

Analiza učinka modela prognoze potražnje za prehrambene proizvode

Marković, Shanon

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:119:667758>

Rights / Prava: [In copyright / Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-05-20**



Repository / Repozitorij:

[Faculty of Transport and Traffic Sciences -
Institutional Repository](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Shanon Marković

ANALIZA UČINKA MODELA PROGNOZE POTRAŽNJE ZA PREHRAMBENE
PROIZVODE

DIPLOMSKI RAD

Zagreb, 2023.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 23. svibnja 2023.

Zavod: **Zavod za transportnu logistiku**
Predmet: **Distribucijska logistika II**

DIPLOMSKI ZADATAK br. 7315

Pristupnik: **Shanon Marković (0135252076)**
Studij: **Inteligentni transportni sustavi i logistika**
Smjer: **Logistika**

Zadatak: **Analiza učinka modela prognoze potražnje za prehrambene proizvode**

Opis zadatka:

U radu je potrebno usporediti različite modele prognoze potražnje na zadanom skupu podataka za određeni tip proizvoda te preporučiti optimalni model prognoze potražnje.

Mentor:

Predsjednik povjerenstva za
diplomski ispit:

prof. dr. sc. Kristijan Rogić

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

ANALIZA UČINKA MODELA PROGNOZE POTRAŽNJE ZA PREHRAMBENE
PROIZVODE

PERFORMANCE ANALYSIS OF DEMAND FORECAST MODELS FOR FOOD
PRODUCTS

Mentor: prof. dr. sc. Kristijan Rogić

Student: Shanon Marković

JMBAG: 0135252076

Zagreb, rujan 2023.

SAŽETAK

Prognoza potražnje je ključni aspekt upravljanja lancem opskrbe. To je proces procjene buduće potražnje za određenim proizvodima ili uslugama, što uključuje predviđanje količine tih proizvoda ili usluga koje će potrošači tražiti u budućem razdoblju. Ova procjena se temelji na analizi različitih čimbenika, uključujući povijesne podatke o potražnji, trendove, sezonske fluktuacije, marketinške kampanje i druge relevantne faktore. Primjena metoda prognoze potražnje u lancu opskrbe obuhvaća planiranje proizvodnje, upravljanje zalihama i planiranje nabave te rezultira većom učinkovitošću, smanjenjem operativnih troškova i boljim zadovoljenjem potreba kupaca. Analiza učinka prognoze potražnje na prehrambene proizvode predstavlja ključan aspekt u modernom poslovanju prehrambene industrije. U ovom radu, fokus je na tome kako primjena metoda prognoze potražnje može doprinijeti upravljanju lance opskrbe. Metode prognoze potražnje će biti primijenjene na proizvodima široke potrošnje, konkretno na primjerima kefira i bezglutenskog kruha.

KLJUČNE RIJEČI: metode prognoze potražnje; lanac opskrbe; prehrambeni proizvodi

SUMMARY

Demand forecasting is a key aspect of supply chain management. It is the process of estimating future demand for specific products or services, including predicting the quantity of these products or services that consumers will seek in a future time period. This estimation is based on the analysis of various factors, including historical demand data, trends, seasonal fluctuations, marketing campaigns, and other relevant factors. The application of demand forecasting methods in the supply chain encompasses production planning, inventory management, and procurement planning, resulting in increased efficiency, reduced operational costs, and better customer satisfaction. The analysis of the impact of demand forecasting on food products represents a crucial aspect of modern food industry operations. This paper focuses on how the application of demand forecasting methods can contribute to supply chain management. Demand forecasting methods will be applied to fast-moving consumer goods, specifically using the examples of kefir and gluten-free bread.

KEYWORDS: demand forecasting methods; supply chain; food products

SADRŽAJ

1. UVOD.....	1
2. OPSKRBNI LANAC.....	3
2.1. Integracija opskrbnog lanca.....	3
2.2. Struktura opskrbnog lanca.....	5
2.2.2 Funkcionalni ciklusi opskrbnog lanca.....	6
2.2.3. Inicijalizacija procesa opskrbnog lanca	7
2.3. Planiranje opskrbnog lanca	9
2.3.1. Logistička strategija	9
2.2.2. Lociranje objekata.....	10
2.2.3. Planiranje resursa	12
2.2.5. Mjerenje i poboljšanje performansi opskrbnog lanca	13
2.4. Aktivnosti u opskrbnom lancu	14
2.3.1. Nabava	14
2.3.2. Upravljanje zalihama.....	16
2.3.3. Skladištenje	18
2.3.4. Transport.....	19
3. METODE PROGNOZE POTRAŽNJE.....	21
3.1. Prognoza potražnje	21
3.1.1. Potražnja	22
3.1.2. Opskrba	25
3.1.3. Značajke proizvoda	25
3.1.4. Konkurencija.....	25
3.2. Metode prognoze potražnje	26
3.2.1. Kvalitativne metode.....	27

3.2.2. Uzročne	28
3.2.3. Vremenske metode	28
3.2.4. Prognoze istraživanjem tržišta	33
3.3. Mjere za točnost prognoze potražnje	33
4. IZRAČUN BUDUĆE POTRAŽNJE PREMA POVIJESNIM PODACIMA	35
4.1. Osnove računanja metoda prognoze potražnje	35
4.1.1. Autokorelacija.....	36
4.1.2. Alati u Excelu	37
4.2. Odabir i provedba metoda prognoze potražnje – kefir s 1,5% m.m.....	39
4.2.1. Holtova metoda prognoze potražnje.....	42
4.2.2. Metoda linearne regresije.....	45
4.3. Odabir i provedba metoda prognoze potražnje – bezglutenski kruh	49
4.3.1. Winterova metoda.....	51
4.3.2. Sezonska dekompozicija	57
5. PRIKAZ I USPOREDBA TOČNOSTI METODA PROGNOZE POTRAŽNJE	62
5.1. Metode prognoze potražnje za kefir s 1,5% m.m.	62
5.2. Metode prognoze potražnje za bezglutenski kruh	64
6. ZAKLJUČAK	69
LITERATURA.....	71
POPIS SLIKA	74
POPIS TABLICA.....	75
POPIS GRAFIKONA	76

1. UVOD

Upravljanje opskrbnim lancima je složen proces koji zahtijeva pažljivo planiranje i prilagodbu promjenama u potražnji. Opskrba prehrambenim proizvodima je ključna za zadovoljenje osnovnih ljudskih potreba i zahtijeva precizno predviđanje potražnje. Prognoza potražnje je ključna komponenta upravljanja lancem opskrbe, koristeći povijesne podatke i druge faktore za planiranje proizvodnje, upravljanje zalihama i nabavu. Ovaj proces povećava učinkovitost i smanjuje troškove, osiguravajući da potrebe kupaca budu ispunjene.

Cilj ovog diplomskog rada je opisati, prikazati i usporediti različite metode prognoziranja potražnje. U suradnji s trgovinom zdrave hrane, prikupljeni su stvarni podaci o potražnji tijekom 2021. i 2022. godine. Na temelju tih podataka izračunata je buduća potražnja pomoću metoda prognoze potražnje koja najbolje odgovara karakteristikama proizvoda.

Diplomski rad je strukturiran u pet dijelova:

1. Uvod
2. Opskrbni lanac
3. Metode prognoze potražnje
4. Izračun buduće potražnje na temelju povijesnih podataka
5. Prikaz i usporedba točnosti metoda prognoze potražnje

U prvom dijelu, uvodnom poglavlju, definiran je predmet istraživanja i navedena struktura rada.

U drugom dijelu, opskrbni lanac je detaljnije objašnjen, uključujući integraciju opskrbnog lanca i razlike u odnosu na klasičnu logistiku. Prikazana je njegova struktura kroz funkcionalne cikluse i inicijalizacijske procese, te su obuhvaćene aktivnosti poput nabave, upravljanja zalihama, skladištenja i transporta.

Treći dio je teorijski uvod u praktični dio rada, gdje se definira prognoza potražnje i objašnjava njezina važnost za buduće planiranje. Opisane su glavne metode prognoze potražnje i kako identificirati obrasce potražnje za pojedine proizvode, uz mjere točnosti koje ocjenjuju preciznost metoda.

Četvrti dio se fokusira na primjenu prognoza potražnje za prehrambene proizvode, konkretno kefir s 1,5% mliječne masti i bezglutenski kruh. Za svaki proizvod analizirano je kretanje potražnje, te su odabrane dvije metode koje najbolje odgovaraju tim obrascima potražnje.

U petom dijelu, metode prognoze potražnje su grafički prikazane i uspoređene, uz analizu točnosti mjera i odstupanja od stvarne potražnje. Na kraju se predlaže optimalno rješenje i najbolja metoda za planiranje buduće potražnje kefira i bezglutenskog kruha.

2. OPSKRBNI LANAC

Opskrbni lanci su inherentni procesi u poslovanju, jer svaki proizvod koji stigne do krajnjeg kupca rezultat je suradnje različitih organizacija. Opskrbni lanac je ključna komponenta suvremenog poslovanja koja predstavljaju složeni sustav koji obuhvaća sve korake, resurse i aktivnosti potrebne za isporuku proizvoda ili usluga kupcima. U današnjem globalnom i tehnološki naprednom svijetu, pravilno upravljanje opskrbnim lancem postaje sve važnije za organizacije kako bi ostvarile konkurentske prednosti, optimizirale troškove i osigurale visoku razinu zadovoljstva svojih kupaca.

2.1. Integracija opskrbnog lanca

"Upravljanje lancem opskrbe" ili "Supply Chain Management" (SCM) je koncept koji se razvio nakon usvajanja ideje o integraciji logistike. Integrirana logistika promatra različite logističke elemente kao jedinstveni i složeni sustav, umjesto odvojenih aktivnosti. SCM ide korak dalje uključujući ne samo logističke aspekte, već i dobavljače i krajnje korisnike. Osnovna razlika između SCM-a i tradicionalne logistike je što SCM obuhvaća čitav lanac, od dobavljača do krajnjeg korisnika [1].

Dakle, opskrbni lanac obuhvaća širi spektar aktivnosti i poslovnih segmenata. On uključuje snabdijevanje sirovinama i komponentama, kao i isporuku proizvoda krajnjem kupcu. Ovaj odnos se može prikazati kao [2]:

$$\text{Opskrbni lanac} = \text{Dobavljači} + \text{Logistika} + \text{Krajnji korisnici}$$

Postoje četiri ključne razlike između upravljanja lancem opskrbe i klasične logistike [1]:


1. **Cjelovitost i integracija:** Upravljanje lancem opskrbe promatra lanac kao jedinstvenu cjelinu umjesto niza odvojenih segmenata poput nabave, proizvodnje i distribucije. U ovom pristupu, dobavljači i krajnji korisnici također su uključeni u planiranje, što premašuje okvire pojedinačnih organizacija.
2. **Strateški pristup:** Upravljanje lancem opskrbe je strateški proces koji se usredotočuje na strateške odluke, umjesto na operativne zadatke.

3. **Optimizacija inventara:** Dok je u tradicionalnoj logistici inventar često služio kao sigurnosni mehanizam između odvojenih dijelova lanca opskrbe, upravljanje lancem opskrbe ima cilj promijeniti ovu perspektivu tako da inventar služi kao alat za ravnotežu protoka proizvoda kroz lanac opskrbe.
4. **Integrirani informacijski sustavi:** Upravljanje lancem opskrbe koristi integrirane informacijske sustave koji obuhvaćaju cijeli lanac umjesto pojedinačnih komponenti. Ovi sustavi omogućuju bolju vidljivost potražnje i stanja zaliha kroz čitav lanac opskrbe zahvaljujući napretku tehnologije informacijskih sustava.

Mnoge tvrtke još uvijek imaju prilično ograničenu integraciju unutar vlastitih organizacija. Unatoč tome, vanjska integracija je ono što se predviđa kao optimalan pristup u budućnosti i kojemu se treba težiti. Razina integracije ima značajan utjecaj na način kako tvrtke organiziraju svoje logističke operacije. Visoko integrirane tvrtke obično drže minimalne zalihe i usredotočene su na stalni protok proizvoda kroz svoj lanac opskrbe. S druge strane, manje integrirane organizacije često održavaju velike količine zaliha na različitim točkama u lancu opskrbe.

Tvrtke obično prolaze kroz nekoliko faza tijekom procesa potpune integracije svog lanca opskrbe, a te faze su prikazane na Slici 1 [3]:

1. **Polazna faza (Baseline):** U ovoj početnoj fazi svaki odjel ili sustav unutar tvrtke upravlja vlastitim dijelom lanca opskrbe. Ovaj izolirani pristup, iako može imati svoje prednosti, često nije učinkovit jer nema cjelovite koordinacije.
2. **Funkcionalna integracija:** U ovoj fazi odjeli unutar tvrtke počinju surađivati kako bi poboljšali učinkovitost i smanjili troškove. To se postiže kombiniranjem narudžbi, zajedničkim raspoređivanjem poslova i sličnim praksama.
3. **Unutarnja integracija lanca opskrbe:** Svi odjeli unutar tvrtke koriste iste sustave i platforme. Ovo obično uključuje upotrebu informacijske tehnologije (IT) kako bi odjeli mogli bolje surađivati, dijeliti informacije i prepoznati prilike za zajednički rad.
4. **Vanjska integracija lanca opskrbe:** Konačno, u ovoj fazi tvrtke uključuju vanjske dobavljače i omogućuju im pristup svojim sustavima kako bi postigli optimalne rezultate i potpunu integraciju lanca opskrbe.



Slika 1 Integracija opskrbnog lanca

Izvor: [3]

2.2. Struktura opskrbnog lanca

Opskrbni lanac ima strukturu koja obuhvaća različite procese, tokove robe, informacija i financijske transakcije unutar i između različitih faza. Glavni akteri u ovim procesima podijeljeni su u pet skupina prema svojim funkcijama [4]:

1. **Dobavljači:** To su subjekti koji isporučuju sirovine i komponente potrebne za proizvodnju proizvoda.
2. **Proizvođači:** Ovi subjekti izrađuju konačne proizvode koristeći sirovine i komponente dobavljene od dobavljača.
3. **Distributeri (Veletrgovci):** Distributeri su odgovorni za distribuciju proizvoda od proizvođača do maloprodajnih trgovaca ili drugih distribucijskih kanala.
4. **Maloprodajni Trgovci (Prodajna Mjesta):** To su subjekti koji prodaju proizvode krajnjim kupcima putem fizičkih trgovina ili internetskih platformi.
5. **Kupci:** Kupci su krajnji korisnici proizvoda koji ih kupuju za osobnu upotrebu.

Strukturu opskrbnog lanca možemo analizirati na dva načina [5]:


1. **Prema funkcionalnim ciklusima:** Procesi opskrbnog lanca grupiraju se u funkcionalne cikluse koji predstavljaju točke interakcije između različitih faza i subjekata u istoj fazi.
2. **Prema inicijalizaciji:** Procesi opskrbnog lanca dijele se na one koji se pokreću kao odgovor na stvarnu potražnju (pull procesi) i one koji se pokreću na temelju očekivanja i predviđanja buduće potražnje (push procesi).

2.2.2 Funkcionalni ciklusi opskrbnog lanca

Nakon detaljne analize opskrbnog lanca i identifikacije pet glavnih subjekata, procesi opskrbnog lanca mogu se organizirati u četiri funkcionalna ciklusa. Ovi ciklusi predstavljaju faze koje opskrbeni lanac prolazi kako bi učinkovito obavio svoje zadatke. Ovi funkcionalni ciklusi uključuju (Slika 2) [4]:

1. **Ciklus prodaje:** Ovaj ciklus obuhvaća aktivnosti povezane s prodajom proizvoda krajnjim korisnicima i upravljanje njihovim zahtjevima.
2. **Ciklus zaliha:** U ovom ciklusu upravlja se razinama zaliha sirovina, komponenata i gotovih proizvoda kako bi se osigurala dostupnost proizvoda u svim fazama lanca opskrbe.
3. **Ciklus proizvoda:** Ovaj ciklus uključuje procese proizvodnje i montaže proizvoda te njihovu distribuciju do krajnjih korisnika.
4. **Ciklus materijala:** Ciklus materijala fokusiran je na upravljanje opskrbom sirovina i komponenata potrebnih za proizvodnju.

Važno je napomenuti da u svakom opskrbnom lancu nisu nužno prisutni svi glavni subjekti. Postoje situacije u kojima se više faza opskrbnog lanca može potpuno ili djelomično nalaziti unutar domene istog subjekta. Istovremeno, navedeni funkcionalni ciklusi nisu uvijek jasno odvojeni, već se mogu potpuno ili djelomično preklapati. Ova fleksibilnost omogućava prilagodbu i priliku za optimizaciju procesa unutar opskrbnog lanca u skladu sa specifičnim uvjetima i potrebama subjekta.



Slika 2 Funkcionalni ciklusi opskrbnog lanca


Izvor: [4]

2.2.3. Inicijalizacija procesa opskrbnog lanca

Procesi opskrbnog lanca su određeni vremenom i inicijalizacijom izvršenja u odnosu na potražnju kupaca. S obzirom na tu činjenicu, procesi opskrbnog lanca mogu se podijeliti u dvije kategorije: pull procese i push procese.

Pull procesi se izvršavaju nakon što se stvarno iskaže potražnja, odnosno u uvjetima poznate potražnje. Oni su reaktivni i odgovaraju na trenutnu potražnju kupaca. S druge strane, push procesi se izvršavaju prije nego što se stvarno iskaže potražnja, odnosno u uvjetima kada potražnja još nije poznata, već se očekuje ili mora predvidjeti. Push procesi su proaktivni i usmjereni prema anticipiranju buduće potražnje [1][2].


U kontekstu prethodno opisanih funkcionalnih ciklusa u opskrbnom lancu, postoji određeno mjesto u vremenskom slijedu procesa gdje se može povući granica koja razdvaja pull-procese od push-procesa (Slika 3). Ova granica se naziva push/pull granica (engl. Push/Pull Boundary). Točno mjesto gdje se granica postavlja, odnosno između koje faze ili ciklusa u opskrbnom lancu se nalazi, ovisi o strategiji opskrbnog lanca koja se primjenjuje [1][2].



Slika 3 Push/Pull granica u opskrbnom lancu

Izvor: [6]

U konkretnom opskrbnom lancu, glavna strategija upravljanja ovisi o specifičnostima proizvoda, proizvodnoj tehnologiji i načinu distribucije, a definiranje granice između push i pull procesa u primjeni push/pull strategije ovisi o tim čimbenicima. Za odabir odgovarajuće strategije upravljanja opskrbnim lancem može se koristiti shema prikazana na Slici 4.



Slika 4 Načelna shema određivanja strategije upravljanja opskrbnim lancem

Izvor: [6]

U stvarnosti, većina tvrtki koristi obje strategije upravljanja opskrbnim lancem. To kombiniranje push i pull strategija omogućuje postizanje ravnoteže između efikasnosti i fleksibilnosti u upravljanju opskrbnim lancem te smanjuje rizik od prekomjernih ili nedovoljnih zaliha. Također pomaže u poboljšanju točnosti prognoziranja potražnje i bržem reagiranju na promjene na tržištu.

2.3. Planiranje opskrbnog lanca


Planiranje opskrbnog lanca obuhvaća različite aspekte unutar lanca opskrbe i počinje izradom logističke strategije koja postavlja osnove za sve ostale logističke odluke. S obzirom na kompleksnost opskrbnih lanaca, ključno je razvijati logističke strategije, pažljivo birati lokacije distribucijskih centara i učinkovito upravljati resursima kako bi se postigla optimizacija poslovnih procesa.

2.3.1. Logistička strategija

Logističko planiranje treba provoditi prema određenoj hijerarhiji koja odražava različite vremenske horizonte planiranja. Odluke koje organizacije donose mogu imati različit stupanj važnosti, a njihove posljedice mogu se dugoročno odraziti na organizaciju. Odluke manje važnosti neće imati značajan utjecaj na organizaciju te se stoga donose brže i na nižim razinama unutar organizacijske strukture. Prema važnosti odluka i vremenskom horizontu odluke se klasificiraju kao (Slika 5)[2]:

1. **Strateške odluke:** Smatraju se najvažnijim odlukama koje određuju cjelokupni smjer organizacije, imaju dugoročne učinke, te zahtijevaju velike resurse. Od svih odluka, strateške odluke su najrizičnije.
2. **Taktičke odluke:** Bave se provedbom strategija u srednjoročnom razdoblju, uzimaju u obzir više detalja, uključuju manje resursa uz postojanje rizika.
3. **Operativne odluke:** Predstavljaju najdetaljnije odluke koje se odnose na kratkoročne aktivnosti, koriste malo resursa uz nizak rizik.

Dakle, poslovne strategije pokazuju što treba učiniti, a logističke strategije pokazuju kako će opskrbeni lanac doprinijeti da se ciljevi realiziraju. Primjerice, ako organizacija ima poslovnu strategiju da bude najjeftiniji dobavljač nekog proizvoda, logistička strategija pokazuje kako će svesti logističke troškove na minimum; ako organizacija radi na brznoj isporuci kupcima, logistička strategija će definirati politike za postizanje toga [2].



Slika 5 Hijerarhija logističkog planiranja

Izvor: [1]

Iz navedenoga, logistička strategija se može definirati kao „skup svih strateških odluka, politika, planova i kultura koje se odnose na upravljanje njezinim opskrbnim lancima [2].“ Logistička strategija čini vezu između viših strategija i detaljnijih operacija opskrbnog lanca. Dok korporativne i poslovne strategije opisuju opće ciljeve, logistička strategija se odnosi na stvarno kretanje materijala potrebnih za postizanje tih ciljeva.

2.2.2. Lociranje objekata

Prilikom otvaranja ili proširenja objekata, organizacije se suočavaju s važnim odlukama o izboru lokacije. Ovaj izbor ima dugoročne posljedice i značajan utjecaj na uspjeh organizacije. Odabir lokacije je kompleksan proces koji zahtijeva razmatranje različitih čimbenika. Među mjerljivim čimbenicima su [2]:

- a. operativni troškovi, plaće, porezi, tečajevi valuta,
- b. konkurencija,
- c. udaljenost od postojećih objekata,
- d. potpore za razvoj,
- e. broj stanovnika i
- f. pouzdanost opskrbe.

S druge strane, postoje i čimbenici koji nisu podložni promjenama i na koje organizacije ne mogu direktno utjecati, kao što su [2]:


- a. kvaliteta infrastrukture,
- b. politička stabilnost,
- c. društveni stavovi,
- d. pravni sustav,
- e. budući razvoj gospodarstva i drugi.

Kada se razmatra odabir lokacije objekta, postoji hijerarhija odluka koju treba slijediti (Slika 6):

1. Na najvišoj razini, organizacija odlučuje u kojim geografskim regijama planira širenje svog poslovanja i otvaranje novih objekata.
2. Nakon što su odabrane regije, organizacija detaljnije istražuje alternativne zemlje ili područja unutar tih regija kako bi suzila izbor.
3. Slijedi pažljivo razmatranje različitih gradova unutar odabranih područja kako bi se odabrala najprikladnija lokacija.
4. Na kraju, organizacija usmjerava svoju pažnju na evaluaciju različitih lokacija unutar odabranog grada kako bi konačno donijela odluku o lokaciji objekta.

Kada se bira lokacija za objekt, često se uzimaju u obzir dva ključna kriterija. Prvi je blizina kupcima ili dobavljačima. Na primjer, tvrtka Toyota otvorila je tvornice u SAD-u kako bi bila bliže glavnom tržištu za automobile, dok tvrtka Exxon posluje na Bliskom istoku zbog svoje blizine izvorima nafte.

Drugi važan faktor je odabir lokacija s nižim operativnim troškovima. Proizvođači često premještaju svoje proizvodne pogone u područja gdje su troškovi proizvodnje niži, čak i ako su te lokacije udaljene od kupaca i dobavljača. U takvim situacijama, logistika postaje ključna komponenta za održavanje učinkovitosti poslovanja, osiguravajući da niži troškovi proizvodnje ne budu nadmašeni višim troškovima logistike.



Slika 6 Hijerarhija donošenja odluka za odabir lokacije

Izvor: [2]


2.2.3. Planiranje resursa

Planiranje aktivnosti u opskrbnom lancu, što obuhvaća nabavu, proizvodnju, skladištenje, transport, distribuciju i drugo, počinje stvaranjem opće logističke strategije koja postavlja ciljeve. Ovi planovi se zatim prenose kroz organizacijsku hijerarhiju, od viših do nižih menadžera, kako bi se detaljnije razradili. Ključan aspekt ovog planiranja je određivanje kapaciteta opskrbnog lanca.

Kapacitet opskrbnog lanca se može definirati kao "maksimalna količina proizvoda koja se može isporučiti krajnjim kupcima u određenom razdoblju" ili kao "maksimalni protok u određenom razdoblju". Svaka operacija u lancu opskrbe ima ograničenje kapaciteta, kao što je maksimalan broj jedinica koje tvornica može proizvesti tjedno ili maksimalna težina koju kamion može prevesti [2].

Kapacitet se izričito odnosi na vremenski okvir, kao što je maksimalni broj kupaca koji se mogu poslužiti u jednom danu. Sve mjere kapaciteta su vremenski definirane. Kapacitet ima ključnu ulogu u logistici jer određuje maksimalni protok kroz opskrbeni lanac unutar određenog razdoblja [2].

Kapacitet različitih dijelova opskrbnog lanca nije jednak. Određeni dijelovi ograničavaju ukupni protok, stvarajući uska grla (Slika 7). Dok neki dijelovi mogu djelovati s maksimalnim kapacitetom, drugi ne mogu pratiti takve kapacitete. Kao rezultat, uska grla u opskrbnom lancu smanjuju ukupni kapacitet. Povećanje kapaciteta uskog grla jedini je način za povećanje kapaciteta opskrbnog lanca.



Slika 7 Usko grlo u opskrbnom lancu

Izvor: [2]

Glavni cilj planiranja kapaciteta je usklađivanje raspoloživog kapaciteta sa zahtjevima postavljenim pred njega. Neusklađenost u opskrbnom lancu može imati negativne posljedice na profit organizacije. Kada je kapacitet manji od potražnje, uska grla ometaju protok materijala, što rezultira smanjenom uslugom za kupce. S druge strane, kada je kapacitet veći od potražnje, organizacija može imati višak kapaciteta i nedovoljno iskorištene resurse. Planiranje kapaciteta predstavlja kompleksan zadatak koji zahtijeva donošenje odluka na visokoj razini unutar organizacije [2].

2.2.5. Mjerenje i poboljšanje performansi opskrbnog lanca

U svakoj organizaciji, menadžeri su odgovorni za mjerenje učinka logistike. Mjerenje je ključno za poboljšanje poslovanja i daje informacije o tome kako tvrtka radi. Također, omogućuje procjenu postizanja ciljeva i usporedbu s konkurencijom. Postoje različiti aspekti logistike koje možemo mjeriti..

Neke od mjera su neizravne i odnose se na financijske aspekte, kao što je ukupni profit tvrtke. Financijske mjere su lako dostupne, pružaju široki pregled i omogućuju usporedbu.

Međutim, imaju određene nedostatke jer se fokusiraju na prošlost umjesto na trenutne performanse, sporije reagiraju na promjene, oslanjaju se na računovodstvene podatke te ne obuhvaćaju važne aspekte logistike. Financijski rezultati mogu ukazivati na isplativost ili neisplativost poslovanja, ali ne pružaju detalje o tome koji dio opskrbnog lanca ne funkcionira dobro niti kako to ispraviti.

U praksi je mnogo korisnije koristiti izravne mjere logistike, kao što su broj isporučenih tona, promet zaliha ili prijeđene udaljenosti. Učinkovitost izvršenja može se procijeniti kroz faktore kao što su kapacitet, iskorištenost i produktivnost.

2.4. Aktivnosti u opskrbnom lancu

Opskrbni lanac uključuje niz usklađenih aktivnosti koje su ključne za njegovo uspješno funkcioniranje. Sve počinje narudžbom od kupca i završava trenutkom kada zadovoljni kupac izvrši plaćanje za isporučenu robu na temelju izdanog računa. Ove aktivnosti obuhvaćaju nabavu, upravljanje zalihama, skladištenje i transport.

2.3.1. Nabava

Nabava, zajedno sa proizvodnjom i prodajom, predstavlja jednu od najvažnijih poslovnih funkcija u industrijskim poduzećima, dok je u trgovinskim poduzećima jednako bitna kao i prodaja. Bez učinkovite nabave, nijedno industrijsko poduzeće ne može uspješno poslovati.

Glavna svrha nabave u industrijskim poduzećima jest osigurati nabavu radnih predmeta, sredstava za rad i proizvodnih usluga potrebnih za proizvodnju i poslovanje poduzeća.

Nabava se u užem smislu odnosi na samu kupnju predmeta po određenoj cijeni. No, u širem smislu, nabava obuhvaća širi spektar aktivnosti, uključujući planiranje, politiku nabave, odabir izvora nabave, praćenje isporuke narudžbi, prihvrat materijala, kvantitativnu i kvalitativnu kontrolu isporučenih materijala, razvoj odgovarajućih tehnika i metoda nabave, te suradnju i koordinaciju s drugim odjelima unutar poduzeća, poput skladišta, transportnog odjela, pripreme, knjigovodstva, prodaje i proizvodnje.

Proces organiziranja nabave može se gledati kroz sljedeće korake [7]:

1. Prepoznavanje potrebe za nabavom
2. Odabir dobavljača
3. Priprema i ispostavljanje narudžbe
4. Nadzor i upravljanje procesom isporuke
5. Vrednovanje nabave i dobavljača

Organizacijska struktura, bitna komponenta svake organizacije, predstavlja sustav veza i odnosa unutar nje. Ova struktura obuhvaća međusobne odnose svih čimbenika poslovanja i igra ključnu ulogu u upravljanju nabavom, osiguravajući da nabavne aktivnosti budu usklađene s ciljevima.

Kada organizacija odabire svoju strukturu nabave, važno je razmotriti model koji najbolje odgovara njezinim potrebama. U manjim organizacijama s ograničenom nabavom, jedan zaposlenik može biti odgovoran za sve nabavne zadatke.

Srednje velike organizacije obično imaju poseban odjel nabave s različitim ulogama kao što su kupci, ekspeditori, skladištari i administrativno osoblje. Ovaj model omogućuje specijalizaciju i bolju koordinaciju nabavnih aktivnosti. Odjel nabave može biti odgovoran za sve faze nabavnog procesa, uključujući identifikaciju potreba, pronalaženje dobavljača, pregovaranje o uvjetima i nadzor nad isporukama [2].

U velikim organizacijama s velikim obimom nabave često se koristi centralizirani model nabave. To znači da se svi nabavni procesi provode kroz jedan odjel koji koordinira sve nabavke u organizaciji. Ovaj model omogućuje bolju kontrolu troškova, veću pregovaračku moć s dobavljačima i stvaranje dosljednih nabavnih procesa. Međutim, svjesni smo izazova centralizirane nabave u organizacijama koje posluju na širem geografskom području. U takvim situacijama, organizacije mogu koristiti lokalnu nabavu kako bi iskoristile prednosti boljeg poznavanja lokalnih uvjeta i kulture, jačih odnosa s dobavljačima, veće fleksibilnosti u operacijama i smanjenja troškova transporta [2].

Problemi operativne nabave su [7]:

1. Nedostatak pravovremenih zahtjeva za nabavom;
2. Kašnjenje u isporuci materijala;

3. Isporuka neodgovarajuće robe;
4. Reklamacije;
5. Poteškoće u praćenju i kompenzaciji robe

Uvođenje sustava elektroničke nabave predstavlja značajan korak unaprijed u poboljšanju nabavne funkcije. Primjena elektroničke razmjene podataka (EDI) postala je popularna od 1980-ih i omogućila je automatizaciju nabavnih procesa. Putem povezivanja informacijskih sustava organizacije i dobavljača, sustav automatski šalje narudžbe u određeno vrijeme. Ova metoda je posebno učinkovita za male, redovite narudžbe koje se često ponavljaju, pa ju većina organizacija prihvaća.

Unatoč tome što sustav elektroničke nabave omogućuje poboljšanu komunikaciju, nije nužno povezan s fizičkim protokom materijala. Stvarni napredak u tome postiže se samo kada organizacije u opskrbnom lancu koriste komunikacijske kanale kako bi pronašle bolje načine za fizički prijenos materijala [1].

2.3.2. Upravljanje zalihama

Zalihe su prisutne u svim fazama opskrbnog lanca: od nabave, preko proizvodnje, distribucije, pa sve do potrošnje. Upravljanje zalihama zahtijeva niz složenih aktivnosti koje zahtijevaju istraživanje i stručnost kako bi se pravilno planirale, nabavljale, kontrolirale i upravljale zalihama. No, precizno predviđanje potražnje za proizvodima u opskrbnom lancu često je izazovno zbog nepredvidljivih promjena u potražnji. Stoga sudionici u opskrbnom lancu održavaju određene količine zaliha kako bi osigurali kontinuirano ispunjenje zahtjeva [8].

U realnom poslovanju opskrbnog lanca, primjetan je fenomen kašnjenja, što dovodi do akumulacije zaliha. Održavanje odgovarajućih zaliha robe ima ključnu ulogu iz više razloga: [8]:


1. Zaštita poslovanja i proizvodnje u uvjetima neizvjesnosti
2. Mogućnost ekonomične nabave i proizvodnje
3. Pokrivanje očekivanih promjena u ponudi i potražnji
4. Održavanje neometanog toka materijala unutar proizvodnog ili poslovnog sustava.

Zalihe u opskrbnom lancu djeluju kao "amortizeri" između ulaznih i izlaznih tokova materijala. One su nužne kada se vremenska i količinska struktura ulaza i izlaza razlikuju, što

može biti rezultat različitih struktura ulaznih i izlaznih tokova na različitim točkama prodajnog kanala. Zalihe se formiraju kako bi se osigurao kontinuitet opskrbe i smanjio rizik od prekida u opskrbnom lancu. Imaju ključnu ulogu u usklađivanju ponude i potražnje te omogućavaju fleksibilnost i prilagodljivost u upravljanju materijalnim tokovima.

Zalihe se primarno mogu klasificirati prema (Slika 8)[8]:

1. Vrsti robe koja se skladišti
2. Stvarnoj i planiranoj količini



Slika 8 Vrste zaliha s obzirom na vrstu robe i planiranje

Izvor: [8]

2.3.3. Skladištenje

Skladištenje je namjerna praksa kojom se materijali ili proizvodi postavljaju u stanje mirovanja, a skup svih radnji koje se odnose na manipulaciju tim materijalima unutar skladišta naziva se skladišni proces. "Skladište" se općenito odnosi na organizirani sustav za skladištenje. Glavne komponente skladišnog sustava su [9]:

1. Skladišni objekti (zgrade, uređene površine...),
2. Sredstva za skladištenje i sredstva za odlaganje materijala (sredstva za oblikovanje jediničnih tereta),
3. Transportna sredstva,
4. Pomoćna skladišna oprema (računalna oprema, oprema za pakiranje, sredstva za paletizaciju i depaletizaciju, sredstva za kontrolu i mjerenje...),
5. Dodatna oprema (protupožarna, oprema za grijanje i hlađenje, rasvjeta, oprema održavanja čistoće, itd.).

Najčešće aktivnosti u procesu skladištenja obuhvaćaju [9]:

1. Istovar i preuzimanje materijala
2. Kontrola materijala
3. Sortiranje, paletizacija i depaletizacija
4. Transport i odlaganje materijala u skladištu čuvanje, zaštita i održavanje materijala
5. Prikupljanje, sortiranje i pripremanje materijala za izdavanje – komisioniranje
6. Otpis i inventura materijala
7. Upravljanje skladištem
8. Pakiranje i izdavanje
9. Evidentiranje svih događaja i promjena u vezi s materijalom
10. Održavanje skladišne i transportne opreme
11. Usklađivanje zadaće skladišta sa zadaćom drugih procesa u poduzeću

Skladišta su nekad bila mjesta za dugoročno skladištenje roba, ali danas imaju drugačiju ulogu. S obzirom na potrebu za brzim protokom materijala kroz lanac opskrbe, skladišta se koriste za sortiranje, pakiranje i konsolidaciju isporuka. Ova promjena znači da skladišta

obavljaju različite zadatke koji doprinose stvaranju dodane vrijednosti, umjesto da budu samo troškovni centri.

Prema stupnju mehanizacije i automatizacije skladišta mogu biti:

1. Nisko mehanizirana,
2. Visoko mehanizirana
3. Automatizirana i
4. Robotizirana.

U nisko mehaniziranim skladištima, koji su klasični tip skladišta, većinu poslova obavljaju skladišni radnici ručno koristeći jednostavnu skladišnu opremu poput kolica. Visoko mehanizirana skladišta kombiniraju ručni rad s automatiziranim sredstvima za obavljanje poslova. U potpuno automatiziranim skladištima, svi poslovi se obavljaju automatizirano, dok je zaposleno osoblje prisutno samo kad je potrebno. U ovim skladištima, upravljanje procesima i operacijama odvija se putem elektroničkih sustava i računalne tehnologije.

2.3.4. Transport

Transport je specijalizirana djelatnost koja osigurava proizvodnju prometnih usluga putem prometne suprastruktura i infrastrukture. Njegova svrha je premještati robu, teret i materijalna dobra s jednog mjesta na drugo, svladavajući prostorne i vremenske udaljenosti.

U okviru transporta, obavljaju se različite operacije vezane uz promet robe, uključujući ukrcaj, iskrcaj, prekrcaj, sortiranje, smještaj, slaganje, punjenje i pražnjenje kontejnera i mnoge druge koje osiguravaju siguran i učinkovit prijevoz [21].

Dva osnovna ekonomska principa su:

1. Ekonomija obujma – kako se povećava veličina pošiljka trošak po jedinici težine opada,
2. Ekonomija udaljenosti (tzv. Tapering princip) – kako se povećava udaljenost na koji se proizvod transportira, trošak po jedinici težine opada.

Transport zauzima najveći udio logističkih troškova, a samim time i troškova opskrbnog lanca. Na troškove transporta, a time i na cijelu transportne usluge utječu sljedeći čimbenici [21]:

1. **Udaljenost:** Troškovi obično rastu s povećanjem udaljenosti, uz fiksne troškove koji se ne mijenjaju s udaljenošću.
2. **Težina:** Veća težina pošiljke obično rezultira nižim troškovima po jedinici težine.
3. **Gustoća:** Proizvodi veće gustoće obično imaju niže troškove po jedinici težine.
4. **Mogućnost smještanja:** Veliki, nepravilno oblikovani ili iznimno veliki predmeti mogu povećati troškove prijevoza.
5. **Rukovanje:** Troškovi se povećavaju ako je potrebna posebna oprema za utovar i istovar, ili ako se roba mora posebno grupirati.
6. **Odgovornost:** Karakteristike proizvoda, kao i kvaliteta pakiranja, mogu utjecati na rizik oštećenja tijekom prijevoza.
7. **Tržište:** Neravnoteža na tržištu može uzrokovati prazne vožnje, što povećava troškove.

Na trošak transportne usluge utječe i izbor prometnog modaliteta. Osnovne transportne modalitete dijelimo na: cestovni, željeznički, vodni, cjevovodni i zračni. Pri donošenju odluke o vrsti transporta, menadžeri opskrbnog lanca moraju uzeti u obzir ravnotežu između troškova transporta i troškova skladištenja, kao i brzinu reakcije na potrebe kupaca.

3. METODE PROGNOZE POTRAŽNJE

Prognoza potražnje igra ključnu ulogu u upravljanju opskrbnim lancem i planiranju poslovnih aktivnosti. Pravilno predviđanje potražnje omogućava organizacijama da se pripreme za fluktuacije na tržištu, osiguraju dovoljne zalihe, optimiziraju proizvodnju i distribuciju, te bolje zadovolje potrebe svojih kupaca. Postizanje točnih prognoza potražnje može biti izazovno, ali postoje različite metode i tehnike koje pomažu u ovom procesu. U nastavku će se istražiti neke od metoda prognoze potražnje i njihova važnost za učinkovito upravljanje opskrbnim lancem.

3.1. Prognoza potražnje

Prognoza potražnje je tehnika za procjenu očekivane potražnje za proizvodom ili uslugom u budućnosti. Temelji se na analizi prošle potražnje za proizvodom ili uslugom u trenutnim uvjetima na tržištu. Prognoza potražnje treba biti znanstveno utemeljena, uzimajući u obzir sve relevantne činjenice i događaje povezane s predviđanjem [13].

Upravljanje tvrtkom zahtijeva prognozu budućih događaja, što omogućava planiranje aktivnosti unutar marketinga, prodaje, proizvodnje, nabave i potrošnje. Prognoza potražnje pruža dodatnu vrijednost tvrtki, iako je važno imati na umu da nijedna prognoza nije potpuno točna. Rizik i nesigurnost su inherentni u procesu prognoze i planiranja. Proces prognoze zahtijeva vještinu procjene u nepoznatim situacijama, ali je jednako važna i vještina izrade scenarija za različite ishode - kako za slučaj da se plan ostvari, tako i za slučaj da se ne ostvari [12].

Ova fleksibilnost omogućuje tvrtkama da se prilagode promjenama na tržištu i minimiziraju rizik od prekomjernih zaliha ili nestašica proizvoda.

Pri prognozi potražnje uzimaju se u obzir sljedeće varijable:

- a. Potražnja (količina, razina potražnje)
- b. Opskrba
- c. Značajke proizvoda
- d. Konkurencija.

3.1.1. Potražnja

Potrošači se pojavljuju na tržištu kako bi zadovoljili svoje potrebe za određenim dobrima. Kao kupci različitih dobara, mogu se javiti krajnji potrošači (pojedinci i kućanstva) kao i druga poduzeća, institucije, država i slično. Svi kupci koji se pojavljuju na tržištu, na bilo koji način, čine potražnju.

Potražnja je ekonomski pojam koji se odnosi na želju potrošača da kupi određeni proizvod ili uslugu te na njihovu spremnost da plate cijenu za tu robu ili uslugu. U kombinaciji s ponudom, potražnja određuje stvarnu cijenu proizvoda i količinu proizvoda dostupnih na tržištu. Odnos između cijene dobra i potražnje za tim dobrom opisan je zakonom potražnje, koji je jedan od temeljnih ekonomskih zakona. Prema zakonu potražnje, povećanje cijene određenog dobra rezultira smanjenjem potražnje za tim dobrom, dok pad cijene dovodi do povećanja potražnje za istim dobrima [14].

Promjena cijene određenog dobra ima utjecaj na potražnju, a taj utjecaj se mjeri cjenovnom elastičnošću potražnje. Cjenovna elastičnost potražnje odražava reakciju tražene količine dobra na promjenu njegove tržišne cijene, uz pretpostavku da su svi ostali faktori nepromijenjeni. Elastičnost potražnje pokazuje koliko će se potražnja za određenim dobrom promijeniti (u postotku) ako se njegova cijena promijeni za 1%. Cjenovna elastičnost potražnje obično je negativna jer povećanje cijene smanjuje interes kupaca - oni su spremni kupiti manje proizvoda. Formula za izračun cjenovne elastičnosti potražnje je [14]:

$$E_d = \frac{\text{promjena potražnje [\%]}}{\text{promjena cijene [\%]}} \quad (1)$$

Oznaka "Ed" označava koeficijent cjenovne elastičnosti potražnje. Na temelju vrijednosti tog koeficijenta mogu se donositi zaključci o tome kako će se potražnja mijenjati kada dođe do promjene cijene. Postoje različiti scenariji koji se mogu razmotriti [14]:

1. $E_d > 1$ - Potražnja je elastična, što znači da će promjena cijene za određeni postotak rezultirati većom promjenom potražnje. Na primjer, ako se cijena poveća za 8%, potražnja će se smanjiti za 12%.

2. $E_d=1$ - Jedinična potražnja; promjena cijene za određeni postotak rezultirat će promjenom potražnje za isti postotak. Na primjer, ako se cijena smanji za 12%, potražnja će se povećati za istih 12%.
3. $E_d<1$ - Potražnja je neelastična, što znači da će se potražnja smanjiti za manji postotak od promjene cijene. Na primjer, ako se cijena poveća za 10%, potražnja će se smanjiti za 7%.


Potražnja se najčešće mijenja kao rezultat promjena u cijeni proizvoda. Ostali čimbenici koji utječu na promjene u potražnji, a vezani su uz tržište, uključuju [15]:

1. Ukusi i sklonosti potrošača
2. Prihodi potrošača
3. Promjene u cijeni srodnih proizvoda
4. Trošak oglašavanja
5. Broj potrošača na tržištu
6. Očekivanja potrošača u vezi s budućim cijenama

Prognožiranje potražnje postaje posebno izazovno na tržištima bez praćenja podataka, te gdje se očekuju varijacije u narudžbama. U tim situacijama, teško je anticipirati potražnju i predvidjeti njezine fluktuacije.


Postoji pet osnovnih šablona potražnje (Slike 9, 10, 11) [16]:

1. Horizontalna
2. Trendovska
3. Sezonska
4. Ciklična
5. Nasumična




Slika 9 a) Horizontalna šablona potražnje, b) Trendovska šablona potražnje

Izvor: [16]



Slika 10 a) Sezonska šablona potražnje, b) Ciklična šablona potražnje,

Izvor: [16]



Slika 11 Nasumična šablona potražnje

Izvor: [16]

3.1.2. Opskrba

Opskrba kao segment prognoziranja potražnje utječe na prognozu putem nekoliko parametara, uključujući vrijeme potrebno za proizvodnju ili sastavljanje proizvoda, broj proizvođača i rokove isporuke. Općenito se može reći da kraći rokovi isporuke i veći broj proizvođača olakšavaju upravljanje i prognoziranje opskrbe, dok duži rokovi isporuke i manji broj proizvođača otežavaju upravljanje i prognoziranje opskrbe.

Prognoze za pojedini opskrbeni lanac pokrivaju vremenske intervale koji uključuju sve rokove potrebne za sklapanje pojedinog proizvoda [16].

3.1.3. Značajke proizvoda

Značajke proizvoda obuhvaćaju svojstva koja imaju utjecaj na potražnju, kao što je njihova sklonost modifikacijama i promjenama tijekom vremena.

Prognoze za poznate proizvode često obuhvaćaju dulje vremenske intervale u usporedbi s novim proizvodima. Također se nastoji predvidjeti u kojoj će mjeri novi proizvodi koji ulaze na tržište utjecati na smanjenje količine narudžbi. Dodatno se pokušava procijeniti koliko će se narudžbe smanjiti zbog uvođenja novih proizvoda na tržište [16].

3.1.4. Konkurencija

Konkurencija ima značajan utjecaj na predviđanje potražnje u kontekstu tržišnog poslovanja pojedine tvrtke, s obzirom na spoznaju o mogućnosti konkurencije da plasira proizvode po jeftinijim cijenama ili s boljim specifikacijama, što rezultira smanjenjem potražnje za određenim proizvodima. Stoga se javlja potreba za procjenom uloge tvrtke na tržištu.

Elementi koji se uzimaju u obzir kod procjene uloge tvrtke na tržištu su: [16]

1. Koliko je tržišni udio tvrtke
2. Koji je trend udjela tvrtke neovisno o trendu tržišta
3. Udio na tržištu može ovisiti o akcijama ili natjecanjima u cijeni, pa stoga treba uzeti u obzir i spomenute elemente.

3.2. Metode prognoze potražnje

Osnovna pretpostavka za uspješno prognoziranje jest kvalitetna i precizna baza podataka. Iako su tvrtke svjesne nesigurnosti potražnje kada prave prognozu, one ipak oblikuju svoje procese planiranja kao da je početna prognoza točan prikaz stvarnosti. Upravo te poteškoće u razumijevanju ekonomskih problema i nemogućnost postizanja apsolutno preciznih prognoza čine da ekonomija nije egzaktna znanost. U tom slučaju, treba biti svjestan sljedećih principa predviđanja [17][18]:

1. Predviđanje nikad nije točno.
2. Što je duži period prognoziranja, prognoza je lošija.
3. Agregatne (skupne) prognoze su točnije.

Prvi princip ukazuje na izazov usklađivanja ponude i potražnje. Drugi princip naglašava još veću težinu predviđanja potražnje kupaca za dugoročni period, poput razdoblja od 12 do 18 mjeseci. Treći princip predlaže, na primjer, dok je teško predvidjeti potražnju za jedan proizvod, lakše je predvidjeti potražnju za sve proizvode unutar jedne skupine proizvoda [21].

Na odluku o izboru metode koja će se upotrijebiti utječe više faktora [19]:

1. Primjenjivost podataka iz prošlosti,
2. Razdoblje na koje se odnosi prognoza,
3. Poželjan stupanj pouzdanosti prognoze,
4. Vrijeme raspoloživo za izradu prognoze,
5. Procjena odnosa troškova i koristi koji se očekuju od prognoze,
6. Dostupnost kvalificiranog kadra za izradu prognoze i dr.

Iako postoji mnogo različitih alata i metoda za predviđanje buduće potražnje, metode se mogu podijeliti u četiri osnovne skupine:

1. Kvalitativne metode uključuju prikupljanje stručnih mišljenja.
2. Uzročne metode su matematičke metode u kojima se prognoze generiraju na temelju različitih varijabli sustava.
3. Vremenske metode su matematičke metode u kojima se prognoza buduće potražnje temelji na povijesnim podacima.
4. Prognoze istraživanjem tržišta uključuju kvalitativne studije o ponašanju kupaca.

3.2.1. Kvalitativne metode

Osnova svih kvalitativnih metoda prognoziranja je uporaba eksperata u pripremanju prognoza. Različite tehnike predstavljaju samo alternativne procedure za pomoć ekspertima u izražavanju njihovih subjektivnih procjena budućnosti.

Angažiranje eksperata je veoma skupo, te se za primjenu kvalitativnih metoda prognoze mora unaprijed napraviti analiza troškova i koristi. U ovim metodama je čovjek, a ne matematički model, primarni korisnik podataka, znanja i informacija. To ne znači da se ekspert ne koristi kvantitativnim metodama, ali samo kao sredstvom kvalitativne prognoze.

Kvalitativne metode prognoziranja, u početnim fazama razvoja, primjenjive su na upravljačke probleme na razini poslovnih sustava. Različite problemske situacije zahtijevaju formiranje različitih ekspertnih timova. Moles govori o tri tipa heterogenih ekspertnih timova [17]:

1. Timovi koji se dopunjuju u tehničkim i prirodnim znanostima,
2. Timovi koji se dopunjuju u znanjima iz psihologije,
3. Timovi koji se dopunjuju u ostalim znanjima relevantnim za problem odlučivanja.

Zadatak eksperata za prognoziranje je da na osnovu ulaznih podataka, u pravilu vremenskih serija, predlože odgovarajuću prognostičku tehniku iz skupa kvalitativnih ili kvantitativnih metoda prognoziranja.

Postoje dvije vrste kvalitativnih metoda:

1. Ekspertne skupine
2. Delphi metoda

Ekspertne skupine se formiraju radi postizanja konsenzusa putem strukturirane komunikacije i razmjene informacija temeljem kojih se izrađuje prognoza. Ove skupine obuhvaćaju vanjske i interne stručnjake iz različitih funkcionalnih područja tvrtke [17].

Delphi metoda predstavlja strukturiranu tehniku koja ima za cilj postizanje zajedničkog zaključka bez fizičkog okupljanja stručnjaka na jednom mjestu. Ova tehnika je osmišljena kako bi se izbjegao utjecaj eksperata s većim autoritetom na zaključak. Stručnjaci sudjeluju putem

ispunjavanja standardiziranog upitnika, čime se prikupljaju informacije za daljnju analizu i zaključivanje. Postupak se ponavlja sve dok se ne postigne konsenzus [17].

3.2.2. Uzročne

Uzročne metode prognožiranja se temelje na povezivanju uzročnih faktora s posljedicama radi generiranja prognoza za ciljanu varijablu. Ove metode omogućuju predviđanje vrijednosti ciljne varijable koristeći informacije iz drugih relevantnih podataka. Primjerice, kada se želi prognozirati prodaja za sljedeću četvrtinu godine, mogu se koristiti faktori poput inflacije, bruto nacionalnog proizvoda (BNP), stope nezaposlenosti, vremenskih uvjeta ili bilo koje druge relevantne varijable, osim same prodaje za tu četvrtinu [16].


Ovaj pristup omogućuje analitičarima da identificiraju uzročne veze između različitih varijabli i koriste te veze kako bi generirali prognoze za ciljanu varijablu. Koristeći uzročne metode, analitičari mogu razumjeti kako promjene u uzročnim faktorima utječu na ciljanu varijablu i na temelju tih saznanja predvidjeti buduće vrijednosti.

3.2.3. Vremenske metode

Vremenske metode prognožiranja temelje se na pretpostavci da analiza povijesnih podataka, poput narudžbi tijekom određenog razdoblja pruža uvid u buduću potražnju. Ove metode se smatraju pouzdanim ako postoji dovoljna količina relevantnih podataka iz prošlosti i ako je tržište stabilno, bez značajnih oscilacija [16].

Osnovni pristup vremenskim metodama je analiza trendova, sezonalnosti i cikličnosti u povijesnim podacima kako bi se identificirali obrasci i strukture koji se mogu koristiti za prognožiranje budućih vrijednosti. Trendovi odražavaju dugoročne promjene u podacima, sezonalnost se odnosi na periodične fluktuacije koje se ponavljaju u određenim razdobljima, dok cikličnost obuhvaća dugoročne fluktuacije izvan sezonalnih obrazaca. Na Slici 12 prikazan je opći princip prognožiranja potražnje koji se sastoji od sljedećih koraka [20]:

1. Za vremenski niz podataka iz perioda A razvije se prognoza
2. Točnost prognoze testira se s podacima iz razdoblja B
3. U slučaju prihvatljive točnosti, prognoziraju se podaci za razdoblje C.



Slika 12 Opći princip prognoziranja koristeći vremenske nizove

Izvor: [20]

S aspekta korisnika, važno je istaknuti da su vremenske metode jeftine, zahtijevaju malo vremena i lako su razumljive. One su posebno povoljne za generiranje velikog broja prognoza, kao što je prognoziranje razina zaliha različitih proizvoda u skladištima.

Najčešće korištene vremenske metode su [16]:

1. Metoda pomičnih prosjeka
2. Metoda eksponencijalnog izgladivanja
3. Metode zasnovane na analizi trendova
4. Metode analize sezonskih podataka.

3.2.3.1. Metoda pomičnih prosjeka

Metoda pomičnih prosjeka je tehnika prognoziranja u kojoj se svaka prognoza dobiva kao prosjek određenog broja prethodnih točaka. Ključna odrednica ove metode je pravilan odabir broja točaka u pomičnom prosjeku kako bi se smanjile pogreške pri prognoziranju [16].

Ova metoda se koristi [16]:

1. kada je potražnja stabilna, tj. kada nema značajnih promjena u potražnji tijekom vremena,
2. nema trendova u potražnji, što znači da ne postoji dugoročno povećanje ili smanjenje potražnje,
3. nema periodičkih fluktuacija, odnosno kada nema redovitih ponavljanja obrazaca u potražnji.

Metodom pomičnih prosjeka potražnja se u traženom razdoblju računa na sljedeći način [16]:

$$MA_n = \frac{\sum_{i=1}^n D_i}{n} \quad (2)$$

Gdje je:

- n – broj razdoblja za koje se računa pomični prosjek
- D_i – potražnja u razdoblju i

Vrijednost parametra n u metodi pomičnih prosjeka ovisi o određenim elementima koji su ključni za pravilno modeliranje i prognoziranje potražnje. Prvo, važno je uzeti u obzir sposobnost modela da filtrira oscilacije u podacima kako bi se izbjegle pretjerane reakcije na potražnju koja značajno odstupa od prosjeka. Ovo je važno kako bi se izbjegle nepotrebne fluktuacije u prognozama uslijed privremenih odstupanja [16].

Drugo, važna karakteristika koja utječe na vrijednost parametra n je sposobnost modela da brzo reagira na promjene u potražnji, kao što su nagli porasti ili padovi očekivane potražnje. Pravilan odabir parametra n omogućuje modelu da bude osjetljiv na takve promjene i da ih uključi u prognoze, što je ključno za pravovremeno reagiranje na dinamično tržište [16].

Odabir velike vrijednosti parametra n u metodi pomičnih prosjeka rezultira jakom inercijom. U ovom slučaju, neka vrijednost potražnje koje je značajno iznad ili ispod prosjeka nema veliki utjecaj na ukupni ishod prognoze. Ovaj pristup zahtijeva više vremena da se model prilagodi značajnim promjenama u prosječnoj potražnji. Iako je precizan, model se sporije prilagođava promjenama u potražnji.

S druge strane, odabir manje vrijednosti parametra n u metodi pomičnih prosjeka rezultira većim utjecajem pojedinačnih vrijednosti potražnje na buduće prognoze. U ovom slučaju, model brzo reagira na promjene u potražnji, ali je vrlo osjetljiv u smislu preciznosti prognoze.

Postoje i težinski pomični prosjeci koji se baziraju na metodi pomičnih prosjeka, pri čemu svakom razdoblju u prošlosti dodjeljuju određeni težinski faktor. Težinski pomični prosjeci računaju se na sljedeći način [16]:

$$F_{t+1} = W_1D_1 + W_2D_2 + \dots + W_nD_{t-n} + 1 \quad (3)$$

Gdje je:

- F_{t+1} – prognoza za sljedeće razdoblje
- W – težinski koeficijent
- D – iznos potražnje u proteklom razdoblju

3.2.3.2. Metoda eksponencijalnog izgladivanja

Metoda eksponencijalnog izgladivanja temelji se na korištenju težinskog prosjeka prethodne prognoze i najnovije točke potražnje. Ova metoda je slična metodi pomičnih prosjeka, ali se razlikuje po tome što se koristi težinski prosjek svih prošlih točaka, pri čemu nedavne točke imaju veću težinu.

Za eksponencijalno izgladivanje potrebna su tri tipa podataka [16]:

1. Prognoza za prethodno razdoblje
2. Potražnja u tom razdoblju
3. Koeficijent izgladivanja, α (alfa), $0 \leq \alpha \leq 1$

Eksponencijalno izgladivanje računa se prema sljedećoj jednadžbi [21]:

$$F_{t+1} = \alpha D_t + (1 - \alpha)F_t \quad (4)$$

Ili

$$F_{t+1} = F_t + \alpha(D_t - F_t) \quad (5)$$

Parametar α u metodi eksponencijalnog izgladivanja određuje važnost koja se pridaje potražnji u određenom razdoblju. Promjenom vrijednosti parametra α može se prilagoditi utjecaj posljednjih razdoblja potražnje na rezultat prognoze. Veće vrijednosti parametra α naglašavaju veći utjecaj nedavnih razdoblja potražnje, što može rezultirati nestabilnijim prognozama. S druge strane, manje vrijednosti parametra α ravnomjernije tretiraju sva

razdoblja u potražnji, što dovodi do stabilnijih rezultata prognoze. Ova metoda je jednostavna za primjenu i zahtijeva minimalnu količinu podataka [16].

3.2.3.3. Metode zasnovane na analizi trendova

Metode pomičnih prosjeka i eksponencijalnog izgladivanja pretpostavljaju odsutnost trenda u podacima. Međutim, ako primijetimo prisutnost trenda, tada su metode temeljene na analizi trendova, kao što su regresijska analiza i Holtova metoda, korisnije. Ove metode omogućuju modeliranje i predviđanje trenda u podacima, što pruža bolju prognozu u situacijama kada trend igra važnu ulogu.

Holtova metoda uključuje utjecaj trenda u određenom razdoblju. Metoda se sastoji od dvije komponente [15]:

1. Eksponencijalno izgladljena komponenta (E_t) – konstanta izgladivanja $0 < w < 1$
 - a. Teži 0: veći značaj podacima iz daljih razdoblja promatranja
 - b. Teži 1: veći značaj podacima iz bližih razdoblja promatranja
2. Komponenta trenda (T_t) – konstanta izgladivanja $0 < v < 1$
 - a. Teži 0: veći značaj prošlom trendu
 - b. Teži 1: veći značaj sadašnjem trendu

Prilikom izračuna, prvo se odabire iznos konstanti w i v između 0 i 1. Nakon toga se računaju komponente E_t i T_t , prema zadanim podacima Y_t , počevši od razdoblja $t = 2$:

$$E_2 = Y_2; T_2 = Y_2 - Y_1 \quad (6)$$

$$E_3 = wY_3 + (1 - w)(E_2 + T_2) \quad (7)$$

$$T_3 = v(E_3 - E_2) + (1 - v)T_2 \quad (8)$$

$$E_t = wY_t + (1 - w)(E_{t-1} + T_{t-1}) \quad (9)$$

$$T_t = v(E_t - E_{t-1}) + (1 - v)T_{t-1} \quad (10)$$

Nakon izračuna komponenata E_t i T_t za svaku vrijednost Y_t korištenjem prethodnih izraza, računa se vrijednost prognoze za sljedeće razdoblje korištenjem izraza:

$$F_{t+1} = E_t + T_t \quad (11)$$

Te k-korak prognoze korištenjem izraza [21]:

$$F_{t+k} = E_t + kT_t \quad (12)$$

3.2.3.4. Metode analize sezonskih podataka

U analizi potražnje, mnoge tehnike imaju mogućnost detektirati i modelirati sezonske promjene. Na primjer, sezonska dekompozicija je tehnika koja uklanja uzorak sezonalnosti iz podataka kako bi se primijenile druge metode prognoziranja. Osim toga, postoji Winterova metoda koja predstavlja prilagođenu verziju eksponencijalnog izgladivanja koja uzima u obzir i trendove i sezonalnost. Ove metode omogućuju bolje razumijevanje sezonskih varijacija i pružaju preciznije prognoze u situacijama kada sezonalnost ima značajan utjecaj na potražnju [21].

3.2.4. Prognoze istraživanjem tržišta

Ispitivanje tržišta predstavlja vrijedan alat u procesu razvijanja prognoza, posebno za nove proizvode. Postoje dvije glavne metode istraživanja tržišta. Prva metoda uključuje ciljano davanje određenog proizvoda ili skupine proizvoda testnoj grupi potrošača. Nakon toga se analiziraju rezultati dobiveni iz tog testiranja, te se na temelju njih izrađuje prognoza potražnje. Druga metoda je provođenje anketa putem upitnika, gdje se podaci prikupljaju od potencijalnih kupaca. Ove ankete obično uključuju intervju, telefonske ili pisane upitnike. Oba pristupa omogućuju prikupljanje važnih informacija od ciljne publike, što omogućuje bolje razumijevanje potencijalne potražnje i uspješnije prognoziranje [21].

3.3. Mjere za točnost prognoze potražnje

Prilikom prognoziranja potražnje, važno je izdvojiti neizvjesnu komponentu potražnje od sistematske komponente kako bi se osigurala točnost prognoze i ocjena kretanja originalnog niza. Cilj je pronaći metodu prognoziranja koja minimizira pogrešku između prognoziranog i originalnog vremenskog niza, pružajući pouzdanu osnovu za planiranje i donošenje odluka. Visina pogreške, ili odstupanja, pruža signal menadžerima o primjerenosti korištene metode s obzirom na promjene u promatranom fenomenu [22].

Postoje različite mjere pogreške koje se mogu koristiti pri odabiru odgovarajuće metode prognoziranja potražnje, a dosadašnja istraživanja su izdvojila neke od njih:

1. Srednja pogreška (engl. Mean Error)

$$ME = \frac{1}{n} \sum_{t=1}^n e_t \quad (13)$$

2. Srednja apsolutna greška (engl. Mean Absolute Error)

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

3. Srednja kvadratna pogreška (engl. Root Mean Square Error)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (15)$$

4. Srednja postotna pogreška (engl. Mean Percentage Error)

$$MPE = \frac{1}{n} \sum_{t=1}^M \frac{e_t}{y_t} \quad (16)$$

5. Srednja apsolutna postotna pogreška (engl. Mean Absolute Percentage Error)

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

4. IZRAČUN BUDUĆE POTRAŽNJE PREMA POVIJESNIM PODACIMA

U suradnji s tvrtkom specijaliziranom za zdravu hranu i prirodne proizvode prikupljeni su podaci potrebni za provedbu metoda prognoze potražnje. Tvrtka posluje na području Republike Hrvatske brojeći ukupno 21 poslovnicu, a zbog zaštite podataka ime tvrtke će ostati anonimno.

Odabrana su dva proizvoda koja spadaju u robu široke potrošnje - bezglutenski kruh i kefir s 1,5% mm. Budući da pekarski i mliječni proizvodi čine osnovu prehrambene potrošnje većine ljudi, kupuju se bez obzira na gospodarske uvjete. Ipak, postoje čimbenici koji mogu utjecati na promjene u potražnji za odabranim proizvodima.

Za izračun potražnje koriste se stvarni povijesni podaci u periodu od 24 mjeseca, od siječnja 2021. do prosinca 2022.godine. Podaci o prodaji i cijeni proizvoda se koriste za provedbu metoda prognoze potražnje. Za svaki artikl je prikazana mjesečna prodaja koja je izražena u jediničnoj mjeri, a cijena je izražena u eurima.

Nakon što se odredi šablona potražnje za bezglutenski kruh i kefir s 1,5% mm, odabrat će se po dvije metode prognoze potražnje po proizvodu, što će rezultirati s ukupno četiri metode potražnje.

4.1. Osnove računanja metoda prognoze potražnje

U prethodnom poglavlju su predstavljene metode koje se koriste za prognozu potražnje. Kroz temeljitu analizu tih metoda proširilo se razumijevanje njihove primjenjivosti, kao i ograničenja.

Daljnje razumijevanje postupka prognoze uključuje poznavanje sljedećih pojmova:

1. Autokorelacija
2. Alati u Excelu

4.1.1. Autokorelacija

Autokorelacija u prognozi potražnje se odnosi na pojavu kada su vrijednosti potražnje u vremenskom nizu međusobno povezane ili kada postoji određen uzorak u odnosu na vremensku os. Drugim riječima, autokorelacija se odnosi na to kako su trenutne vrijednosti potražnje povezane s prethodnim vrijednostima u vremenskom slijedu. Postojanje autokorelacije može značiti da prethodne vrijednosti potražnje utječu na trenutne vrijednosti, što može biti od velikog značaja pri prognoziranju buduće potražnje. Ako se autokorelacija primijeti u vremenskom nizu potražnje, to može ukazivati na prisutnost sezonskih trendova, cikličkih uzoraka ili drugih redovitih fluktuacija u potražnji [23].

Vrijednosti autokorelacije kod vremenskih podataka mogu biti u rasponu od -1 do 1, gdje [24]:

1. Autokorelacija blizu -1 ukazuje na jaku negativu korelaciju između trenutne vrijednosti i prethodnih vrijednosti u vremenskom nizu. To znači da su prethodne vrijednosti u suprotnosti s trenutnom vrijednosti potražnje.
2. Autokorelacija blizu 0 ukazuje na vrlo slabu povezanost između trenutne vrijednosti i prethodnih vrijednosti u vremenskom nizu. To znači da trenutna vrijednost potražnje nije povezana s prethodnim vrijednostima.
3. Autokorelacija blizu 1 ukazuje na jaku pozitivnu korelaciju između trenutne vrijednosti i prethodnih vrijednosti u vremenskom nizu. To znači da trenutna vrijednost potražnje prati sličan uzorak kao i prethodne vrijednosti.

U Excelu se autokorelacija računa pomoću funkcije „CORREL“. Autokorelacija se izračunava za vremenske nizove, a funkcija „CORREL“ koristi se za izračunavanje korelacije između dva niza podataka. U slučaju autokorelacije, koristit će se isti niz podataka za oba argumenta funkcije.

U kontekstu autokorelacije, „lag“ se odnosi za broj vremenskih intervala za koje se prethodna vrijednost potražnje pomakne kako bi se usporedila s trenutnom vrijednosti potražnje. U osnovi, „lag“ predstavlja vremenski pomak između dvije uzastopne vrijednosti u vremenskom nizu podataka. Ako se utvrđuje autokorelacija s „lagom“ od jednog koraka, tada se uspoređuju T1 s T2, T2 s T3, T3 s T4, T4 s T5. S „lagom“ od dva koraka, uspoređuju se T1 s

T3, T2 s T4 i T3 s T5 i tako dalje (T predstavlja period). „Lag “ u podacima za prognozu potražnje se odnosi na pomaknutu verziju vremenskog niza potražnje. Kada želimo izračunati „lag“ u podacima, koristimo vrijednosti potražnje iz prethodnih razdoblja kako bismo ih pomaknuli prema naprijed ili unatrag u vremenskom slijedu [24].

Za izračun „lag-a“ za neko razdoblje unaprijed, koristi se funkcija [25]:

OFFSET(reference, redci, stupci)

Gdje je:

- Reference: ovo je početna ćelija u rasponu s kojim želite raditi. Funkcija će se temeljiti na ovoj ćeliji za pomjeranje.
- Rows: broj redova koje želite pomaknuti od referentne ćelije, Može biti pozitivan(gore) ili negativan (dolje).
- Cols: broj stupaca koje želite pomaknuti od referentne ćelije. Može biti pozitivan (desno) ili negativan (lijevo).

4.1.2. Alati u Excelu

U Excelu se pruža niz korisnih alata i funkcija za analizu, obradu podataka i prognozu.

Među ključnim alatima i funkcijama za prognozu potražnje su:

- Alat za rješavanje (Solver): Ovaj alat omogućuje optimizaciju vrijednosti ćelija uz zadane uvjete i ograničenja.
- Data Analysis: To je dodatak koji proširuje funkcionalnost Excela pružajući dodatne alate za analizu podataka, uključujući regresiju, analizu varijacije, korelaciju, i izradu histograma.

4.1.2.1. Alat za rješavanje (Solver)

Solver je dodatak u Microsoft Excelu koji omogućuje optimizaciju vrijednosti ćelija u radnom listu uz zadane uvjete. Koristi se za pronalaženje optimalnih vrijednosti varijabli koje će zadovoljiti određena ograničenja i ciljeve. U kontekstu prognoze potražnje, Solver se može koristiti za podešavanje parametara modela potražnje kako bi se postigla što preciznija prognoza [26].

U primjeru modela prognoze potražnje, kada postoji ovisnost o različitim čimbenicima kao što su cijene proizvoda, promotivne kampanje, sezonske promjene itd., Solver se može primijeniti za pronalazak optimalnih vrijednosti tih čimbenika koje će rezultirati najboljom prognozom potražnje. Alat Solver automatski će mijenjati varijable kako bi se minimizirala razlika između stvarnih i predviđenih vrijednosti potražnje, uzimajući u obzir zadane uvjete i ograničenja [26].

4.1.2.2. Analiza podataka (Data Analysis)

Data Analysis je skup alata i tehnika koje Excel nudi za analizu kompleksnih podataka i izradu statističkih modela. Može se koristiti za razumijevanje obrazaca, trendova i odnosa između različitih varijabli u skupu podataka. Data Analysis se može koristiti za korelaciju, deskriptivnu statistiku, eksponencijalno izgladivanje, histogram, generiranje slučajnih brojeva, regresiju i u mnoge druge svrhe. U kontekstu prognoze potražnje, Data Analysis se može koristiti za izradu vremenskih serija, identificiranje sezonskih uzoraka, provođenje regresijskih analiza i slično [27].

Primjerice, analiza vremenskih serija može pomoći u identificiranju sezonskih varijacija u prodaji proizvoda tijekom različitih mjesečnih perioda. Regresijska analiza može pomoći u određivanju koliko cijene proizvoda ili marketinške kampanje utječu na potražnju. Korištenjem različitih alata za analizu podataka, mogu se bolje razumjeti faktori koji utječu na potražnju i razvijati preciznije modele prognoze.

4.2. Odabir i provedba metoda prognoze potražnje – kefir s 1,5% m.m.

Prvi korak u procesu prognoziranja potražnje podrazumijeva sakupljanje stvarnih podataka o prodaji. Podaci se zatim unose u Excel tablicu (Slika 13) kao tri skupa informacija: period t, mjesec - godina i stvarna potražnja. Mjeseci od siječnja do prosinca za 2021. i 2022. godinu nalaze se u stupcu B, dok su mjesečni podaci o prodaji smješteni u stupcu C.

	A	B	C
1	period t	mjesec - godina	stvarna potražnja - Yt
2	1	siječanj-21	76
3	2	veljača-21	115
4	3	ožujak-21	160
5	4	travanj-21	191
6	5	svibanj-21	182
7	6	lipanj-21	175
8	7	srpanj-21	164
9	8	kolovoz-21	149
10	9	rujan-21	201
11	10	listopad-21	221
12	11	studenj-21	152
13	12	prosinac-21	210
14	13	siječanj-22	236
15	14	veljača-22	209
16	15	ožujak-22	283
17	16	travanj-22	290
18	17	svibanj-22	299
19	18	lipanj-22	287
20	19	srpanj-22	306
21	20	kolovoz-22	327
22	21	rujan-22	313
23	22	listopad-22	298
24	23	studenj-22	282
25	24	prosinac-22	315

Slika 13 Ulazni podaci za kefir

Zatim je potrebno odabrati odgovarajuću metodu prognoziranja, a njezin odabir ovisi o šablona potražnje za proizvodom. Identificiranje šablone često uključuje stvaranje grafa koji vizualizira podatke o prodaji. Graf omogućuje lakše uočavanje fluktuacija u prodaji tokom vremena, sezonskih trendova te mogućih obrazaca koji mogu ukazivati na odgovarajuću šablonu potražnje.



Slika 14 Podaci o potražnji za kefirom

Ponekad je prilikom analize grafa moguće identificirati različite šablone potražnje, kao što su horizontalna, sezonska, trendovska, ciklička ili nasumična potražnja. Slika 14 grafički prikazuje ulazne podatke za kefir s 1,5% mm.


Promatrajući graf, primjećuje se izražen i kontinuiran uspon količine prodaje tijekom vremena. Ovo je karakteristično obilježje pozitivnog trenda rasta. To znači da je potražnja za proizvodom postupno rasla kroz vrijeme. Graf pokazuje da proizvod ima stabilan i održiv rast potražnje, što je važna informacija za metodu prognoze potražnje. Na temelju ovog pozitivnog trenda, možemo pretpostaviti da će potražnja za proizvodom nastaviti rasti i u budućnosti, i to sa sličnim stopama kao što je to bio slučaj u prošlosti.

Sljedeći korak je izračun matrice autokorelacije za kefir. Na Slici X prikazan je postupak za izračun autokorelacije pomoću lagova. Korelacija se računala po formuli CORREL (niz 1, niz 2) u Excelu pri čemu su se dobile sljedeće vrijednosti lagova (Tablica 1 i Graf 1).

Tablica 1 Autokorelacija s lagovima za kefir s 1,5% m.m.

Period	Prodaja	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
1	76	0	0	0	0	0	0	0	0	0	0	0	0
2	115	76	0	0	0	0	0	0	0	0	0	0	0
3	160	115	76	0	0	0	0	0	0	0	0	0	0
4	191	160	115	76	0	0	0	0	0	0	0	0	0
5	182	191	160	115	76	0	0	0	0	0	0	0	0
6	175	182	191	160	115	76	0	0	0	0	0	0	0
7	164	175	182	191	160	115	76	0	0	0	0	0	0
8	149	164	175	182	191	160	115	76	0	0	0	0	0
9	201	149	164	175	182	191	160	115	76	0	0	0	0
10	221	201	149	164	175	182	191	160	115	76	0	0	0
11	152	221	201	149	164	175	182	191	160	115	76	0	0
12	210	152	221	201	149	164	175	182	191	160	115	76	0
13	236	210	152	221	201	149	164	175	182	191	160	115	76
14	209	236	210	152	221	201	149	164	175	182	191	160	115
15	283	209	236	210	152	221	201	149	164	175	182	191	160
16	290	283	209	236	210	152	221	201	149	164	175	182	191
17	299	290	283	209	236	210	152	221	201	149	164	175	182
18	287	299	290	283	209	236	210	152	221	201	149	164	175
19	306	287	299	290	283	209	236	210	152	221	201	149	164
20	327	306	287	299	290	283	209	236	210	152	221	201	149
21	313	327	306	287	299	290	283	209	236	210	152	221	201
22	298	313	327	306	287	299	290	283	209	236	210	152	221
23	282	298	313	327	306	287	299	290	283	209	236	210	152
24	315	282	298	313	327	306	287	299	290	283	209	236	210

Matrica autokorelacije	
Lag	Prodaja
Lag 1	0,91
Lag 2	0,87
Lag 3	0,87
Lag 4	0,82
Lag 5	0,81
Lag 6	0,82
Lag 7	0,81
Lag 8	0,82
Lag 9	0,83
Lag 10	0,84
Lag 11	0,89
Lag 12	0,89



Graf 1 Izračun matrice autokorelacije za kefir s 1,5% m.m.

Budući da graf pokazuje prisutnost trenda, za prognoziranje buduće potražnje koristit će se dvije metode koje su najprikladnije za analizu trendova: Holtova metoda i metoda linearne regresije.

4.2.1. Holtova metoda prognoze potražnje

Formule za izračun prognoze potražnje putem Holtove metode koriste se sljedeći koraci [21]:

1. Početne vrijednosti:

- Početna vrijednost izgladene komponente: $E_2 = Y_2$ (18)
- Početna vrijednost komponente trenda: $T_2 = Y_2 - Y_1$ (19)

2. Izračun vrijednosti za sljedeće periode:

- Izračun izgladene komponente: $E_3 = wY_3 + (1 - w)(E_2 + T_2)$ (20)

- Izračun komponente trenda: $T_3 = v(E_3 - E_2) + (1 - v)T_2$ (21)

3. Općenita formula za izračun izgladene komponente i komponente trenda:

- Izgladena komponenta za period t: $E_t = wY_t + (1 - w)(E_{t-1} + T_{t-1})$ (22)

- Komponenta trenda za period t: $T_t = v(E_t - E_{t-1}) + (1 - v)T_{t-1}$ (23)

Ovdje, w predstavlja faktor glatkoće ($0 \leq w \leq 1$), a v predstavlja faktor trenda ($0 \leq v \leq 1$). Ovi faktori su važni jer utječu na težinu koja se pridaje novim podacima i prijašnjim prognozama pri izračunu sljedeće prognoze [21].

Za faktor glatkoće odabrana je vrijednost 0,93, a za komponentu trenda ta vrijednost iznosi 0,26. Odabir faktora glatkoće od 0,93 donesen je s ciljem naglašavanja važnosti najnovijih podataka u analizi potražnje. Ovaj faktor je namjerno postavljen kako bi se bolje razumjelo kako potražnja reagira na inflaciju i rast cijena. Dakle, veća težina se pridaje najnovijim podacima kako bi se bolje uhvatio trenutni trend potražnje. Manji faktor trenda $v=0,26$ označava koliko se trenutni trend uvažava u modeliranju, manje reagira na trenutne promjene te se više oslanja na povijesne trendove.


Buduća potražnja se dobiva zbrajanjem komponenata E_t i T_t . Za prognozu će se računati $k=1,2,3$ pri čemu k predstavlja korak prognoze, a računa se po formuli [21]:

$$F_{t+k} = E_t + kT_t \quad (24)$$

U Tablici 2 su prikazani rezultati primjene Holtove metode s proizvoljno odabranim faktorom glatkoće i faktorom trenda. Prema izračunima, za nadolazeće mjesece očekuje se potražnja od 318 proizvoda u siječnju, 323 u veljači i 329 u ožujku. Ovi rezultati prognoze ukazuju na nastavak rastućeg trenda u budućim mjesecima. Graf 2 prikazuje prognoziranu potražnju za razdoblje od siječnja 2021. do ožujka 2023. godine.

Tablica 2 Izračun potražnje za kefirom s 1,5% m.m. Holtovom metodom

period t	mjesec - godina	stvarna potražnja - Y_t	eksponencijalna izgladnena komponenta - E_t	komponenta trenda - T_t	vrijednost prognoze potražnje za sjedeće razdoblje - F_{t+1}	pogreška	apsolutna pogreška	kvadratna pogreška	postotna pogreška	apsolutna postotna pogreška
1	siječanj-21	76	0,00							
2	veljača-21	115	115,00	39,00						
3	ožujak-21	160	159,58	40,45	154,00	6,00	6,00	36,00	0,04	0,04
4	travanj-21	191	191,63	38,27	200,03	-9,03	9,03	81,56	-0,05	0,05
5	svibanj-21	182	185,35	26,69	229,90	-47,90	47,90	2294,34	-0,26	0,26
6	lipanj-21	175	177,59	17,73	212,04	-37,04	37,04	1371,82	-0,21	0,21
7	srpanj-21	164	166,19	10,16	195,32	-31,32	31,32	981,07	-0,19	0,19
8	kolovoz-21	149	150,91	3,54	176,35	-27,35	27,35	747,92	-0,18	0,18
9	rujan-21	201	197,74	14,80	154,46	46,54	46,54	2166,23	0,23	0,23
10	listopad-21	221	220,41	16,84	212,54	8,46	8,46	71,59	0,04	0,04
11	studeni-21	152	157,97	-3,77	237,25	-85,25	85,25	7267,65	-0,56	0,56
12	prosinac-21	210	206,09	9,72	154,20	55,80	55,80	3114,00	0,27	0,27
13	siječanj-22	236	234,59	14,60	215,82	20,18	20,18	407,39	0,09	0,09
14	veljača-22	209	211,81	4,88	249,19	-40,19	40,19	1615,24	-0,19	0,19
15	ožujak-22	283	278,36	20,92	216,70	66,30	66,30	4395,92	0,23	0,23
16	travanj-22	290	290,65	18,67	299,28	-9,28	9,28	86,04	-0,03	0,03
17	svibanj-22	299	299,72	16,18	309,32	-10,32	10,32	106,57	-0,03	0,03
18	lipanj-22	287	289,02	9,19	315,90	-28,90	28,90	835,23	-0,10	0,10
19	srpanj-22	306	305,45	11,07	298,21	7,79	7,79	60,64	0,03	0,03
20	kolovoz-22	327	326,27	13,60	316,53	10,47	10,47	109,67	0,03	0,03
21	rujan-22	313	314,88	7,11	339,87	-26,87	26,87	722,09	-0,09	0,09
22	listopad-22	298	299,68	1,31	321,99	-23,99	23,99	575,44	-0,08	0,08
23	studeni-22	282	283,33	-3,28	300,99	-18,99	18,99	360,47	-0,07	0,07
24	prosinac-22	315	312,55	5,17	280,05	34,95	34,95	1221,85	0,11	0,11
25					317,72					
26					322,89					
27					328,06					
Σ						-139,92	652,93	28628,72	-0,99	3,11



Graf 2 Prognozirane vrijednosti potražnje za kefirom za siječanj, veljaču i ožujak 2023. Holtovom metodom

Faktor glatkoće i faktor trenda su prvobitno odabrani bez određenih kriterija. Međutim, kako bi se postigla bolja prilagodba modela stvarnim podacima, primijenjen je Solver. Solver je omogućio automatsko izračunavanje optimalnih vrijednosti za ova dva faktora.

Kroz korištenje Solvera, identificirane su optimizirane vrijednosti faktora glatkoće i faktora trenda. Tijekom ovog procesa, otkriveno je da je optimalna vrijednost faktora glatkoće 0,74, dok je optimalna vrijednost faktora trenda 0,26. Solver je smanjio faktor glatkoće sa početne vrijednosti od 0,93 na 0,74. Ovo znači da je manje naglašavao najnovije podatke u usporedbi s početnim proizvoljnim koeficijentom.

Rezultati prognoze prikazani su u Tablici 3, gdje se ističe da se u siječnju 2023. očekuje potražnja od 311 jedinica, u veljači 314 i u ožujku 317.

Tablica 3 Izračun potražnje za kefirom s 1,5% m.m. Holtovom metodom (Solver)

period t	mjesec - godina	skema potražnje - V_t	eksponencijalna izgladna komponenta - E_t	komponenta trenda - T_t	vrijednost prognoze potražnje za sljedeće razdoblje - F_{t+h}	pogreška	apsolutna pogreška	kvadratna pogreška	postotna pogreška	apsolutna postotna pogreška
1	siječanj 21	76	0,00							
2	veljača 21	115	115,00	39,00						
3	ožujak 21	160	158,45	40,15	154,00	6,00	6,00	36,00	0,04	0,04
4	travanj 21	191	192,96	38,69	198,60	-7,60	7,60	57,76	-0,04	0,04
5	svibanj 21	182	194,79	29,21	231,65	-49,65	49,65	2465,37	-0,27	0,27
6	lipanj 21	175	187,63	19,85	224,00	-49,00	49,00	2401,45	-0,28	0,28
7	srpanj 21	164	175,20	11,55	207,48	-43,48	43,48	1890,45	-0,27	0,27
8	kolovoz 21	149	158,73	4,34	186,75	-37,75	37,75	1425,25	-0,25	0,25
9	rujan 21	201	191,23	11,58	163,07	37,93	37,93	1438,88	0,19	0,19
10	listopad 21	221	216,31	15,06	202,81	18,19	18,19	330,80	0,08	0,08
11	studeni 21	152	172,45	-0,10	231,37	-79,37	79,37	6299,98	-0,52	0,52
12	prosinac 21	210	200,30	7,09	172,35	37,65	37,65	1417,53	0,18	0,18
13	siječanj 22	236	228,63	12,55	207,39	28,61	28,61	818,50	0,12	0,12
14	veljača 22	209	217,29	6,41	241,18	-32,18	32,18	1035,76	-0,15	0,15
15	ožujak 22	283	267,72	17,73	223,70	59,30	59,30	3516,52	0,21	0,21
16	travanj 22	290	288,83	18,60	285,45	4,55	4,55	20,66	0,02	0,02
17	svibanj 22	299	301,17	16,99	307,43	-8,43	8,43	71,06	-0,03	0,03
18	lipanj 22	287	295,03	11,04	318,16	-31,16	31,16	971,11	-0,11	0,11
19	srpanj 22	306	306,02	11,03	306,07	-0,07	0,07	0,00	0,00	0,00
20	kolovoz 22	327	324,44	12,93	317,04	9,96	9,96	99,12	0,03	0,03
21	rujan 22	313	319,28	8,28	337,36	-24,36	24,36	593,55	-0,08	0,08
22	listopad 22	298	305,61	2,63	327,55	-29,55	29,55	873,33	-0,10	0,10
23	studeni 22	282	288,76	-2,38	308,25	-26,25	26,25	688,82	-0,09	0,09
24	prosinac 22	315	307,63	3,08	286,38	28,62	28,62	819,02	0,09	0,09
25					310,71					
26					313,80					
27					316,88					
Σ						-188,07	649,67	27270,95	-1,24	3,15



Graf 3 Prognozirane vrijednosti potražnje za kefirom za siječanj, veljaču i ožujak 2023. Holtovom metodom (Solver)

4.2.2. Metoda linearne regresije

Model koji sadrži jednu zavisnu i jednu nezavisnu varijablu naziva se modelom linearne regresije. Analiza se provodi na osnovi stvarnih vrijednosti varijabli [28].

Metoda linearne regresije pronalazi linearnu funkciju (regresijski model) koja najbolje opisuje linearnu vezu između neovisne varijable x i zavisne varijable y . Kako su odnosi među pojavama statistički, treba odrediti kriterij prema kojemu će jednadžba pravca najbolje opisivati odnos varijabli na temelju njihovih opaženih vrijednosti [28].

Cilj je pronaći regresijsku liniju koja minimizira kvadratne udaljenosti između stvarnih y vrijednosti i predviđenih y vrijednosti na temelju x . Postupak omogućuje bolje razumijevanje utjecaja nezavisne varijable x na zavisnu varijablu y i omogućava prognoziranje y za određene x vrijednosti.

Formule za izračun linearne regresije [28]:

1. Izračun srednjih vrijednosti:

- $\bar{x} = \frac{\sum x_i}{n}$ (25) - Srednja vrijednost nezavisne varijable x
- $\bar{y} = \frac{\sum y_i}{n}$ (26) - Srednja vrijednost zavisne varijable y

2. Formule za izračun funkcije regresijskog modela:

- $\sum x_i y_i$ (27) - Suma produkata nezavisne i zavisne varijable
- $\sum x_i^2$ (28) - Suma kvadrata nezavisne varijable

3. Izračun parametara a i b :

- $b = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$ (29) - Koeficijent nagiba regresijske linije
- $a = \bar{y} - b \bar{x}$ (30) - Presjek regresijske linije s osi y

4. Izračun standardne devijacije i koeficijenta varijacije:

- y_i^2 (31) - Kvadrat pojedinačne zavisne varijable
- $y_i - \bar{y}$ (32) - Razlika između stvarne i predviđene vrijednosti y
- $SR = \sum (y_i - \bar{y})^2$ (33) - Suma kvadrata reziduala

5. Izračun standardne devijacije i koeficijenta varijacije:

- $\sigma_y = \sqrt{\frac{\sum (y_i - \bar{y})^2}{n}}$ (34) - Standardna devijacija reziduala
- $V_y = \frac{\sigma_y}{\bar{y}} \cdot 100$ (35) - Koeficijent varijacije zavisne varijable

6. Izračun koeficijenta determinacije:

- $R = \frac{n \sum xy - \sum x \sum y}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}}$ (36) - Koeficijent determinacije (R-squared)

Tablica 4 Izračun potražnje za kefirom s 1,5% m.m. metodom linearne regresije

	A	B	C	D	E	F	G	H	I	J
	period t	mjesec - godina	potražnja yi	cijena xi	$x_i \cdot y_i$	x_i^2	$\sum y_i$	$\sum (y_i - \bar{y})^2$	$\sum (y_i - \bar{y})^2$	$\sum y_i^2$
1										
2	1	srpanj-21	164	1,03	168,92	1,06	263,65	9930,72	7802,78	26896,00
3	2	kolovoz-21	149	0,92	137,08	0,85	235,98	7565,99	10677,78	22201,00
4	3	rujan-21	201	0,93	186,93	0,86	238,50	1406,12	2635,11	40401,00
5	4	listopad-21	221	0,97	214,37	0,94	248,56	759,56	981,78	48841,00
6	5	studenj-21	152	0,97	147,44	0,94	248,56	9323,86	10066,78	23104,00
7	6	prosinac-21	210	0,97	203,70	0,94	248,56	1486,88	1792,11	44100,00
8	7	siječanj-22	236	0,98	231,28	0,96	251,08	227,27	266,78	55696,00
9	8	veljača-22	209	0,96	200,64	0,92	246,04	1372,31	1877,78	43681,00
10	9	ožujak-22	283	0,86	243,38	0,74	220,89	3857,67	940,44	80089,00
11	10	travanj-22	290	0,98	284,20	0,96	251,08	1515,11	1418,78	84100,00
12	11	svibanj-22	299	0,98	293,02	0,96	251,08	2296,75	2177,78	89401,00
13	12	lipanj-22	287	0,98	281,26	0,96	251,08	1290,56	1201,78	82369,00
14	13	srpanj-22	306	0,98	299,88	0,96	251,08	3016,69	2880,11	93636,00
15	14	kolovoz-22	327	0,96	313,92	0,92	246,04	6553,77	5575,11	106929,00
16	15	rujan-22	313	0,97	303,61	0,94	248,56	4152,50	3680,44	97969,00
17	16	listopad-22	298	1,04	309,92	1,08	266,17	1013,25	2085,44	88804,00
18	17	studenj-22	282	1,12	315,84	1,25	286,29	18,42	880,11	79524,00
19	18	prosinac-22	315	1,13	355,95	1,28	288,81	686,03	3927,11	99225,00
20	Σ		4542	17,73	4491,34	17,53	4542,00	56473,46	60868,00	1206966,00

Pri računanju metode linearne regresije prikupljaju se ulazni podaci o potražnji y_i i cijeni x_i u određenom periodu t (od ćelije A1 do D1). Nakon toga potrebno je odrediti funkciju regresijskog modela koja glasi: $y=ax+b$. To je oblik linearne regresije gdje [28]:

- y predstavlja zavisnu varijablu koja se nastoji predvidjeti,
- x je nezavisna varijabla (ulazni podatak),
- a je koeficijent nagiba pravca koji određuje kut nagiba pravca,
- b je sjecište pravca s osi y tj. vrijednost y kada je $x=0$.

Kako bi se izračunala funkcija regresijskog modela treba izračunati koeficijente a i b . Za izračun koeficijenata a i b potrebno je izračunati srednje vrijednosti $\bar{x}$ i $\bar{y}$.

$$\bar{x} = \frac{\sum x_i}{n} = 0,99 ; \bar{y} = \frac{\sum y_i}{n} = 252,33$$

Nadalje se računa suma umnoška zavisne i nezavisne varijable (ćelija E20), te suma kvadrata nezavisne varijable (ćelija F20). Vrijednosti se unose u formulu za izračun:

$$n = 18$$

$$b = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} = 251,55 ; a = \bar{y} - b \bar{x} = 4,56$$

Iz toga slijedi da je funkcija regresijskog modela:

$$y = 4,56x + 251,55.$$

U sljedećem koraku treba se izračunati standardna devijacija i koeficijent varijacije prema formulama:

$$\sigma_y = \sqrt{\frac{\sum (y_i - \hat{y})^2}{n}} = 56,01$$

$$V_y = \frac{\sigma_y}{\bar{y}} \cdot 100 = 22\% > 10\% \text{ model nije reprezentativan}$$

Budući da je koeficijent varijacije veći od 10%, zaključuje se model nije reprezentativan te da ne postoji linearna veza između cijene i potražnje.

Metoda linearne regresije se u Excelu može provesti pomoću alata za analizu podataka. Nakon što su podaci o zavisnoj i nezavisnoj varijabli uneseni u ćelije C1 i D1 aktivira se alat za analizu podataka. Data Analysis se aktivira na sljedeći način: File(Datoteka) > Options (Opcije) > Add-Ins (Dodaci), označi se „Analysis ToolPak“.

Kada se otvori Data Analysis odabere se Regression i u dijaloškom okviru za regresiju se unese raspon zavisne varijable Y u polje „Input Y Range“, a raspon nezavisnih varijabli x u polje „Input X Range“.

Nakon toga Excel računa i prikazuje podatke regresije kao što je prikazano u Tablici 5.

Tablica 5 Rezultati regresije za kefir koristeći alat Data Analysis

29	SUMMARY OUTPUT								
30									
31	Regression Statistics								
32	Multiple R	0,364326354							
33	R Square	0,132733692							
34	Adjusted R Sq	0,074915938							
35	Standard Error	55,1504702							
36	Observations	17							
37									
38	ANOVA								
39		df	SS	MS	F	Significance F			
40	Regression	1	6982,619842	6982,619842	2,295725505	0,150517315			
41	Residual	15	45623,61545	3041,574363					
42	Total	16	52606,23529						
43									
44		Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%	Lower 95,0%	Upper 95,0%
45	Intercept	-58,88061528	209,2566769	-0,281379864	0,782263575	-504,9006641	387,1394335	-504,9006641	387,1394335
46	1,03	322,0940395	212,5801497	1,515165174	0,150517315	-131,0098239	775,1979029	-131,0098239	775,1979029

4.3. Odabir i provedba metoda prognoze potražnje – bezglutenski kruh

Kao i u prethodnim analizama prognoze potražnje, inicijalni korak prognoze potražnje za bezglutenskim kruhom je prikupljanje povijesnih podataka. Prikupljeni podaci su sistematično uneseni u Excel tablicu koja obuhvaća tri stupca, a to su stupac A s informacijama o vremenskom periodu (t), stupac B koji predstavlja mjesec i godinu, te stupac C sa zabilježenom stvarnom potražnjom za bezglutenskim kruhom. Prikupljeni podaci su prikazani u Tablici 6 koja će služiti kao temelj za daljnju analizu potražnje.

Tablica 6 Ulazni podaci za bezglutenski kruh

	A	B	C
1	period t	mjesec - godina	stvarna potražnja - Yt
2	1	siječanj-21	212
3	2	veljača-21	202
4	3	ožujak-21	198
5	4	travanj-21	183
6	5	svibanj-21	196
7	6	lipanj-21	135
8	7	srpanj-21	125
9	8	kolovoz-21	122
10	9	rujan-21	169
11	10	listopad-21	175
12	11	studenj-21	192
13	12	prosinac-21	229
14	13	siječanj-22	196
15	14	veljača-22	167
16	15	ožujak-22	164
17	16	travanj-22	160
18	17	svibanj-22	163
19	18	lipanj-22	134
20	19	srpanj-22	129
21	20	kolovoz-22	127
22	21	rujan-22	188
23	22	listopad-22	191
24	23	studenj-22	194
25	24	prosinac-22	215

Nakon što su prikupljeni podaci prikazani brojčano, korišteni su za izradu grafa potražnje za bezglutenskim kruhom. Iz tog grafa jasno se uočava da najviše potražnje dolazi tijekom zimskih mjeseci. Najveća zabilježena vrijednost potražnje u promatranim dvjema godinama iznosila je 229 u prosincu 2021. godine, dok je zatim slijedio prosinac 2022. s potražnjom od 215. Nasuprot tome, najniže vrijednosti potražnje zabilježene su tijekom srpnja i kolovoza. Konkretno, u srpnju 2021. godine potražnja je bila 125, dok je u istom mjesecu

2022. godine iznosila 129. U kolovozu 2022. godine potražnja je bila 122, dok je u istom mjesecu sljedeće godine iznosila 127. Sve relevantne informacije o potražnji za bezglutenskim kruhom su prikazane u Grafu 4.



Graf 4 Potražnja za bezglutenskim kruhom u 2021. i 2022. godini

Analiza sezonskih varijacija u potražnji za bezglutenskim kruhom sugerira da se potražnja mijenja ovisno o godišnjem dobu. Očigledno je da se minimalna potražnja ponavlja tijekom ljetnih mjeseci, dok se maksimalna potražnja javlja tijekom zime. Ova sezonska fluktuacija može biti povezana s prehrambenim navikama stanovništva.

Najviša potražnja za bezglutenskim kruhom tijekom zime, posebno u prosincu, može se objasniti blagdanskim razdobljima i proslavom Božića. Tijekom tih blagdana, kruh se često konzumira u većim količinama, što rezultira povećanom potražnjom. Također, drugi zimski mjeseci pokazuju povećanu potražnju, što se može povezati s prehrambenim navikama u hladnijim mjesecima. Ljudi često konzumiraju jela uz koja se tradicionalno jede kruh tijekom zime.

S druge strane, ljetni mjeseci karakteriziraju lakšu i svježiju prehranu, s većim unosom tekućine i voća, što rezultira smanjenom potražnjom za kruhom. Ova analiza prehrambenih navika u kontekstu sezonske potražnje za bezglutenskim kruhom može biti korisna za planiranje proizvodnje i zaliha kako bi se bolje zadovoljile potrebe tržišta tijekom različitih vremenskih razdoblja.



Graf 5 Usporedba potražnje za bezglutenskim kruhom 2021. i u 2022. godini

Uspoređujući potražnju u 2021. i 2022. godini (Graf 5), primjetno je da se potražnja u ovim godinama prati i ima sličan obrazac. Očigledno je da postoji veća potražnja u zimskim mjesecima i manja potražnja u ljetnim mjesecima. Ovaj konzistentan obrazac sugerira prisutnost sezonalnosti u potražnji za bezglutenskim kruhom.

Stoga će se koristiti Winterova metoda i sezonska dekompozicija kao ključni alati za prognozu i razumijevanje sezonskih varijanci u potražnji.

4.3.1. Winterova metoda

Winterova metoda analizira tri ključne komponente [21]:

1. Razina (L_t)
2. Trend (T_t)
3. Sezonalnost (S_t)

pridajući svakoj od tih komponenti određenu težinu.

Razina potražnje predstavlja temeljnu vrijednost serije i računa se prema sljedećoj formuli [21]:

$$L_t = \alpha \left(\frac{Y_t}{S_{t-p}} \right) + (1 - \alpha) L_{t-1} + T_{t-1} \quad (37)$$

Gdje su :

1. L_t - razina u trenutnom razdoblju t
2. Y_t - stvarna vrijednost u trenutnom razdoblju t
3. S_{t-p} - sezonski faktor koji se odnosi na isto razdoblje u prethodnoj godini
4. α - težinski koeficijent za razinu

Trend predstavlja promjenu u vremenskoj seriji i računa se prema sljedećoj formuli [21]:

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (38)$$

Gdje su:

- T_t - trend u trenutnom razdoblju t
- L_t - razina u trenutnom razdoblju t
- L_{t-1} - razina u prethodnom razdoblju $t-1$
- β - sezonski koeficijent za trend

Sezonalnost predstavlja periodičke fluktuacije u vremenskoj seriji i računa se prema sljedećoj formuli [21]:

$$S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma) * S_{t-p} \quad (39)$$

Gdje su:

- S_t - sezonalnost u trenutnom razdoblju t
- Y_t - stvarna vrijednost u trenutnom razdoblju t
- L_t - razina u trenutnom razdoblju t
- S_{t-p} - sezonski faktor koji se odnosi na isto razdoblje u prethodnoj godini
- γ - težinski koeficijent za sezonalnost

Odabran je period sezonalnosti (p) od 12 mjeseci s ciljem da se zabilježile godišnje fluktuacije u potražnji za bezglutenskim kruhom. Analiza se temelji na stvarnim podacima koji pokazuju da potražnja za bezglutenskim kruhom varira tijekom godine, s naglaskom na povećanju potražnje tijekom zimskih mjeseci i smanjenju tijekom ljetnih mjeseci.

Korištenjem perioda sezonalnosti od 12 mjeseci omogućuje se modelu da se adekvatno prilagodi dugoročnim trendovima. To znači da će model moći bolje procijeniti buduće vrijednosti potražnje tijekom cijele godine, uzimajući u obzir sezonske promjene.

Prvi korak u Winterovoj metodi uključuje izračun sezonalnosti za period od 12 mjeseci, što se primjenjuje na podatke od siječnja 2021. do prosinca 2021. godine. Izračun sezonalnosti za ovih 12 mjeseci provodi se pomoću Excela putem sljedeće formule:

$$S_p = \frac{Y_t}{AVERAGE(Y_1, Y_2, Y_3, \dots, Y_p)} \quad (40)$$

Gdje je:

- S_p je rezultat sezonske komponente za određeni trenutak t (t se može mijenjati od 1 do N , gdje je N ukupan broj promatranja)
- Y_t je promatrana vrijednost u trenutku t
- $AVERAGE(Y_1, Y_2, Y_3, \dots, Y_p)$ je prosjek promatranih vrijednosti u prethodnih p trenutaka

$$S_1 = \frac{Y_1}{AVERAGE(Y_1, Y_2, Y_3, \dots, Y_{12})} \quad (41)$$

Formula je primijenjena u Excelu u rasponu od ćelije G3 do G14, pri čemu su izračunate sezonalnosti za prvih 12 perioda, odnosno od siječnja 2021. do prosinca 2021. godine. Rezultati su prikazani u Tablici 7.

Tablica 7 Izračun potražnje za bezglutenskim kruhom Winterovom metodom

	B	C	D	E	F	G	H	I	J	K	L	M	N
	period t	mjesec - godina	stvarna potražnja - Y_t	level	trend	sezonálnost	vrijednost prognoze potražnje za sljedeće razdoblje - F_{t+1}		prognoka	apsolutna prognoka	koeficijenta prognoka	postotna prognoka	apsolutna postotna prognoka
2													
3	1	siječanj 21	212			1,19							
4	2	veljača 21	202			1,13							
5	3	ožujak 21	198			1,11							
6	4	travanj 21	183			1,03							
7	5	svibanj 21	196			1,10							
8	6	lipanj 21	135			0,76							
9	7	srpanj 21	125			0,70							
10	8	kolovoz 21	122			0,68							
11	9	rujan 21	169			0,95							
12	10	listopad 21	175			0,98							
13	11	studeni 21	192			1,08							
14	12	prosinac 21	229			1,29							
15	13	siječanj 22	196	164,72	-13,45	1,19							
16	14	veljača 22	167	148,69	-14,09	1,12	171,51		-4,51	4,51	20,33	-0,03	0,03
17	15	ožujak 22	164	143,03	-11,98	1,14	149,58		14,42	14,42	207,98	0,09	0,09
18	16	travanj 22	160	147,12	-7,97	1,08	134,60		25,40	25,40	645,09	0,16	0,16
19	17	svibanj 22	163	145,01	-6,50	1,12	153,08		9,92	9,92	98,37	0,06	0,06
20	18	lipanj 22	134	163,43	-0,27	0,82	104,95		29,05	29,05	843,69	0,22	0,22
21	19	srpanj 22	129	176,62	3,09	0,73	114,47		14,53	14,53	211,11	0,11	0,11
22	20	kolovoz 22	127	183,45	4,03	0,69	123,06		3,94	3,94	15,53	0,03	0,03
23	21	rujan 22	188	194,45	5,77	0,97	177,84		10,16	10,16	103,28	0,05	0,05
24	22	listopad 22	191	196,47	4,83	0,97	196,66		-5,66	5,66	32,02	-0,03	0,03
25	23	studeni 22	194	187,47	1,38	1,04	216,94		-22,94	22,94	526,08	-0,12	0,12
26	24	prosinac 22	215	174,82	-2,13	1,23	242,73		-27,73	27,73	768,83	-0,13	0,13
27	25						265,49						
28	26						191,86						
29	27						192,83						
									46,59	168,25	3472,31	0,42	1,03

Nakon što je izračunata sezonalnost za prvih 12 perioda, sljedeći korak u Winterovoj metodi je odabir ili procjena težinskih koeficijenata α , β i γ . Ovi koeficijenti određuju koliko će se svaka komponenta (sezonalnost, razina i trend) uzeti u obzir u prognozi.

Proizvoljno su odabrani sljedeće vrijednosti koeficijenata α , β i γ :

- Koeficijent $\alpha = 0,65$
- Koeficijent $\beta = 0,25$
- Koeficijent $\gamma = 0,95$

Ako je alfa blizu 1, tada se veća težina daje najnovijim podacima, što znači da će model brže reagirati na najnovije promjene. U ovom slučaju, alfa je 0,65 što znači da model pridaje umjerenu važnost najnovijim podacima, ali također uzima u obzir i povijesne podatke.


Niži beta znači da se manje težine daju trendu, sugerirajući da model manje reagira na dugoročne promjene. U ovom slučaju, beta je 0,25, što znači da model manje uzima u obzir trend u analizi.

Veći gama znači da model veću važnost pridaje sezonskoj komponenti. Vrijednost koeficijenta gama od 0,95 znači da model snažno uzima u obzir sezonalne fluktuacije.

Nakon što su dodijeljene vrijednosti koeficijenta, nastavlja se s izračunom vrijednosti trenda, razine i sezonalnosti. Kada su te komponente izračunate, dobiva se prognoza potražnje primjenom sljedeće formule, što predstavlja ključni korak u analizi [21]:

$$Y_t = (L_{t-1} + T_{t-1})S_{t-p} \quad (42)$$

Rezultati prognoze potražnje prikazani su u stupcu H Excel tablice, a grafički te podatke možemo prikazati Grafom 6 i 7.



Graf 6 Usporedba stvarne potražnje i prognozirane potražnje za bezglutenskim kruhom korištenjem Winterove metode



Graf 7 Prognozirane vrijednosti potražnje za bezglutenskim kruhom za siječanj, veljaču i ožujak 2023. Winterovom metodom

Bitno je napomenuti da nasumičan izbor početnih vrijednosti za koeficijente ne osigurava postizanje najboljih rezultata u analizi vremenskih serija. Zbog toga je korišten specijalizirani alat za optimizaciju unutar programa Excel kako bi se pronašle optimalne vrijednosti tih koeficijenata.


Nakon korištenja Excel alata Solver dobivene su optimalne vrijednosti koeficijenata:

- Koeficijent $\alpha = 0,71$
- Koeficijent $\beta = 1$
- Koeficijent $\gamma = 0,48$

Rezultati prognoze potražnje, dobiveni primjenom Solvera, prikazani su u Tablici 8. Kako bi se ovi rezultati bolje vizualizirali, prikazani su Grafovima 8 i 9 koji su povezani s tablicom kako bi se olakšalo razumijevanje analize.

Tablica 8 Izračun potražnje za bezglutenskim kruhom Winterovom metodom (Solver)

	B	C	D	E	F	G	H	I	J	K	L	M	N
	period t	mjesec - godina	stvarna potražnja - Y_t	level	trend	sezonálnost	vrijednost prognoze potražnje za sljedeće razdoblje - $\hat{Y}_{t+k}$		pogreška	apsolutna pogreška	kvadratna pogreška	postotna pogreška	apsolutna postotna pogreška
2													
3	1	siječanj 21	212			1,19							
4	2	veljača 21	202			1,13							
5	3	ožujak 21	198			1,11							
6	4	travanj 21	183			1,03							
7	5	svibanj 21	196			1,10							
8	6	lipanj 21	135			0,76							
9	7	srpanj 21	125			0,70							
10	8	kolovoz 21	122			0,68							
11	9	rujan 21	169			0,95							
12	10	listopad 21	175			0,98							
13	11	studeni 21	192			1,08							
14	12	prosinac 21	229			1,29							
15	13	siječanj 22	196	164,72	-13,45	1,19		Σ					
16	14	veljača 22	167	148,46	-16,26	1,13	171,51		-4,51	4,51	20,33	-0,03	0,03
17	15	ožujak 22	164	143,07	-5,39	1,13	146,92		17,08	17,08	291,81	0,10	0,10
18	16	travanj 22	160	150,48	7,41	1,04	141,42		18,58	18,58	345,24	0,12	0,12
19	17	svibanj 22	163	151,01	0,54	1,09	173,69		-10,69	10,69	114,22	-0,07	0,07
20	18	lipanj 22	134	169,44	18,43	0,77	134,83		19,17	19,17	367,46	0,14	0,14
21	19	srpanj 22	129	185,04	15,60	0,70	131,81		-2,81	2,81	7,88	-0,02	0,02
22	20	kolovoz 22	127	189,91	4,87	0,68	137,39		-10,39	10,39	107,89	-0,08	0,08
23	21	rujan 22	188	197,20	7,29	0,95	184,76		3,24	3,24	10,51	0,02	0,02
24	22	listopad 22	193	197,39	0,20	0,98	200,85		-9,85	9,85	97,02	-0,05	0,05
25	23	studeni 22	194	185,16	-12,23	1,06	212,93		-18,93	18,93	358,28	-0,10	0,10
26	24	prosinac 22	215	168,93	-16,23	1,28	222,28		-7,28	7,28	52,98	-0,03	0,03
27	25						181,70						
28	26						154,14						
29	27						135,84						
									-6,37	122,52	1773,61	0,00	0,76



Graf 8 Usporedba stvarne potražnje i prognozirane potražnje za bezglutenskim kruhom korištenjem Winterove metode (Solver)



Graf 9 Prognozirane vrijednosti potražnje za bezglutenskim kruhom za siječanj, veljaču i ožujak 2023. Winterovom metodom (Solver)

4.3.2. Sezonska dekompozicija

Metoda dekompozicije razdvaja potražnju na nekoliko osnovnih komponenata, uključujući [29]:

1. Sezonalnost
2. Trend
3. Ciklus
4. Slučajnosti

Prvi korak u metodi sezonske dekompozicije je izračunavanje pomičnog prosjeka koristeći korak $k=12$, što odgovara duljini sezonalnosti. Metodom pomičnog prosjeka, eliminira se komponenta sezonalnosti, kao i slučajnosti u potražnji. Pomični prosjek je izračunat i prikazan u stupcu F u Excelu (Tablica 9).

Tablica 9 Izračun potražnje za bezglutenskim kruhom metodom sezonske dekompozicije

	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
	period t	period sezonalnosti	mjesec - godina	stvarna potražnja - Y_t	Pomični prosjek (12)	S, R	Si	Ct	Tt	Pogreška potražnje		apsolutna pogreška	apsolutna pogreška	kvadratna pogreška	procentna pogreška	apsolutna pogreška
2																
3	1	1	siječanj 21	212			1,10	1,215	174,49	191,95		20,05	20,05	20,05	0,09	0,09
4	2	2	veljača 21	202			0,94	1,163	173,74	164,08		37,92	37,92	37,92	0,19	0,19
5	3	3	ožujak 21	198			0,94	1,145	172,99	163,13		34,87	34,87	34,87	0,18	0,18
6	4	4	travanj 21	183			0,94	1,092	172,24	161,09		21,91	21,91	21,91	0,12	0,12
7	5	5	svibanj 21	196			0,96	1,143	173,50	165,24		30,76	30,76	30,76	0,16	0,16
8	6	6	lipanj 21	195			0,83	0,791	170,75	157,49		-2,49	-2,49	2,49	-0,02	0,02
9	7	7	srpanj 21	125			0,78	0,735	170,00	131,84		-6,84	-6,84	6,84	-0,05	0,05
10	8	8	kolovoz 21	122			0,76	0,721	169,25	128,97		-6,97	-6,97	6,97	-0,06	0,06
11	9	9	rujan 21	180			1,13	1,003	168,51	189,60		-20,60	-20,60	20,60	-0,12	0,12
12	10	10	listopad 21	175			1,15	1,043	167,76	185,97		-14,97	-14,97	14,97	-0,09	0,09
13	11	11	studeni 21	192			1,14	1,150	167,01	190,59		1,41	1,41	1,41	0,01	0,01
14	12	12	prosinac 21	229			1,26	1,377	166,26	210,07		18,93	18,93	18,93	0,08	0,08
15	13	1	siječanj 22	196	176,17	1,10	1,10	1,184	165,52	182,07		13,53	13,53	13,53	0,07	0,07
16	14	2	veljača 22	187	176,83	0,94	0,94	1,014	164,77	154,86		12,12	12,12	12,12	0,07	0,07
17	15	3	ožujak 22	184	173,92	0,94	0,94	1,000	164,02	154,16		9,82	9,82	9,82	0,06	0,06
18	16	4	travanj 22	160	171,08	0,94	0,94	0,980	163,27	152,48		6,52	6,52	6,52	0,04	0,04
19	17	5	svibanj 22	163	169,17	0,96	0,96	1,003	162,52	156,02		6,98	6,98	6,98	0,04	0,04
20	18	6	lipanj 22	134	166,42	0,81	0,81	0,828	161,78	131,04		2,96	2,96	2,96	0,02	0,02
21	19	7	srpanj 22	129	166,33	0,78	0,78	0,801	161,03	125,60		3,40	3,40	3,40	0,03	0,03
22	20	8	kolovoz 22	127	166,67	0,76	0,76	0,792	160,28	121,81		5,19	5,19	5,19	0,04	0,04
23	21	9	rujan 22	188	167,08	1,13	1,13	1,178	159,53	180,27		7,73	7,73	7,73	0,04	0,04
24	22	10	listopad 22	193	168,67	1,13	1,13	1,203	158,78	179,43		11,57	11,57	11,57	0,06	0,06
25	23	11	studeni 22	194	170,00	1,14	1,14	1,228	158,04	180,16		13,84	13,84	13,84	0,07	0,07
26	24	12	prosinac 22	215	170,17	1,26	1,26	1,367	157,29	198,19		16,81	16,81	16,81	0,08	0,08
27	25	1	siječanj 23		169,00	0,00	1,26	0,000	156,54	197,24						
28												166,88	270,63	270,63	0,83	1,51
29																

Uklanjanje sezonalnosti i slučajnosti se postiže dijeljenjem stvarne potražnje sa potražnjom koja je izračunata primjenom metode pomičnih prosjeka [29]:

$$S_t, R_t = \frac{Y_t}{PP} \quad (43)$$

Gdje je:

- S_t, R_t – sezonalnost, slučajnost
- Y_t – potražnja
- PP – pomični prosjek

Potražnja koja se izračunava pomoću metode pomičnih prosjeka predstavlja osnovu za daljnju analizu sezonalnosti. Sljedeći korak u postupku je izračunavanje sezonalnih indeksa za svih 12 mjeseci. S obzirom na ponavljanje ciklusa svakih 12 mjeseci, potrebno je utvrditi 12 sezonalnih indeksa.

Sezonalni indeksi, označeni kao S, dobivaju se tako da se za svaki od 12 mjeseci uzme prosjek potražnje izračunate metodom pomičnih prosjeka za isti mjesec tijekom promatranog razdoblja. Na primjer, ako se analizira razdoblje od 24 mjeseca, od siječnja 2021. do prosinca

2022. godine, sezonalni indeks S1 dobiva se izračunavanjem prosjeka potražnje za svaki siječanj u tom razdoblju.

Na primjeru bezglutenskog kruha se ciklus sezonalnosti ponavlja svakih 12 mjeseci, pa će sezonalni indeksi će biti isti kao i potražnja koja je izračunata metodom pomičnih prosjeka. Važno je napomenuti da zbog promatranog razdoblja od 24 mjeseca nije moguće izračunati prosjek potražnje (dobiven metodom pomičnih prosjeka) za dva ili više mjeseci s istim imenom, kao što su siječanj (2021. i 2022.), veljača (2021. i 2022.) i drugi. Indeksi sezonalnosti u Excel tablici su prikazani u stupcu G.

Sljedeći korak je određivanje prisutnosti trenda, ako postoji. Za izračunavanje trenda se primjenjuje jednostavna linearna regresija prema sljedećoj formuli [29]:

$$Y = a + bX \quad (44)$$

Odnosno, u ovom slučaju:

$$PP = a + bt \quad (45)$$

Gdje je:

- a – konstantni član
- b – regresijski koeficijent

Za izračun linearne regresije korišten je Excel alat "Data Analysis, Regression". U ovom slučaju, zavisna varijabla je pomični prosjek, dok je nezavisna varijabla razdoblje (period t). Rezultati su dobiveni u obliku "Summary Output" i prikazani su u Tablici 10 [29].

Tablica 10 Rezultati regresije za bezglutenski kruh koristeći alat Data Analysis

SUMMARY OUTPUT									
Regression Statistics									
Multiple R	0,672759504								
R Square	0,452605351								
Adjusted R Square	0,397865886								
Standard Error	3,109337205								
Observations	12								
ANOVA									
	df	SS	MS	F	Significance F				
Regression	1	79,938277	79,938277	8,26835541	0,016513077				
Residual	10	96,67977855	9,667977855						
Total	11	176,6180556							
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%	Lower 95,0%	Upper 95,0%	
a= Intercept	175,2348485	1,913664763	91,57029585	5,90448E-16	170,9709377	179,4987593	170,9709377	179,4987593	
b= X Variable 1	-0,747668998	0,260015839	-2,875474815	0,016513077	-1,327020392	-0,168317604	-1,327020392	-0,168317604	

Korištenjem alata "Data Analysis" i regresije dobiveni su podaci potrebni za daljnje izračune, a to su Intercept (konstantni član, oznaka "a") i X Variable (regresijski koeficijent, oznaka "b"). Sada se, s obzirom na definirane vrijednosti "a" i "b", može izračunati trend.

Trend se računa prema sljedećoj formuli, a rezultat je vidljiv u stupcu J u Tablici 9 [29]:

$$Tt = a + bt$$


Sljedeća komponenta koja se računa je ciklus. Ciklus C_t se računa prema sljedećoj formuli [29]:

$$C_t = \frac{M_t}{T_t}$$

Posljednja komponenta, slučajnost R_t se računa prema formuli [29]:

$$R_t = \frac{S}{S_t}$$

Prognoza se dobiva umnoškom svih komponenata. Rezultati prognoze potražnje prikazani su u Tablici 9 u stupcu K, a usporedba stvarne potražnje i prognozirane potražnje je prikazana Grafiom 10.



Graf 10 Usporedba stvarne potražnje i prognozirane potražnje za bezglutenskim kruhom korištenjem metode sezonske dekompozicije



Graf 11 Prognozirane vrijednosti potražnje za bezglutenskim kruhom za siječanj 2023. metodom sezonske dekompozicije

5. PRIKAZ I USPOREDBA TOČNOSTI METODA PROGNOZE POTRAŽNJE

U ovom poglavlju će se provesti analiza i usporedba različitih metoda prognoze potražnje kako bi se ocijenila njihova preciznost i učinkovitost. Ovaj pregled će pomoći u razumijevanju koje metode pružaju najbolje rezultate u predviđanju buduće potražnje za proizvodima ili uslugama, te kako te informacije mogu pridonijeti poboljšanju upravljanja opskrbnim lancem i planiranju poslovnih aktivnosti.

5.1. Metode prognoze potražnje za kefir s 1,5% m.m.

Za proizvod kefir s 1,5% m.m. korištene su sljedeće metode:

- Holtova metoda
- Metoda linearne regresije

Prva metoda koja je primijenjena za prognozu potražnje kefira je Holtova metoda. Holtova metoda je primijenjena na dva načina - prvi put s proizvoljnim koeficijentima, a zatim uz korištenje Excel alata Solver. Koeficijenti koji su korišteni u analizi su sljedeći:


- Prije primjene Solvera: $w = 0,93$; $v = 0,26$
- Nakon primjene Solvera: $w = 0,74$; $v = 0,26$

Tablica 11 Prikaz točnosti izračuna Holtove metode za kefir

Mjere za točnost	Holt	Holt (Solver)
ME	-139,92	-188,07
MAE	652,93	649,67
RMSE	36,07	35,21
MPE	-0,99	-1,24
MAPE	3,11	3,15


U Tablici 11 prikazane su mjere točnosti za provedene Holtove metode. Holtova metoda (Solver) pokazuje manju prosječnu pogrešku (-188,07) u usporedbi s klasičnom Holtovom metodom (-139,92), što sugerira da Holtova metoda sa Solverom može bolje

predvidjeti stvarne vrijednosti. Primjena Solvera je u ovom slučaju poboljšala učinkovitost Holtove metode. To se odražava u manjim apsolutnim i postotnim pogreškama, kao i manjim RMSE.



Graf 12 Grafički prikaz točnosti izračuna Holtove metode za kefir

Ocjena temeljena na analizi mjera ukazuje da je Holtova metoda s primjenom Solvera bolji izbor za predviđanje u ovoj specifičnoj situaciji, jer ima bolju preciznost u usporedbi s klasičnom Holtovom metodom. Unatoč tome, razlika u RMSE između Holtove metode s proizvoljnim koeficijentima i Holtove metode s Solverom je mala, što sugerira da Solver nije značajno utjecao na preciznost Holtove metode u ovoj analizi.



Graf 13 Grafički prikaz potražnje i prognoza potražnje (Holtova metoda) za kefir

Kada je riječ o modelu linearne regresije, usporedba s Holtovom metodom nije izvediva. U modelu linearne regresije, koeficijent varijacije premašuje 10%, konkretno iznosi 22%. Ova visoka vrijednost koeficijenta varijacije sugerira da model nije reprezentativan za analizirani skup podataka i jasno ukazuje na nedostatak linearnog odnosa između cijene i potražnje za proizvodom.


5.2. Metode prognoze potražnje za bezglutenski kruh

Za prognozu potražnje bezglutenskog kruha korištene su dvije metode nakon pretpostavljene sezonalnosti u potražnji, a te metode su:

- Winterova metoda
- Sezonska dekompozicija

Prva metoda koja je primijenjena za analizu potražnje za bezglutenskim kruhom je Winterova metoda. Winterova metoda je primijenjena na dva načina - prvi put s proizvoljnim koeficijentima, a zatim koristeći Excel alat Solver. Koeficijenti koji su korišteni u analizi su sljedeći:

- Prije primjene Solvera: $\alpha = 0,65, \beta = 0,25, \gamma = 0,95$
- Nakon primjene Solvera: $\alpha = 0,71, \beta = 1, \gamma = 0,48$




Graf 14 Grafički prikaz potražnje i prognoza potražnje (Winterova metoda) za bezglutenski kruh

Tablica 12 Prikaz točnosti izračuna Winterove metode za bezglutenski kruh

Mjere za točnost	Winter	Winter (Solver)
ME	46,59	-6,37
MAE	168,25	122,52
RMSE	17,77	12,7
MPE	0,42	0
MAPE	1,03	0,76


Winterova metoda (Solver) pokazuje negativnu srednju pogrešku (-6,37), što sugerira prosječno podcjenjivanje stvarne vrijednosti, dok Winterova metoda ima pozitivnu srednju pogrešku (46,59), što ukazuje na prosječno precjenjivanje stvarnih vrijednosti. U pogledu srednje apsolutne pogreške (MAE), manja vrijednost (122,52) sugerira bolju preciznost u predviđanjima. To implicira da je Winterova metoda (Solver) preferirano rješenje u usporedbi s Winterovom metodom bez Solvera. Analizom korijena srednje kvadratne pogreške (RMSE) vidimo da je primjena Solvera značajno poboljšala točnost prognoze za 39,92%.



Graf 15 Grafički prikaz točnosti izračuna Winterove metode za bezglutenski kruh

Druga metoda koja je korištena za prognozu potražnje bezglutenskog kruha je sezonska dekompozicija. U prethodnom poglavlju je uz izračun i postupak objašnjeno pod kojim pretpostavkama je odabrana ova metoda.

Pri usporedbi Winterove metode sa i bez alata Solver, došli smo do zaključka je da je upotreba Solvera pouzdanija i da rezultati metode uz korištenje Solvera imaju veću preciznost. Stoga ćemo nadalje uspoređivati Winterovu metodu (Solver) i metodu sezonske dekompozicije. Na Grafu 16 prikazana je stvarna potražnja i vrijednosti prognozirane potražnje Winterovom metodom i metodom sezonske dekompozicije.



Graf 16 Grafički prikaz stvarne potražnje, prognoze potražnje Winterove metode i metode sezonske dekompozicije za bezglutenskim kruhom


Na Grafu 16 se uočava da vrijednosti sezonske dekompozicije bolje prate liniju stvarne potražnje, naročito u 18 periodu kada je Winterovom metodom prognozirano 29 proizvoda manje nego što je bila stvarna potražnja. Tablica 13 prikazuje razinu pogreške za obje analize.

Tablica 13 Prikaz točnosti izračuna Winterove metode, Winter (Solver) i sezonske dekompozicije za bezglutenski kruh

Mjere za točnost	Winter	Winter (Solver)	Sezonska dekompozicija
ME	46,59	-6,37	166,88
MAE	168,25	122,52	270,63
RMSE	17,77	12,7	3,36
MPE	0,42	0	0,83
MAPE	1,03	0,76	1,51

Winter (Solver) ima negativnu ME (-6,37) što ukazuje na tendenciju da podcjenjuje stvarne vrijednosti, dok sezonska dekompozicija ima pozitivnu ME (166,88) što znači da precjenjuje stvarne vrijednosti. Sezonska dekompozicija ima značajno manji RMSE u usporedbi s Winter Solverom. To znači da je sezonska dekompozicija bolja u minimiziranju većih grešaka u predviđanjima, što može biti važno u slučajevima gdje su velike greške neprihvatljive.

MPE mjera predstavlja prosječnu postotnu grešku. Winter (Solver) ima MPE vrijednost od 0, što znači da njegova predviđanja imaju tendenciju biti vrlo blizu stvarnim vrijednostima. Sezonska dekompozicija ima MPE vrijednost od 0,83, što ukazuje na veću postotnu grešku u predviđanjima.



Graf 17 Graf 15 Grafički prikaz točnosti izračuna Winterove metode (Solver) i sezone dekompozicije za bezglutenski kruh

Ako se izabere Winterova metoda koja ukazuje na tendenciju podcjenjivanja stvarnih vrijednosti, potrebno je povećati razinu sigurnosnih zaliha kako bi se smanjili potencijalni nedostaci zaliha. Time će se izbjeći situacije u kojima nema dovoljno proizvoda, a potražnja će biti zadovoljena.

S obzirom na visoku ME vrijednost za sezonsku dekompoziciju, koja ukazuje na tendenciju precjenjivanja stvarnih vrijednosti, potrebno je dublje proučiti sezonske obrasce i prilagoditi planiranje zaliha kako bi bolje odgovarala tim obrascima. To može uključivati prilagodbu narudžbenica ili promjenu vremena isporuke kako biste bolje pratili potrebe sezonskog tržišta.

Općenito, Winter (Solver) se čini boljim za minimiziranje apsolutnih i postotnih pogrešaka u predviđanjima, dok sezonska dekompozicija ima niži RMSE. Izbor između ova dva modela će ovisiti o specifičnim ciljevima tvrtke.

6. ZAKLJUČAK

Današnje dinamično poslovno okruženje značajno utječe na planiranje opskrbnih lanaca. Globalizacija je proširila područje poslovanja na međunarodnu i globalnu razinu, što je donijelo nove izazove u upravljanju opskrbnim lancima. To znači da su dobavljači, proizvodne lokacije i tržišta sve više razasuti diljem svijeta, stvarajući veću kompleksnost i rizik u procesima.

Osim globalizacije, logistika se suočava s izazovom kompleksnosti proizvoda. Proizvodi postaju sve složeniji s raznim varijacijama i prilagodbama prema željama kupaca. Također, njihov životni vijek postaje kraći, a potražnja se brzo mijenja, osobito u doba interneta i e-trgovine. Upravljanje ovim promjenama zahtijeva brze i precizne prilagodbe unutar opskrbnog lanca.

Iz tih razloga planiranje prognoze potražnje postaje izazovno. Da bi planiranje potražnje bilo što točnije, a zahtjevi kupaca zadovoljeni, mogu se poboljšati različiti elementi, a oni uključuju osoblje i edukaciju. Osobe zadužene za prognoziranje potražnje trebaju imati duboko razumijevanje tržišta, konkurencije i faktora koji utječu na potražnju. Praćenje trendova, promocija i sezonskih varijacija može pomoći u preciznijim prognozama. Isto tako, korištenje naprednih analitičkih alata uključujući algoritme strojnog učenja i statističke metode mogu otkriti uzorke i trendove koji mogu promaknuti ljudskom oku.

U praktičnom dijelu ovoga rada, izračunate su prognoze potražnje za dva proizvoda široke potrošnje – kefir s 1,5% m.m. i bezglutenski kruh. Prvo i osnovno, prikupljeni su kvalitetni podaci o potražnji u prošlosti i njihovim cijenama. U suradnji s odjelom nabave omogućeno je shvaćanje neočekivanih promjena u potražnji, koje su uzrokovane popustima.

U procesu prognoze potražnje za kefirom, analizirane su dvije različite metode prognoze. Kefir je prema svojim povijesnim podacima pokazao trendovsku šablonu potražnje. Unazad dvije godine, u 2021. i 2022. godini, vidljiv je pozitivan trend u potražnji za kefirom. S obzirom na trendovsku šablonu, korištene su metode adekvatne za trend, a to su Holtova metoda i metoda linearne regresije.

Također, bezglutenski kruh je pokazao sezonsku šablonu potražnje. Njegova sezonalnost vidljiva je u zimskom periodu, naročito u prosincu i siječnju kada su zabilježene

najveće vrijednosti potražnje. Povećana potražnja u tim mjesecima može se pripisati blagdanskom razdoblju i proslavi blagdana Božića. Isto tako, zimi su prehrambene navike stanovništva usmjerene na tradicionalna jela i variva koja često uključuju konzumaciju kruha. Druga veća oscilacija u potražnji je u ljetnim mjesecima, kada je najmanja potražnja za kruhom, a takva potražnja se može pripisati visokim temperaturama i konzumaciji lakše hrane.

Analizom točnosti metoda, primijećeno je da Excel alat Solver ima veliki značaj u prognoziranju. Korištenjem alata Solver, skraćeno je vrijeme traženja optimalnih koeficijenata za Holtovu metodu – kefir i za Winterovu metodu – bezglutenski kruh. U slučaju kefira, Holtova metoda s upotrebom Solvera se pokazala kao najbolja solucija. Metoda linearne regresije zbog prevelike vrijednosti koeficijenta varijacije nije bila reprezentativna te se u metodi nije mogla pronaći veza između potražnje i cijene proizvoda. Za bezglutenski kruh je Winterova metoda sa Solverom dala bolje rezultate od Winterove metode s proizvoljnim koeficijentima. Ali u odnosu sa sezonskom dekompozicijom, nije lako odrediti koja metoda prognoze potražnje je bolja. Sezonska dekompozicija ukazuje na tendenciju precjenjivanja stvarnih vrijednosti što može značiti stvaranje viška zaliha, dok Winterova metoda sa Solverom ima tendenciju podcjenjivanja što dovodi do nedovoljno zaliha i smanjenja zadovoljstva kupaca.

Važno je napomenuti da nijedna metoda prognoze nije uvijek savršeno precizna. Na kraju, tvrtka treba pažljivo odabrati metodu prognoze potražnje temeljem svojih specifičnih ciljeva i potreba.

LITERATURA

- [1] Rushton, A., Croucher, P., Baker, P.: The Handbook of Logistics and Distribution Management, The Chartered Institute of Logistics and Transport, London, UK, 2010.
- [2] Waters, D.: Logistics-an Introduction to Supply chain Management, Palgrave Mac Millan, New York, 2003
- [3] Creative portal. Preuzeto sa: <https://www.creativesafetysupply.com/articles/supply-chain-integration/> [Pristupljeno: svibanj 2023.]
- [4] Rogić, K., Stanković, R., Šafran, M., Upravljanje logističkim procesima, Velika Gorica, Veleučilište Velika Gorica, 2012. [Pristupljeno: svibanj 2023.]
- [5] Ivaković, Č.; Stanković, R.; Šafran, M.: Špedicija i logistički procesi, Fakultet prometnih znanosti, Zagreb, 2010, op.cit, str.295.
- [6] <https://repozitorij.unin.hr/islandora/object/unin%3A1472/datastream/PDF/view>
- [7] Siročić, A. (2017.) Temeljni procesi u sustavu nabave. Završni rad. Sveučilište Sjever. Preuzeto sa: https://hrcak.srce.hr/upute/upute_reference_Pannoniana.pdf [Pristupljeno: svibanj 2023.]
- [8] Šafran M. (2021.) Osnove upravljanja zalihama. Zagreb, Sveučilište u Zagrebu, Fakultet prometnih znanosti.
- [9] Miloš, I.; Unutrašnji transport i skladištenje, autorizirana predavanja kolegija "Unutrašnji transport i skladištenje", Veleučilište u Rijeci, Rijeka, 2003.
- [10] Stojanović L. (2016.) Unutrašnji transport i skladištenje. Završni rad. Sveučilište Sjever. Preuzeto sa: <https://zir.nsk.hr/islandora/object/unin:1033/preview> [Pristupljeno: svibanj 2023.]
- [11] Štimac H. (2016.) Prezentacija. Načini transporta. Preuzeto sa: <http://www.efos.unios.hr/upravljanje-marketingom/wp-content/uploads/sites/431/2013/04/3.-predavanje.pdf> [Pristupljeno: svibanj 2023.]
- [12] Logiko portal. Preuzeto sa: <https://logiko.hr/izvori/clanci/61-planiranje-i-prognoze-forecasting/234-forecasting-planiranje-potraznje> [Pristupljeno: svibanj 2023.]

- [13] Toppr portal. Preuzeto sa: <https://www.toppr.com/guides/business-economics/theory-of-demand/demand-forecasting/> [Pristupljeno: svibanj 2023.]
- [14] Edukacija portal. Preuzeto sa: <https://edukacija.rs/poslovne-vestine/menadzment/traznja> [Pristupljeno: svibanj 2023.]
- [15] EconomicsDiscussion.net. Preuzeto sa: <http://www.economicsdiscussion.net/essays/economics/6-important-factors-that-influence-the-demand-of-goods/926> [Pristupljeno: svibanj 2023.]
- [16] Fakultet prometnih znanosti, Distribucijska logistika II (materijali), Zagreb, 2019.
- [17] Markić B., Pavlović I., Problemi izgradnje eksperta za prognoziranje u poslovnim sustavima trgovine. Preuzeto sa: <https://hrcak.srce.hr/file/324069> [Pristupljeno: svibanj 2022.]
- [18] Simchi-Levi, D, Kaminsky, P., Simchi-Levi, E., Designing & Managing the Supply Chain: Concepts, Strategies, and Case Studies, New York, McGraw-Hill/Irwin, 2003.
- [19] Prezentacija. Munađar D., Prognoziranje. Fakultet organizacije i informatike, Sveučilište u Zagrebu. Preuzeto sa: <file:///C:/Users/Windows/Downloads/N04prognoziranje-final2.pdf> [Pristupljeno: svibanj 2023.]
- [20] Preuzeto sa: https://elfarchive1718.foi.hr/pluginfile.php/54392/mod_resource/content/0/NT-41-Metode%20prognoziranja%20na%20vremenskim%20nizovima.pdf [Pristupljeno: svibanj 2023.]
- [21] Jazbec, M. S. (2019.) Metode prognoze potražnje u lancu opskrbe. Diplomski rad. Zagreb: Sveučilište u Zagrebu, Fakultet prometnih znanosti
- [22] Dunković, D. (2004.) Traženje metode prognoziranja potražnje: Maloprodaja jestivog ulja. Ekonomski vjesnik br. 1 i 2 (17): 112-126
- [23] Paprić, D. (2020.) Procjena autokorelacijske funkcije. Diplomski rad. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za matematiku
- [24] CFI portal. Preuzeto sa: <https://corporatefinanceinstitute.com/resources/data-science/autocorrelation/> [Pristupljeno: kolovoz 2023.]

- [25] Microsoft portal. Preuzeto sa: <https://support.microsoft.com/en-gb/office/offset-function-c8de19ae-dd79-4b9b-a14e-b4d906d11b66> [Pristupljeno: kolovoz 2023.]
- [26] Microsoft portal. Preuzeto sa: <https://support.microsoft.com/en-us/office/define-and-solve-a-problem-by-using-solver-5d1a388f-079d-43ac-a7eb-f63e45925040> [Pristupljeno: kolovoz 2023.]
- [27] Microsoft portal. Preuzeto sa: <https://support.microsoft.com/en-gb/office/use-the-analysis-toolpak-to-perform-complex-data-analysis-6c67ccf0-f4a9-487c-8dec-bdb5a2cefab6> [Pristupljeno: kolovoz 2023.]
- [28] Prezentacija. Perković J., Regresija i korelacija Preuzeto sa: http://www.unizd.hr/portals/4/nastavni_mat/2_godina/statistika/10_predavanje.pdf [Pristupljeno: kolovoz 2023.]
- [29] Video. Asghar, Z. (2021.) Decomposition of Time Series Components Using Excel. Preuzeto sa: <https://www.youtube.com/watch?v=kTwtPq0rldQ> [Pristupljeno: kolovoz 2023.]

POPIS SLIKA

Slika 1 Integracija opskrbnog lanca	5
Slika 2 Funkcionalni ciklusi opskrbnog lanca.....	7
Slika 3 Push/Pull granica u opskrbnom lancu	8
Slika 4 Načelna shema određivanja strategije upravljanja opskrbnim lancem	8
Slika 5 Hijerarhija logističkog planiranja	10
Slika 6 Hijerarhija donošenja odluka za odabir lokacije	12
Slika 7 Usko grlo u opskrbnom lancu.....	13
Slika 8 Vrste zaliha s obzirom na vrstu robe i planiranje	17
Slika 9 a) Horizontalna šablona potražnje, b) Trendovska šablona potražnje	24
Slika 10 a) Sezonska šablona potražnje, b) Ciklična šablona potražnje,.....	24
Slika 11 Nasumična šablona potražnje	24
Slika 12 Opći princip prognoziranja koristeći vremenske nizove	29
Slika 13 Ulazni podaci za kefir	39
Slika 14 Podaci o potražnji za kefirom	40

POPIS TABLICA

Tablica 1 Autokorelacija s lagovima za kefir s 1,5% m.m.....	41
Tablica 2 Izračun potražnje za kefirom s 1,5% m.m. Holtovom metodom	43
Tablica 3 Izračun potražnje za kefirom s 1,5% m.m. Holtovom metodom (Solver)	44
Tablica 4 Izračun potražnje za kefirom s 1,5% m.m. metodom linearne regresije	47
Tablica 5 Rezultati regresije za kefir koristeći alat Data Analysis.....	48
Tablica 6 Ulazni podaci za bezglutenski kruh	49
Tablica 7 Izračun potražnje za bezglutenskim kruhom Winterovom metodom	54
Tablica 8 Izračun potražnje za bezglutenskim kruhom Winterovom metodom (Solver)	56
Tablica 9 Izračun potražnje za bezglutenskim kruhom metodom sezonske dekompozicije	58
Tablica 10 Rezultati regresije za bezglutenski kruh koristeći alat Data Analysis.....	60
Tablica 11 Prikaz točnosti izračuna Holtove metode za kefir	62
Tablica 12 Prikaz točnosti izračuna Winterove metode za bezglutenski kruh.....	65
Tablica 13 Prikaz točnosti izračuna Winterove metode, Winter (Solver) i sezonske dekompozicije za bezglutenski kruh	67

POPIS GRAFIKONA

Graf 1 Izračun matrice autokorelacije za kefir s 1,5% m.m.....	41
Graf 2 Prognozirane vrijednosti potražnje za kefirom za siječanj, veljaču i ožujak 2023. Holtovom metodom	43
Graf 3 Prognozirane vrijednosti potražnje za kefirom za siječanj, veljaču i ožujak 2023. Holtovom metodom (Solver)	45
Graf 4 Potražnja za bezglutenskim kruhom u 2021. i 2022.godini.....	50
Graf 5 Usporedba potražnje za bezglutenskim kruhom 2021. i u 2022.godini.....	51
Graf 6 Usporedba stvarne potražnje i prognozirane potražnje za bezglutenskim kruhom korištenjem Winterove metode.....	55
Graf 7 Prognozirane vrijednosti potražnje za bezglutenskim kruhom za siječanj, veljaču i ožujak 2023. Winterovom metodom	55
Graf 8 Usporedba stvarne potražnje i prognozirane potražnje za bezglutenskim kruhom korištenjem Winterove metode (Solver)	57
Graf 9 Prognozirane vrijednosti potražnje za bezglutenskim kruhom za siječanj, veljaču i ožujak 2023. Winterovom metodom (Solver).....	57
Graf 10 Usporedba stvarne potražnje i prognozirane potražnje za bezglutenskim kruhom korištenjem metode sezonske dekompozicije	61
Graf 11 Prognozirane vrijednosti potražnje za bezglutenskim kruhom za siječanj 2023. metodom sezonske dekompozicije	61
Graf 12 Grafički prikaz točnosti izračuna Holtove metode za kefir	63
Graf 13 Grafički prikaz potražnje i prognoza potražnje (Holtova metoda) za kefir.....	64
Graf 14 Grafički prikaz potražnje i prognoza potražnje (Winterova metoda) za bezglutenski kruh.....	65
Graf 15 Grafički prikaz točnosti izračuna Winterove metode za bezglutenski kruh	66
Graf 16 Grafički prikaz stvarne potražnje, prognoze potražnje Winterove metode i metode sezonske dekompozicije za bezglutenskim kruhom.....	67
Graf 17 Graf 15 Grafički prikaz točnosti izračuna Winterove metode (Solver) i sezonske dekompozicije za bezglutenski kruh	68

Sveučilište u Zagrebu
Fakultet prometnih znanosti
Vukelićeva 4, 10000 Zagreb

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad

isključivo rezultat mogega vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju upotrijebljene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedopušten način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu završnog/diplomskog rada pod naslovom Analiza učinka modela prognoze potražnje za prehrambene proizvode, u Nacionalni repozitorij završnih i diplomskih radova ZIR.

Student/ica:

U Zagrebu, 13.9.2023.

Shanon Marković
(ime i prezime, potpis)