za menadžere u preduzeću budući da otkriva značajan pad potrošnje i gubitak tržišta. Za dalje istraživanje posmatranih karakteristika koristi se metodologija dekompozicije sezonskog trenda (engl. *seasonal trend decomposition - STL*) (slika 9.3). STL dekompozicija deli izvorne obrasce potražnje na tri komponente: sezonsku, trend i ostatak.



Slika 4.56 STL dekompozicija podataka o potražnji.

STL je otkrio da posmatrane vremenske serije pokazuju aditivnu prirodu, što znači da se fluktuacije oko krive linije trend-ciklus ne povećavaju značajno tokom vremena. Kao rezultat, Box-Coxove transformacije nisu bile potrebne za neobrađene vremenske serije. Dekompozicija je otkrila da je sezonska komponenta dominantna u posmatranom nizu, pokazujući visoke fluktuacije unutar jedne godine. S obzirom na ograničeni broj godina posmatranja, teško je identifikovati poslovni ciklus. Dekompozicija je takođe pokazala da je trend u seriji minimalan, s opadajućim uzorkom počevši od sredine 2013.

Ove identifikovane karakteristike predstavljale su važan input tokom 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 kombinuje i autoregresivnu komponentu i komponentu pokretnog proseka, zajedno s razlikom kako bi podaci bili stacionarni. Ovaj model je posebno uspešan 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, omogućava preciznije i pouzdanije prognoze, koje su ključne za uspešno planiranje lanca snabdevanja i upravljanje zalihami. S-ARIMA strukturni oblik predstavljen je u jednačini (1).

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

gde su $\Phi(z)$ i $\Theta(z)$ polinomi reda P odnosno Q , od kojih svaki ne sadrži korene 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 korišćenju S-ARIMA modela je izbor odgovarajućeg redosleda modela, što uključuje određivanje vrednosti p , q , P , Q , D i d . Ako su d i D poznati, poredak p , q , P i Q može se odabrati korišćenjem informacionog kriterijuma kao što je Akaikeov informacioni kriterijum (AIC) ili Bayesov informacioni kriterijum (BIC). Formule za AIC i BIC date su prema:

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

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

gde je $k = p+q+P+Q+1$ ako je uključen konstantni izraz i 0, inače, L je maksimizirana verovatnoća modela prilagođenog različitim podacima, SSE je zbir kvadrata grešaka, N je broj opažanja koji se koristi za procenu, a k je broj prediktora u modelu.

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

- Upotrebite Canova-Hansen test za određivanje D u okviru ARIMA.
- Odaberite d primenom uzastopnog KPSS testa jediničnog korena na sezonski diferencirane podatke (ako je $D = 1$) ili na izvorne podatke (ako je $D = 0$).
- Odaberite optimalne vrednosti 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 njihovi rezultati prikazani su u tabeli 9.1. Za testiranje performansi različitih modela koristi se nekoliko mera: srednja absolutna procentualna greška (engl. *mean absolute percentage error* - MAPE), koren srednje kvadratne greške (engl. *root mean square error* - RMSE), srednja absolutna skalirana greška (engl. *mean absolute scaled error* - MASE), AIC i BIC (jednačine 2 i 3)

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

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

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

gde 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 mere za menadžere u lancima snabdevanja su RMSE i MAPE jer daju "osećaj" koliko je model dobar u realnim brojevima (RMSE) i procentima (MAPE).

Tabela 4.5 Rezultati 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} godine	1882.	22,12 %	1,05 %	41.74	53,56 0
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

^aGreške modela izračunavaju se na skupu testnih podataka.

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

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

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

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

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

Tabela 9.1 pokazuje da je model S-ARIMA (5,0,1)(1,0,0) ₅₂ nadmašio konkurentne modele postižući najniže greške RMSE, MAPE i MASE. Oblik modela S-ARIMA (5,0,1)(1,0,0) ₅₂ predstavljen je u jednačini (4), gde 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 $\Theta_1 = 0,6345$.

$$(1 - \phi_1 B - \phi_2 B - \phi_3 B - \phi_4 B - \phi_5 B)(1 - \Phi_1 B^{52})y_t = c + (1 + \Theta_1 B)e_t , (4)$$

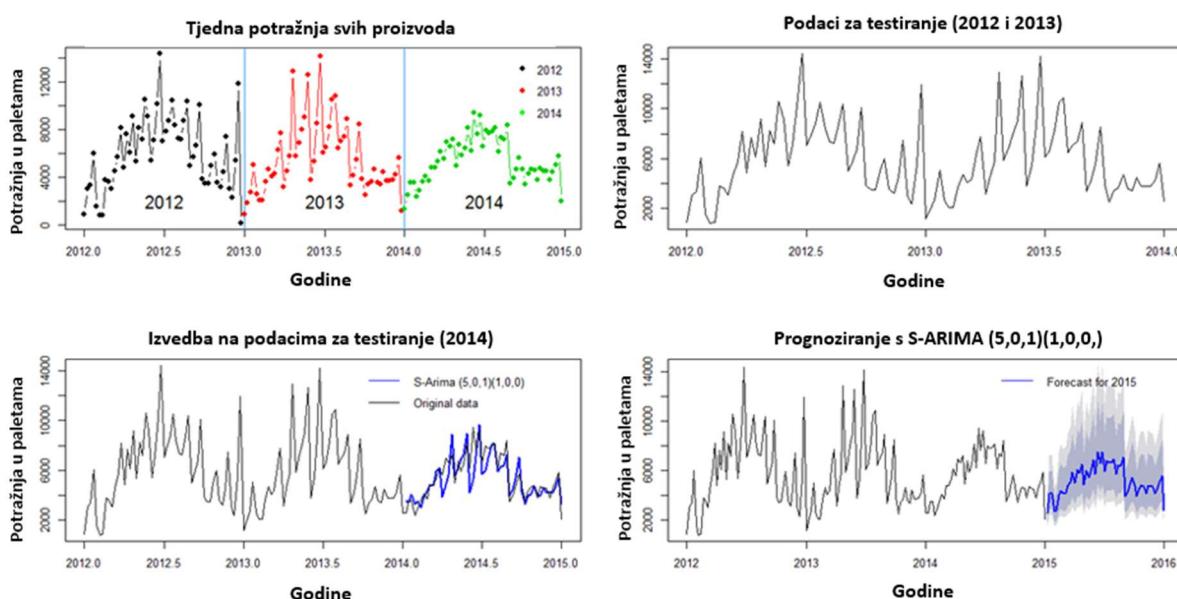
Slična izvedba primijećena je s modelima S-ARIMA (4,0,0)(1,0,0) ₅₂ i S-ARIMA (4,0,1)(1,0,0) ₅₂. Prilikom predviđanja, model S-ARIMA (5,0,1)(1,0,0) ₅₂ u proseku proizvodi grešku od 1023 proizvoda, što znači 14,18 %. Ovi rezultati naglašavaju važnost pažljivog izbora uslova za uključivanje u S-ARIMA model budući da nema značajnih razlika između performansi modela s različitim parametrima. Procena je pokazala da su modeli koji uključuju autoregresivne (p , P) i komponente pokretnog proseka (q , Q) učinkovitiji u predviđanju potrošnje pića od onih koji uključuju sezonske ili nesezonske razlike. Osim toga, uporedni 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 lošije rezultate od jednostavnog prosečnog modela naivne prognoze, što dokazuje njihova MASE greška veća od jedinice.

9.5 Predviđanja buduće potražnje

Slika 9.4 prikazuje rezultate S-ARIMA (5,0,1)(1,0,0) ₅₂. Gornji levi 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, kao ulaz postoje podaci za dve godine i treba predvideti buduću potražnju godinu dana unapred! Ovo je prilično čest scenario u lancima snabdevanja i logistici jer postoji napisano pravilo da kompanije čuvaju istoriju 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 levi prikaz na slici 9.4 predstavlja performanse promatranog modela. Učinkovitost modela već je prikazana u tabeli 9.1 putem različitih statističkih mera, ali menadžerima je obično teško da steknu utisak koliko je model dobar ili loš. U tu svrhu grafički prikaz prikazuje performanse modela. Moglo bi se tvrditi da model prilično dobro prati testne podatke i za većini perioda pokazuje izvrsne performanse. Kako bi se generisale 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 nedelje unapred 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 vrednosti. Model predviđa kontinuirani pad potražnje koji je započeo 2014. Uzroci ovog pada mogu biti različiti i menadžeri na strateškom nivou preduzeća trebali bi ih dodatno istražiti.



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., Maslarić, 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., & Maslarić, 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., & Maslarić, 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.